



**HAL**  
open science

# Apport de la synergie entre Sentinel-1, Alos-2 et Sentinel-2 à l'estimation de l'humidité de surface des sols en zones semi-arides

Emna Ayari

► **To cite this version:**

Emna Ayari. Apport de la synergie entre Sentinel-1, Alos-2 et Sentinel-2 à l'estimation de l'humidité de surface des sols en zones semi-arides. Hydrologie. Université Paul Sabatier - Toulouse III; Institut national agronomique de Tunisie, 2023. Français. NNT : 2023TOU30211 . tel-04502431

**HAL Id: tel-04502431**

**<https://theses.hal.science/tel-04502431>**

Submitted on 13 Mar 2024

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

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

Université Fédérale



Toulouse Midi-Pyrénées

# THÈSE



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

Délivré par l'Université Toulouse 3 - Paul Sabatier

Cotutelle internationale: Université de Carthage

Présentée et soutenue par

**Emna AYARI**

Le 3 novembre 2023

**Apport de la synergie entre Sentinel-1, Alos-2 et Sentinel-2 à  
l'estimation de l'humidité de surface des sols en zones semi-  
arides**

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

Spécialité : **Surfaces et interfaces continentales, Hydrologie**

Unité de recherche :

**CESBIO - Centre d'Etudes Spatiales de la BIOSphère**

Thèse dirigée par

**Mehrez ZRIBI et Zohra Lili CHABAANE**

Jury

Mme Sihem BENABDALLAH, Rapporteur

M. Faysal BEN JEDDI, Examinateur

M. Christian WALTER, Examinateur

M. Nicolas BAGHDADI, Examinateur

Mme Zohra LILI CHABAANE, Co-directrice de thèse

Mme Valérie DEMAREZ, Présidente

# Résumé

---

Le développement des stratégies optimales pour gouverner et gérer durablement les ressources en eau, dans le secteur agricole, devient de plus en plus crucial, particulièrement au niveau du bassin Méditerranée. La quantification de l'humidité du sol constitue l'une des variables clés dans ces stratégies, vu son importance dans les interactions sol-végétation-atmosphère. Durant les dernières décennies, la télédétection radar a prouvé sa pertinence pour estimer et cartographier l'état hydrique en allant d'une échelle parcellaire à une échelle régionale.

Dans le cadre des futures missions des mesures radar en bande de fréquences L, les travaux de la présente thèse visent, en premier lieu, la proposition d'une approche pour estimer l'état hydrique du sol dans une région semi-aride, en Tunisie centrale en comparant le potentiel des données en bandes C et L. L'estimation de l'humidité du sol se base sur l'utilisation des mesures radar à synthèse d'ouverture (SAR) à haute résolution en bande L acquises par ALOS-2 en HH (L-HH) et en HV (L-HV) et en bande C acquises par Sentinel-1 en VV (C-VV) et en VH (C-VH) avec des mesures in-situ faites sur des parcelles sélectionnées dans la plaine de Kairouan. Pour quantifier l'humidité du sol, nous avons considéré deux types de végétation omniprésents dans la zone d'étude, les céréales et les piments structurés en lignes. Dans le but de simuler le signal radar sur des parcelles des céréales dans un contexte homogène d'humidité du sol, nous avons considéré deux options du Water Cloud Model (WCM) sans et avec le terme de diffusion lié à l'interaction sol-végétation. L'intégration du terme d'interaction sol-végétation apporte une amélioration importante des estimations d'humidité du sol en utilisant les données L-HV face à une amélioration limitée en utilisant les données en bande C. Lorsque la végétation est structurée en ligne et localement irriguée, la répartition spatiale de l'humidité est hétérogène. Nous avons proposé une version modifiée du WCM sur les parcelles des piments. La sensibilité du signal simulé avec le modèle WCM modifié diminue en fonction de l'augmentation de la hauteur et la fraction du couvert végétal. La comparaison des résultats de simulation dévoile que le modèle proposé est plus sensible à l'humidité du sol en utilisant les données L-HH qu'en C-VV.

Vu la complexité de la description de la végétation et la limitation des données optiques en présence des nuages, dans la deuxième partie des travaux, nous nous sommes intéressés au potentiel des données radar Sentinel-1 pour décrire la végétation dans le processus d'estimation d'humidité du sol. Nous avons utilisé la cohérence interférométrique et l'indice normalisé du rapport de polarisation pour estimer l'indice NDVI durant le cycle du blé en fonction des périodes de développement. Cette méthodologie développée a permis le retraçage des séries temporelles de NDVI des parcelles test de blé. Le rapport de polarisation et sa normalisation ont été testés en tant que descripteurs de végétation dans le modèle WCM pour estimer l'humidité du sol en utilisant les données Sentinel-1. Les résultats d'estimation de l'état hydrique du sol insistent sur la pertinence des données SAR pour décrire la végétation avec des RMSE inférieure à 7.5 vol.%. Dans la dernière partie des travaux de thèse, nous avons investigué le potentiel des séries temporelle de la variabilité de l'humidité de surface du sol dans l'identification des anomalies climatiques. Nous avons utilisé des produits opérationnels d'humidité du sol issus de la synergie Sentinel-1 et Sentinel-2 (HRSM) à une résolution spatiale kilométrique. Les résultats ont souligné la capacité des données à reproduire les évolutions de l'humidité à différents contextes climatiques sur le territoire Tunisien ainsi son potentiel à identifier les périodes de sécheresse.

**Mots-clés :** Etat de surface, télédétection, radar, bande L, bande C, optique, humidité, végétation, semi-aride.

# Abstract

---

The development of optimized strategies to govern and sustainably manage water resources, in agriculture sector, is becoming more and more crucial, practically in the Mediterranean basin. Soil moisture quantification constitutes one of key variable in these strategies thanks to its primordial role in soil-vegetation-atmosphere interactions. During the latest decencies, remote sensing proved its relevance to retrieve and mapping the hydric state from the field scale to regional one.

Within the context of future missions operating in L band frequency, the present work aims, in first place, to propose an approach to estimate the soil moisture in semi-arid region, in central Tunisia by comparing the potential of L and C bands. The soil moisture retrieval is based on the use of high-resolution synthetic aperture radar (SAR) measurements in L band acquired by ALOS-2 in HH (L-HH) and HV (L-HV) polarizations and in C band acquired by the Sentinel-1 in VV (C-VV) and VH (C-VH) polarization with the in-situ measurements collected in selected reference fields in the Kairouan plain.

To estimate the soil moisture, we considered two types of vegetation omnipresent in the study area, cereals as homogenous culture and pepper as row-structured vegetation. For radar signal simulations within cereal fields and homogenous soil moisture context, we considered two options of Water Cloud Model (WCM) without and with the soil-vegetation interactions' term. The integration of this term well improved the soil moisture retrieval using the L-HV regarding a limited improvement using the C band data. In the case of row-structured vegetation locally irrigated, the spatial distribution of soil moisture is heterogenous. Therefore, we proposed a modified version of WCM within pepper fields. The sensitivity of the simulated signal with modified WCM to the soil moisture decreased as function of vegetation cover fraction and height increase. The comparison between simulations' results highlights a higher sensitivity of the proposed model to soil moisture using L-HH data compared to the C-VV data use.

Due to the complexity of vegetation description and the lack of optical data in the presence of clouds, in the second part of the work, we were interested in the potential of radar Sentinel-1 data to describe the vegetation in the soil moisture retrieval process. We used the interferometric coherence and the normalized index of the polarization ratio to estimate the NDVI during the wheat cycle as function of the vegetation growth stage. The polarization ratio and its normalized index were tested as vegetation descriptors in WCM to estimate the water soil content using Sentinel-1 data. The retrieval results insist on the pertinence of SAR data to describe the vegetation with RMSE value lower than 7.5 vol.%.

In the last part of the present work, we investigated the potential of surface soil moisture time series to identify the climatic anomalies. We used operational products of soil moisture generated using the Sentinel-1 and Sentinel-2 synergy, namely HRSM products with kilometric spatial resolution. The results underlined the capacity of the HRSM products to reproduce the soil moisture evolution within different climatic contexts in Tunisian territory and to identify the drought periods.

**Key words:** Surface states, remote sensing, radar, L band, C band, optic, soil moisture, vegetation, semi-arid.

## الخلاصة

أصبح تطوير الإستراتيجيات المثلى لحوكمة الموارد المائية وإدارتها بشكل مستدام خاصة في القطاع الزراعي أمرا في غاية الأهمية لا سيما على مستوى الحوض الأبيض المتوسط. يعد القياس الكمي لرطوبة التربة أحد المتغيرات الرئيسية في هذه الإستراتيجيات، نظرا لأهمية دور رطوبة التربة في التحكم في تفاعلات التربة، الغطاء النباتي والغلاف الجوي. خلال العقود الماضية، أثبتت تقنيات الاستشعار عن بعد عبر الرادار نجاعتها في تقدير ورسم خرائط رطوبة التربة من نطاق قطعة الأرض إلى نطاق إقليمي.

في إطار المهام المستقبلية في نطاق التردد L، يهدف عمل هذه الأطروحة إلى اقتراح منهجية لتقدير رطوبة التربة في منطقة شبه قاحلة في الوسط التونسي، عبر مقارنة نجاعة البيانات في نطاق الترددات الرادار L و C. تستند هذه المنهجية إلى استخدام قياسات الرادار ذو الفتحة الاصطناعية (SAR) عالية الدقة في نطاق التردد عبر القمر الصناعي ذو استقطاب HH (L-HH) و استقطاب HV (L-HH) كذلك في نطاق التردد C عبر القمر الصناعي Sentinel-1 ذو استقطاب VV (C-VV) و استقطاب VH (C-VH). تعتمد هذه المنهجية أيضا على بيانات ميدانية جمعت في عدد من قطع الأراضي المختارة في سهل القيروان.

لقياس رطوبة التربة، قمنا بدراسة نوعين من النباتات الحبوب، كغطاء نباتي متجانس، والفلفل كغطاء نباتي غير متجانس منظم في صفوف. من أجل محاكاة إشارات الرادار عبر قطع الأراضي المغطاة بالحبوب، في سياق التوزيع المتجانس لرطوبة التربة، استعملنا خيارين لنموذج Water Cloud Model (WCM) بدون أو مع مصطلح تفاعلات التربة والغطاء النباتي. استخدام هذا المصطلح قام بتحسين تقدير رطوبة التربة عبر استعمال البيانات L-HV. مقابل تحسن محدود باستخدام بيانات في نطاق التردد . عندما يكون الغطاء النباتي منظما في خطوط ذات ري موضعي بالتنقيط، تتوزع رطوبة التربة بطريقة غير متجانسة على قطعة الأرض. لذلك اقترحنا نسخة معدلة من WCM. تتناقص حساسية الإشارة المحاكاة باستعمال النسخة المعدلة من WCM مع زيادة نمو الغطاء النباتي وارتفاعه. كشفت نتائج مقارنة المحاكاة أن النموذج المقترح أكثر حساسية لرطوبة التربة باستخدام L-HH مقارنة ب-C-VV.

نظرا لتعقيد ديناميكية الغطاء النباتي ومحدودية البيانات المرئية البصرية في حالة وجود السحب، فقد اهتمنا في الجزء الثاني من العمل بمقدرة بيانات الرادار Sentinel-1 على وصف الغطاء النباتي في عملية تقدير رطوبة التربة. استخدمنا تماسك التداخل الراداري والمؤشر الطبيعي لنسبة الاستقطاب لتقدير المؤشر الطبيعي للغطاء النباتي NDVI عبر مراحل نمو القمح. وقد سمحت هذه المنهجية بإعادة رسم السلاسل الزمنية لمؤشر NDVI لعدة قطع أراضي بالمنطقة المدروسة. تم اختبار نجاعة المؤشر الطبيعي لنسبة الاستقطاب في نموذج WCM لتقدير رطوبة التربة باستخدام بيانات Sentinel-1. تؤكد نتائج تقدير نسبة رطوبة التربة على أهمية بيانات SAR لوصف الغطاء النباتي بقيمة جذر الخطأ المتوسط التربيعي (RMSE) أقل من 7.5 vol.%.

في الجزء الأخير من الرسالة، قمنا بدراسة نجاعة السلاسل الزمنية لمنتجات رطوبة التربة السطحية في تحديد الحالات المناخية الشاذة. استعملنا في هذه الدراسة منتجات لرطوبة التربة (HRSM) استنادا لتأزر بيانات Sentinel-1 و Sentinel-2. بعد التحقق من توافق منتجات مع منتجات الأقمار الصناعية الأخرى، سلطت النتائج الضوء على قدرة هذه البيانات على رصد تطور رطوبة في سياقات مناخية مختلفة على الأراضي التونسية فضلا على قدرتها على تحديد فترات الجفاف.

**الكلمات المفتاحية:** حالة سطح الأرض، الاستشعار عن بعد، رادار، نطاق التردد L، نطاق التردد C، بيانات مرئية، رطوبة التربة، الغطاء النباتي، المناطق الشبه القاحلة.

*À l'âme de mon cher papa,  
À ma mère et mes soeurs,  
À ma famille et mes amis...*

# Remerciements

---

L'aventure de la thèse a commencé depuis quatre ans et elle touche à sa fin. Cette expérience a été enrichissante scientifiquement et humainement en oscillant entre les moments les plus heureux et les plus difficiles. Cette aventure a été marquée par plusieurs événements : le confinement et les restrictions sanitaires du COVID-19, les campagnes terrains, les conférences et la découverte des autres pays et cultures... À cette occasion je voudrais remémorer les personnes qui m'ont aidée à achever ce travail et arriver là.

J'aimerais remercier mes directeurs de thèse, Mme Zohra Lili-Chabaane coté INAT et M. Mehrez Zribi coté CESBIO. J'adresse mes profonds remerciements à Mme Zohra Lili-Chabaane de m'avoir acceptée en tant que doctorante au sein du laboratoire GREEN-TEAM. Je tiens à vous remercier pour votre encadrement, votre confiance et votre aide précieuse que vous m'avez accordés pour accomplir les travaux de la présente thèse. Vos enseignements de la télédétection et le SIG me suivront pour toujours.

Une gratitude particulière à M. Mehrez Zribi pour sa veille précieuse dans l'accomplissement de ce travail de recherche, son soutien scientifique ainsi moral, ses conseils et ses critiques très constructives et méticuleuses. Les nombreuses discussions que nous avons eues sont pour beaucoup dans les travaux de cette thèse. Je le remercie pour toute la patience et la disponibilité dont il a fait preuve de mon égard et pour sa confiance inébranlable en mes capacités à traiter ce sujet de thèse. Vous m'avez permis de faire mes premiers pas dans le monde de la recherche.

J'adresse mes remerciements chaleureux à Mme Zeineb Kassouk pour l'encadrement et le soutien qu'elle m'a apportés durant ces années de thèse. Merci beaucoup pour votre aide précieuse et vos encouragements.

Je tiens à remercier tous les membres du comité de suivi des travaux de thèse, M. Hamadi Hbaieb, M. Christian Walter et M. Nicolas Baghdadi pour leurs conseils et leurs commentaires enrichissants et pertinents. Je tiens à remercier les membres de mon jury, Mme Sihem BenAbdallah ; M. Faysal Ben Jeddi ; M. Frédéric Frappart ; Mme Valérie Demarez ; M. Christian Walter et M. Nicolas Baghdadi de m'avoir fait l'honneur d'évaluer mon travail. Je leur suis reconnaissante pour leur pédagogie, leurs remarques constructives, et d'avoir su passer outre les imperfections de mon manuscrit.

Cette thèse n'aurait pu être menée à bien sans l'aide et le support surtout moral de mes chères ami(e)s avec le(s)quel(le)s j'ai partagé des moments inoubliables et agréables sur terrain, au sein des laboratoires GREEN-TEAM et CESBIO : Haifa M. & Nadia, Sahar, Ons, Khouloud, Roiya, Raid, Ines, Hayfa Z., Manel, Hajer, Wissal M., Younes, Nitu, Ichraf, Maweheb, Soumaya, Asma, Fatma, Mariem K., Wissal K., Matteo R. et Fama. Je remercie également Azza, Safa, Wafa et Aicha pour leur aide et leurs précieux conseils.

J'adresse des remerciements spécifiques au personnel de l'INAT qui m'ont aidée à coordonner les missions terrain et collecter les données : Mohamed El Hedi, Mohamed Jeridi, Adel et Chedi. Je tiens à remercier particulièrement l'équipe IRD en Tunisie, Radhouan, Gaspard, Victor et Pierre pour leur aide incontournable durant les différentes missions terrains. Je remercie tout le personnel de la représentation IRD en Tunisie, Rim ; Wajdi ; Walid ; Anne Marie et Salwa, pour leur support inestimable qui a facilité toutes les procédures administratives et la logistique des missions terrain. Je suis éternellement reconnaissante pour tous les agriculteurs de la plaine de Kairouan pour leur accueil chaleureux et leur ample générosité avec nous durant les campagnes de collecte des données dans leurs parcelles.

Les séjours au sein du CESBIO étaient plus agréables avec le personnel du labo qui ont contribué à créer une excellente ambiance de travail et d'installation : Laurence, Dominique, Delphine et Ibrahim.

Cette thèse est le fruit du support et d'aide qu'avez consentis ma famille pour moi. Aucun remerciement ne saurait exprimer l'amour et le respect que j'ai toujours eu pour vous. Mon père Abid, vous êtes une partie de moi. Vous m'avez toujours enseigné d'être forte et de sacrifier pour notre famille. J'espère que j'ai pu t'honorer. Comme tu as toujours tout fait pour nous.

J'exprime ma gratitude éternelle et incontournable à ma mère Sameh et mes deux sœurs Imen et Ines. Vous étiez toujours présentes pour m'encourager dans tous mes moments d'exams par votre soutien moral et votre confiance infaillible et inaltérable. Les mots ne suffisent guère pour exprimer l'attachement, l'amour et l'affection inconditionnels, forts et intemporels que je porte pour vous. Merci d'avoir offert votre amour qui m'a permis de trouver ma place dans la vie. Vous êtes toujours ma source de puissance et d'espoir pour travailler et avancer sans hésitation ! Grâce à vos sacrifices, j'arrive à soutenir aujourd'hui ! Merci mes chères !



# Avant-propos

---

Cette thèse a été réalisée dans le cadre d'une cotutelle internationale entre l'Université de Paul Sabatier Toulouse III, sous la direction de **M. Mehrez Zribi**, et l'Université de Carthage/Institut National Agronomique de Tunisie (INAT), sous la direction de **Mme Zohra Lili Chabaane** avec un co-encadrement assuré par **Mme Zeineb Kassouk**. Ce travail est le fruit de plusieurs années de travail, réalisés à au laboratoire GREEN-TEAM à l'INAT et au Centre des Etudes Spatiales de la BIOSphère (CESBIO) à Toulouse.

Durant ces années de thèse, le travail a été suivi annuellement par le comité d'évaluation composé de **M. Hamadi Habaieb**, professeur à l'INAT et Directeur Général du Bureau de la Planification et des Equilibres Hydraulique, **M. Nicolas Baghdadi**, Directeur de Recherche à l'Institut National de Recherche en Sciences et Technologies pour l'environnement et l'agriculture (INRAE) et **M. Christian Walter**, professeur à l'Institut Agro Rennes-Angers.

Entre le 01/06/2021 et 31/05/2022, j'ai bénéficié d'une bourse de 24 mois pour les séjours en France et en Tunisie délivré par le programme des allocations de recherche pour une thèse de sud (**ARTS**) de l'Institut de Recherche pour le Développement en France (**IRD**). Egalement, cette thèse a été réalisée et financée dans le cadre de plusieurs projets :

- Le projet "Vulnerabilities and adaptive capacities of Irrigated Agriculture in North Africa (**VIANA**)" financé par ERA-NET ARIMNet, coordonné par Mme Zeineb Kassouk en Tunisie.
- Le projet **PHC Utique** intitulé Identification des Pratiques Agricoles et Surveillance des Sols par télédétection en milieux semi-aride et tempéré (**IPASS**) 20G0903, coordonné par Mme Zeineb Kassouk et M. Youssef Fouad.
- Le projet **ERANET-MED CHAAMS** : Global Change : Assessment and adaptation to mediterranean Region Water Scarcity, coordonné par M. Lionel Jarlan, Mme Hedia Chakroun et M. Mehrez Zribi et par Mme Zohra Lili Chabaane pour l'équipe de l'UCAR.
- Le projet H2020 RISE Accounting for Climate Change in Water and Agriculture management (**ACCWA**), coordonné par Mme Maria José Escorihuela et Mme Zohra Lili Chabaane pour l'équipe de l'UCAR.
- Les projets **ESA Irrigation+** et **TAPAS TOSCA/CNES**

# Table des matières

---

<b>Introduction Générale.....</b>	<b>1</b>
Contexte scientifique.....	2
Objectifs et plan du manuscrit.....	6
<b>Chapitre I : Apport de la télédétection radar à la caractérisation des états de surface.....</b>	<b>10</b>
I.1. Etats de surface continentale.....	11
I.1.1. Notions et variables des états de surface.....	11
I.1.2. Etat hydrique des surfaces continentales.....	13
I.2. Suivi des états de surface en utilisant la télédétection radar .....	25
I.2.1. Principe d'acquisition des images radar.....	25
I.2.2. Géométrie des acquisitions des radar à ouverture de synthèse .....	25
I.2.3. Mesures des capteurs SAR.....	27
I.2.4. Sensibilité du signal radar .....	28
I.2.5. Modélisation du signal radar à travers les scènes agricoles .....	33
I.2.6. Méthodes d'inversion des modèles .....	39
I.3. Apport de l'état hydrique estimé par télédétection dans la compréhension des processus naturels .....	39
I.4. Conclusions.....	42
<b>Chapitre II : Description de la zone d'étude et de la base des données .....</b>	<b>44</b>
II.1. Description du site d'étude : La plaine de Kairouan.....	45
II.1.1. Situation géographique .....	45
II.1.2. Contexte géologique .....	46
II.1.3. Contexte climatique .....	46
II.1.4. Ressources en sols .....	49
II.1.5. Contexte hydrologique et hydrogéologique.....	51
II.1.6. Contexte agricole et occupation du sol.....	53
II.2. Description de la base de données .....	55
II.2.1. Données In-situ.....	55
II.2.2. Données satellites .....	64
II.2.3. Produits satellitaires opérationnels d'humidité de surface.....	70
II.3. Conclusions.....	72
<b>Chapitre III : Comparaison du potentiel des données en bandes C et L pour estimer l'humidité de surface du sol à une échelle parcellaire .....</b>	<b>73</b>
III.1. Introduction .....	74
III.2. Estimation de l'humidité sur sols couverts par des céréales .....	75
III.2.1. Résumé .....	75

III.2.2. Article.....	77
III.3. Estimation de l'humidité sur sols couverts par des piments.....	103
III.3.1. Résumé .....	103
III.3.2. Article.....	105
III.4. Conclusions .....	129
<b><i>Chapitre IV : Apport des données SAR pour décrire la végétation dans le processus d'estimation de l'humidité de surface du sol.....</i></b>	<b>130</b>
IV.1. Introduction.....	131
IV.2. Reconstruction du cycle NDVI en utilisant des données SAR .....	132
IV.2.1. Résumé.....	132
IV.2.2. Article.....	133
IV.3. Sensibilité de l'estimation de l'humidité du sol aux descripteurs de la végétation estimés à partir des données SAR.....	171
IV.3.1. Résumé .....	171
IV.3.2. Article.....	172
IV.4. Conclusions .....	186
<b><i>Chapitre V.....</i></b>	<b>188</b>
<b><i>Apport de l'humidité de surface du sol dans le suivi de la variabilité climatique à une échelle régionale.....</i></b>	<b>188</b>
V.1. Introduction .....	189
V.2. Matériels et Méthodes .....	190
V.2.1. Base de données .....	190
V.2.2. Méthodologie.....	192
V.3. Résultats et Discussion .....	193
V.3.1. Intercomparaison des produits HRSM et SMAP.....	193
V.3.2. Evolution mensuelle des humidités de surface du sol des produits HRSM.....	197
V.3.3. Intercomparaison des moyennes mensuelles HRSM et SMAP .....	198
V.4. Conclusions et perspectives.....	204
<b><i>Conclusions et perspectives.....</i></b>	<b>205</b>
<b><i>Références.....</i></b>	<b>211</b>

## Liste des figures

---

<b>Figure 1.</b> Les changements à long-terme des variables du cycle d'eau (précipitation, évapotranspiration, le ruissellement et l'humidité de surface) selon le model SSP2-4.5 (2081-2100 vs 1995-2014) du rapport (IPCC, 2022).....	3
<b>Figure 2.</b> Les interactions des états de surface du sol et les processus hydrologiques sous l'effet des facteurs climatiques et anthropiques (Arnaud, 2009, modifié par Ayari,2023).....	12
<b>Figure 3.</b> Illustration du phénomène de rétention de l'eau en fonction de la texture du sol : (a) sol granulaire et (b) sol à texture fine (Delage, 2000).....	14
<b>Figure 4.</b> Illustration d'une ThetaProbe composée du corps, la ligne de transmission et du réseau des aiguilles (Gaskin & Miller, 1996).....	17
<b>Figure 5.</b> Localisation des réseaux des mesures in-situ de l'humidité du sol ISMN en juillet 2021 (Dorigo et al., 2021). ....	18
<b>Figure 6.</b> Les parties principales du spectre électromagnétique (Girard & Girard, 2010). ....	19
<b>Figure 7.</b> Les exigences des résolutions temporelle et spatiale des produits d'humidité du sol en fonction des applications : Climatologie, la prévision numérique de la météo (NWP), Hydrologie, gestion des risques, agriculture, foresterie (Peng et al., 2021).....	24
<b>Figure 8.</b> Principe d'acquisition d'imagerie radar en émettant des impulsions par le capteur radar et la mesure des échos dans la direction de sa vision (Talla Tankam et al., 2010).....	25
<b>Figure 9.</b> Géométrie des scènes observées lors de l'acquisition des images radar aéroportées en illustrant les deux directions de résolution spatiale (transversale et longitudinale). ....	26
<b>Figure 10.</b> Principe de la technique des radars à synthèse d'ouverture (Maitre, 2001). ....	27
<b>Figure 11.</b> (a) Image optique Sentinel-2 avec une résolution $10 \times 10$ m avec une Couverture nuageuse 64% (b) Image radar ALOS-2 en bande L, Polarisation HH dont la taille des pixels est $6 \times 6$ m. ....	29
<b>Figure 12.</b> Direction de vibration du champ électrique : Horizontale (H) ou Verticale (V) (Centre Canadien de télédétection : CCRS, <a href="http://www.ccrs.nrcan.gc.ca">http://www.ccrs.nrcan.gc.ca</a> ). ....	29
<b>Figure 13.</b> Illustration de l'angle d'incidence (Girard et Girard, 2010). ....	30
<b>Figure 14.</b> Différents types de contribution dans la rétrodiffusion du signal radar dans des sols couverts (Bellakanji, 2015). ....	30
<b>Figure 15.</b> Sensibilité de la constante diélectrique et le contenu en eau du sol en fonction de la texture du sol et la fréquence de l'onde (Hallikainen et al., 1985). ....	31
<b>Figure 16.</b> Comportement du signal radar (valeur des coefficients de rétrodiffusion) en fonction de la rugosité des surfaces. ....	33
<b>Figure 17.</b> Localisation de la plaine de Kairouan dans le gouvernorat de Kairouan.....	45
<b>Figure 18.</b> Répartition des précipitations annuelles de la station de Kairouan synoptique entre 1986 et 2022. ....	47
<b>Figure 19.</b> Répartition des précipitations moyennes mensuelles de la station de Kairouan synoptique durant la période entre 1986 et 2022. ....	48
<b>Figure 20.</b> Répartition des températures moyennes, minimales et maximales mensuelles de la station de Kairouan synoptique durant la période entre 1986 et 2022. ....	48
<b>Figure 21.</b> Carte de texture des sols de la plaine de Kairouan (extraite de la carte agricole 2000). ....	49
<b>Figure 22.</b> Produits de texture des sols de la plaine de Kairouan réalisée à partir des données optiques (Shabou et al., 2015), radar (Zribi et al., 2012 et Gorrab et al., 2015) et la synergie des données optiques-radar (Bousbih et al., 2019) à des différentes étendues sur le site d'étude. ....	50
<b>Figure 23.</b> Evolution du niveau d'eau dans l'aquifère de la plaine de Kairouan depuis les inondations de 1969, l'implémentation du barrage El Haouareb en 1989 jusqu'à 2010. Ces courbes sont établies à partir des niveaux piézométriques au niveau de P1 et P2 (sur Merguellil	

jusqu'à 1989 et le barrage El Haouareb après 1989), P3 et P4 (dans la zone de recharge saisonnière) et P5 et P6 (renseignant sur le niveau de l'aquifère de la plaine de Kairouan) (Massuel & Riaux, 2017). .....	52
<b>Figure 24.</b> Occupation du sol de la plaine de Kairouan, de résolution spatiale de 10 m, produite à partir des données optiques Sentinel-2 et des observations terrain de la campagne hiver-printemps 2019-2020 (Zayani, 2023). .....	54
<b>Figure 25.</b> Localisation des parcelles de référence des céréales durant les deux campagnes terrain 2019/2020 et printemps 2022 dans la plaine de de Kairouan. ....	57
<b>Figure 26.</b> Stades phénologiques du blé suivis lors des missions terrain durant 2019/2020 et printemps 2022 : germination, tallage, montaison, floraison, et remplissage des grains. ....	58
<b>Figure 27.</b> Localisation des parcelles de référence des piments durant la campagne terrain d'été 2020 dans la plaine de de Kairouan par deux rectangles en pointillé. Le contenu de chaque rectangle est représenté à droite de la figure. ....	59
<b>Figure 28.</b> Stades phénologiques des piments suivis lors des missions terrain durant les trois mois Juin, Juillet et Août 2020. ....	60
<b>Figure 29.</b> Mesures de rugosité en utilisant le rugosimètre à aiguilles dans les parcelles test. ....	62
<b>Figure 30.</b> Exemple illustratif des images hémisphériques acquises sur des parcelles test de blé à différentes phases physiologiques avec les résultats des traitements pour calculer l'indice foliaire. ....	63
<b>Figure 31.</b> Différents modes d'acquisition des images ALOS-2 (Stripmap, ScanSAR et Spotlight) et leurs caractéristiques (Japan Aerospace Exploration Agency : JAXA). ....	65
<b>Figure 32.</b> Illustration des produits HRSM en Tunisie pour le mois d'avril sur quatre années (2017, 2019, 2020 et 2022). ....	71
<b>Figure 33.</b> Résultats d'inversion des deux options du WCM couplées aux IEM-B et g(Mv, Hrms) exprimés en RMSE (vol.%) en utilisant les données en bande L (L-HH et L-HV) et en bande C (C-VV et C-VH). ....	77
<b>Figure 34.</b> Organigramme décrivant le WCM modifié avec les équations utilisées. ....	104
<b>Figure 35.</b> Classification des étages bioclimatiques de la zone d'étude en Tunisie avec la localisation des stations météorologiques (la station barrage Joumine, la station Tunis et la station de Kairouan). ....	191
<b>Figure 36.</b> Séries temporelles des précipitations et des températures des trois stations : barrage Joumine (données fournies par la direction des barrages), Tunis et Kairouan (données fournies par le site Meteostat <a href="https://meteostat.net/fr/">https://meteostat.net/fr/</a> ). ....	192
<b>Figure 37.</b> Séries temporelles des mesures d'humidité à partir des produits SMAP, SMAP-AM, SMAP-PM et HRSM entre 2017 et 2022 en fonction des étages bioclimatiques : (a) humide (b) subhumide (c) aride à hiver doux (d) aride à hiver frais (e) semi-aride à hiver doux et (f) semi-aride à hivers frais. ....	194
<b>Figure 38.</b> Séries temporelles des mesures d'humidité à partir des produits SMAP, SMAP-AM, SMAP-PM et HRSM entre 2017 et 2022 à un climat subhumide. ....	195
<b>Figure 39.</b> Séries temporelles de l'indice normalisé des mesures d'humidité à partir des produits SMAP, SMAP-AM, SMAP-PM et HRSM entre 2017 et 2022 en fonction des étages bioclimatiques : (a) humide (b) subhumide (c) aride à hiver doux (d) aride à hiver frais (e) semi-aride à hiver doux et (f) semi-aride à hiver frais. ....	196
<b>Figure 40.</b> Variation des moyennes mensuelles des humidités de surface du sol sur l'étendue des produits HRSM (entre Janvier 2017 jusqu'à Juin 2022) en fonction des étages bioclimatiques. ....	197
<b>Figure 41.</b> Moyennes mensuelles des produits SMAP (a) SMAP-AM (b) et SMAP-PM (c) en fonction des moyennes mensuelles HRSM colorées par étage bioclimatique. ....	198
<b>Figure 42.</b> Séries temporelles des moyennes mensuelles calculées à partir des données SMAP, SMAP-AM, SMAP-PM et HRSM durant la saison pluvieuse entre 2017 et 2022 en fonction	

des étages bioclimatiques : (a) humide (b) subhumide (c) aride à hiver doux (d) aride à hiver frais (e) semi-aride à hiver doux et (f) semi-aride à hiver frais..... 200

**Figure 43.** Séries temporelles des indices mensuels calculés à partir des données SMAP, SMAP-AM, SMAP-PM et HRSM durant la saison pluvieuse entre 2017 et 2022 en fonction des étages bioclimatiques : (a) humide (b) subhumide (c) aride à hiver doux (d) aride à hi hiver frais (e) semi-aride à hiver doux et (f) semi-aride à hiver frais. Les cadres en bleus localisent les zones de différence entre les indices des deux produits d'humidité..... 202

## *Liste des tableaux*

---

<b>Tableau 1.</b> Plages de fréquence et de longueurs d'onde du signal radar.....	28
<b>Tableau 2.</b> Récapitulatif [min, max] des mesures in-situ collectées lors de la première campagne terrain des paramètres de rugosité (Hrms, Lc), de l'humidité à 5 cm de profondeur Mv (vol.%) et les variables biophysiques (Hauteur (H), Indice foliaire (LAI) et contenu en eau de la végétation (VWC)). .....	56
<b>Tableau 3.</b> Récapitulatif [min, max] des mesures in-situ collectées lors de la deuxième campagne terrain des paramètres de rugosité (Hrms, Lc), de l'humidité à 5 cm de profondeur (entre les lignes de végétation Mvinter-row (vol.%) et sur la ligne des piments Mvvegr-row) et les variables biophysiques des piments (Hauteur (H), Indice foliaire (LAI) et Fraction de couvert (Fc). .....	56
<b>Tableau 4.</b> Caractéristiques des images ALOS-2 acquises sur la plaine de Kairouan durant l'année agricole 2019/2020 et les images supplémentaires acquises en 11/2014, 11/2015 et en 2016. ....	66
<b>Tableau 5.</b> Caractéristiques des images Sentinel-1 acquises sur la plaine de Kairouan durant les années agricoles (2018/2019, 2019/2020 et 2021/2022). .....	68
<b>Tableau 6.</b> Caractéristiques des images Sentinel-2 acquises sur la plaine de Kairouan durant les années agricoles (2018/2019, 2019/2020 et 2021/2022). .....	70
<b>Tableau 7.</b> Les valeurs RMSE de l'humidité volumétrique caractérisant la relation des moyennes mensuelles calculées à partir des données SMAP, SMAP-AM et SMAP-PM en fonction des moyennes mensuelles des humidités de surface HRSM selon l'étage bioclimatique et selon la saison pluvieuse (P) et la saison sèche (S). .....	203

# Introduction Générale

---



# Introduction Générale


---

## Contexte scientifique

Le monde témoigne actuellement d'un réchauffement climatique considérable (IPCC, 2022). Entre 2021-2040 et 1850-1900, la hausse de température est prévue supérieure à 1.5°C (IPCC, 2022). Cette situation alarmante de réchauffement induit un déficit hydrique de 393 Km<sup>3</sup>/année prévu en 2050 (Droogers et al., 2012). C'est la conséquence d'une augmentation de la demande évaporative des surfaces continentales et de la transpiration de la végétation face à une diminution des taux de précipitations.

Selon les scénarii des changements climatiques (**Figure 1**), le bassin méditerranéen (MED), identifié comme un hotspot du changement climatique (Giorgi & Lionello, 2008 ; IPCC, 2022 ; Pörtner et al., 2022) est menacé par des déclin des taux de précipitation entre 10 et 20 %. Cette diminution se superpose avec des déficits d'évapotranspiration entre 5 et 10%, des chutes des quantités ruisselées (jusqu'à 40%) et des quantités d'humidité du sol de surface (de l'ordre de 10%)(IPCC, 2022). Par conséquent, le taux d'aridité va augmenter et les risques des sécheresses hydrologiques, agronomiques et écologiques seront plus fréquents (Droogers et al., 2012 ; Pörtner et al., 2022 ; Schilling et al., 2020).

La région MED, dotée de 0.7% des ressources en eau douce disponibles dans le monde, est soumise de plus aux forçages anthropiques sous forme des changements des systèmes agricoles et l'augmentation de l'extraction des eaux d'irrigation (Elliott et al., 2014 ; MedECC, 2020). Ces risques sont plus sévères dans la rive sud du bassin MED. Elle ne possède que 28% des ressources hydriques renouvelables des régions méditerranéennes pour faire face à une forte demande pour assurer une sécurité alimentaire équitable aux populations (Araus, 2004 ; MedECC, 2020 ; Seager et al., 2019).



**Figure 1.** Les changements à long-terme des variables du cycle d'eau (précipitation, évapotranspiration, le ruissellement et l'humidité de surface) selon le model SSP2-4.5 (2081-2100 vs 1995-2014) du rapport (IPCC, 2022).

La Tunisie fait partie des pays de l'Afrique du Nord les plus menacés par la pénurie d'eau (Gafrej, 2016 ; Trambly et al., 2020). Selon les prévisions du ministère de l'agriculture, des ressources hydrauliques et de la pêche maritime en Tunisie, la disponibilité d'eau est au-dessous du niveau critique du stress hydrique ( $500 \text{ m}^3/\text{habitant}/\text{an}$ ). Elle décroîtra à une valeur de  $268.3 \text{ m}^3/\text{habitant}$  à l'horizon de 2050. Cette situation est le résultat de plusieurs facteurs limitant l'offre des ressources en eaux tels que la répartition spatiotemporelle erratique des pluies, le climat et la surexploitation des eaux souterraines. Sur la majorité du territoire tunisien, le climat est semi-aride à aride. Il se caractérise par un régime pluvieux perturbé par des pluies extrêmes telles les inondations de septembre-Octobre 1969, de mars 1973 et de janvier 1990 ou bien des longues périodes de sécheresse (par exemple 1983-1984, 1987-1988, 2019-2023) favorisant une forte évaporation accompagnée par le sirocco (Habaieb & Albergel, 2000 ; Slimani et al., 2007).

En outre, ce régime pluvieux suit un gradient spatial décroissant vers le sud : entre 1500 mm/an à l'extrême Nord, entre 200 et 400 mm/an au Centre et 50-200 mm/an au Sud. Il est impacté par une augmentation préalable de la température avec 1.5° et 2° et des périodes de retour des pluies irrégulières. Le secteur agricole en Tunisie consomme 80% des ressources en eau disponibles de surface et souterraines. Selon les chiffres d'Aquastat en 2002, le prélèvement des eaux pour l'agriculture dépasse 40% des ressources hydrauliques pour irriguer des superficies privées et publiques réparties du Nord au Sud. Bien que les superficies irriguées contribuent par 30% dans la couverture des besoins de consommation en produits agricoles, elles sont caractérisées par des pertes importantes de l'ordre de 30 à 40% dues au transport et aux mauvaises pratiques d'irrigation.

Contrairement à sa pauvreté en ressources en eau accentuée par l'aridité du climat, le centre de la Tunisie possède un potentiel agricole important. Selon les chiffres déclarés dans l'annuaire statistique de 2018 du ministère de l'agriculture en Tunisie, 62.5% (6%) de la production agricole du centre de la Tunisie (nationale) est produite au niveau de la délégation de Kairouan. Cette dernière dispose du plus grand réservoir d'eau de la Tunisie centrale : la plaine de Kairouan. Elle est soumise à l'effet conjugué de l'irrégularité climatique et de l'anthropisation croissante (Cudennec et al., 2003 ; Feuillette et al., 2003). Ces facteurs ont favorisé l'extension des superficies irriguées et l'intensification des systèmes agricoles via le recours aux forages privés (Leduc et al., 2007, 2017 ; Massuel & Riaux, 2017) . Cette situation inquiétante et critique requiert l'évaluation et la quantification des ressources hydrauliques disponibles dans la plaine de Kairouan afin de prévoir des plans de gestion agricoles précises allant de l'échelle de la parcelle jusqu'à régionale. Par ailleurs, l'analyse de ces aléas implique la caractérisation des variables d'états de surface telle que l'humidité du sol qui constitue un élément majeur dans la répartition des précipitations en différents processus hydrologiques (l'évapotranspiration, l'infiltration et le ruissellement).

L'humidité du sol peut être quantifiée directement par des mesures in-situ gravimétriques ou en utilisant des sondes. Ces mesures localisées sont insuffisantes pour couvrir la variabilité spatiotemporelle du contenu en eau du sol (Babaeian et al., 2019 ; Peng et al., 2021).

Pour couvrir cette variabilité spatiotemporelle de l'état hydrique dans les zones arides et semi-arides, la télédétection est une alternative pertinente pour estimer l'humidité du sol en utilisant les données optiques, thermiques et hyperfréquences à différentes échelles spatiales : parcellaire, au niveau du bassin versant et régionale. Grâce à leur sensibilité à l'humidité du sol,

la technique micro-onde des radars est souvent sollicitée pour estimer le contenu en eau du sol (Engman & Chauhan, 1995 ; Peng et al., 2021).

En se basant sur l'énergie émise naturellement par les surfaces continentales, la télédétection dans le domaine des micro-ondes a réussi à estimer l'humidité du sol à une fréquence temporelle qui peut aller à un jour mais avec une résolution spatiale grossière entre 25 et 36 Km tels que les produits de la mission SMOS (Kerr et al., 2001), Soil Moisture Active/Passive (SMAP)(Entekhabi et al., 2010) ou les produits ASCAT (Wagner et al., 2007, 2013).

La résolution spatiale a été affinée en utilisant les acquisitions des capteurs radar à synthèse d'ouverture (SAR) en bandes X avec les images acquises par Cosmo-SkyMED et TerraSARX (Aubert et al., 2013 ; El Hajj et al., 2016 ; Gorrab, 2014) , en bande C (Amzirh et al., 2018 ; Amri et al., 2012 ; Bousbih et al., 2017 ; Ezzahar et al., 2020 ; Gao et al., 2017 ; Kumar et al., 2019 ; Ouaadi et al., 2020) et en bande L ((Fascetti et al., 2017 ; Hamze et al., 2021 ; Hosseini & McNairn, 2017 ; Lievens & Verhoest, 2011 ; Shi et al., 1995, 1997 ; Zribi et al., 2019). La disponibilité des données SAR à résolution spatiale métrique a permis l'établissement des approches d'estimation d'humidité du sol à une échelle parcellaire fine.

Ces approches sont basées sur une modélisation du comportement du signal radar dans les milieux agricoles. Dans le cas des sols nus, il existe plusieurs types de modèle pour simuler le comportement du signal radar face à des rugosités et des humidités de surface différentes. Les modèles physiques sont basés sur les théories de la diffusion électromagnétique tels que le modèle Small Perturbation Model (SPM), Geometrical Optic Model (GOM), Physical Optic Model (POM) (Ulaby et al., 1990) et Integral Equation Model (IEM) (Fung et al., 1992). Les modèles semi-empiriques comme Dubois (Dubois et al., 1995) et Oh (Oh et al., 1994) ont prouvé leur pertinence pour simuler la rétrodiffusion des sols nus. Pour les sols couverts, les modèles utilisés sont physiques tels que le modèle Michigan Microwave Canopy Scattering MIMCS (Ulaby et al., 1990) et le modèle Karam (Karam et al., 1995) ou bien semi-empirique comme Water Cloud Model (WCM) (Attema & Ulaby, 1978). L'estimation de l'humidité du sol est issue suite à l'inversion des modèles précédemment cités en utilisant plusieurs méthodes telles que l'inversion directe, le look up tables, les approches probabilistes ou bien en utilisant les algorithmes du Machine Learning de régression tels que Random Forest, Support Vector Machine, XGBoost (Extreme Gradient Boosting) et le réseau des neurones artificiels.

Grâce aux lancements des deux constellations Sentinel-1 A en 03 avril 2014 et Sentinel-1 B en 25 avril 2016, des données SAR en bande C sont disponibles à l'utilisation en offrant une résolution spatiale de 10 m avec un intervalle d'acquisition entre les deux satellites de 6 jours. Cette disponibilité a forgé davantage les travaux en bande C pour quantifier le contenu en eau du sol à une échelle parcellaire à une échelle régionale. En contrepartie, les travaux en bande L sont limités à deux missions japonaises Advanced Land Observing Satellite (ALOS) et ALOS-2 lancé par l'agence spatiale japonaise JAXA et à la mission argentine Satélite Argentino de Observacion COndMicroondas (SAOCOM).

Afin de remédier cette carence en données en bande L, des nouvelles missions sont projetées dans le futur : La mission Tandem-L conçue par l'agence allemande pour acquérir des données interférométriques en bande L (Blaes & Defourny, 2003), la mission NASA-ISRO SAR (NISAR) en 2023 (Kellogg et al., 2020) et la mission du Radar Observing System for Europe L-band (ROSE-L) qui sera lancé par l'agence spatiale Européenne (ESA) en 2028 (Torres et al., 2020). Une mission ALOS-4 est planifiée en 2024 par l'agence japonaise JAXA pour améliorer la résolution spatiotemporelle de l'acquisition en bande L (Motohka et al., 2019).

En vertu de ce contexte scientifique, l'objectif principal de cette thèse est la caractérisation des états de surface d'une zone d'étude menacés par les aléas d'aridité et de sécheresse. Les travaux se basent sur la modélisation et l'inversion du signal radar pour estimer l'humidité du sol à une échelle parcellaire à des différents contextes de répartition spatiale, en utilisant des données en bandes L et C ainsi qu'une variété de descripteurs de végétation. A une échelle régionale, une analyse spatiotemporelle des produits opérationnels d'humidité du sol était conduite afin d'étudier la variabilité de ce paramètre en fonction des étages bioclimatiques. Pour plus de précision, Nous avons tracé les objectifs d'une manière plus détaillée dans la partie suivante.

## Objectifs et plan du manuscrit

Dans le contexte de la recherche des stratégies de gestion optimale des ressources hydrauliques dans les régions à climat semi-aride, les travaux de la présente thèse visent l'évaluation du potentiel des données radar en bande L acquises par le satellite ALOS-2 et les données en bande C acquises par les satellites A et B pour estimer l'humidité du sol surfacique.

En considérant les différentes caractéristiques des états de surface en termes des propriétés géométriques (rugosité) et diélectriques du sol (humidité et texture) et de la dynamique du couvert végétal, nous estimons le contenu en eau du sol dans des parcelles de références sélectionnées dans la plaine de Kairouan.

Ce site d'étude a constitué depuis des années un observatoire continu du centre de la Tunisie témoignant les irrégularités climatiques en termes des événements extrêmes : des pluies torrentielles et des saisons de sécheresse successives. Ce site d'étude a attiré plusieurs projets scientifiques durant des années traitant les problématiques de gestion des ressources naturelles et les impacts d'anthropisation et du changement climatique (Lili Chabaane et al., 2014 ; Massuel et al., 2017). La diversité et la richesse des sources des données sur ce site l'élisent pour enchaîner d'autres travaux scientifiques dont cette thèse fait partie. Durant les années de thèse, nous avons ciblé trois objectifs principalement :

- La comparaison du potentiel des données SAR en bandes C et L pour estimer l'humidité du sol dans des différents contextes de répartition spatiale homogène et hétérogène du contenu en eau à l'échelle parcellaire.
- L'exploitation des données radar en bande C pour décrire et le suivi de la végétation et leur apport dans le processus de l'estimation de l'humidité du sol
- L'étude de l'apport de la variable d'humidité du sol de surface dans l'analyse de la variabilité climatique à une échelle régionale.

Pour répondre à ces objectifs, nous avons structuré les approches développées et les résultats obtenus en cinq chapitres :

- **Le premier chapitre : Apport de la télédétection radar à la caractérisation des états de surface**

Il comprend une revue bibliographique sur la caractérisation des états de surface plus précisément l'importance de l'humidité du sol, quelques généralités sur la télédétection active et leur rôle dans la caractérisation des milieux agricoles ainsi que les différentes approches développées pour estimer l'état hydrique.

- **Le deuxième chapitre : Description de la zone d'étude et des bases de données expérimentale et satellite**

Il englobe en premier lieu une description du site d'étude ainsi que les variables de suivi des états de surface mesurées localement durant les missions terrains.

Cet axe a permis d'acquérir des données terrain dans des différentes parcelles de référence sélectionnées dans la plaine de Kairouan. Ces parcelles sont soit des sols nus, soit des sols couverts en céréales et en cultures maraîchères. Afin de suivre la variabilité des états de surface des parcelles, la caractérisation géométrique de la surface comprend

des mesures de rugosité ainsi que des mesures d'humidité de surface. Pour la végétation, les variables de suivi de la dynamique du couvert végétale sont l'indice foliaire, le contenu en eau et la hauteur de végétation. La deuxième partie de ce chapitre détaille les différentes caractéristiques des images satellites utilisées dans cette thèse : Advanced Land Observing Satellite -2 (ALOS-2) en bande L et les deux satellites Sentinel-1 A et B en bande C.

- **Le troisième chapitre : Comparaison du potentiel des données en bandes C et L pour estimer l'humidité du sol de surface à une échelle parcellaire**

Il est consacré pour la comparaison du potentiel des données en bandes L et C pour estimer l'humidité du sol à une échelle parcellaire. Ce chapitre est subdivisé en deux parties selon la répartition spatiale de l'humidité :

- Une répartition spatiale homogène de l'humidité du sol dans des parcelles de céréales. Dans ce sous-chapitre, l'analyse du comportement des signaux radar mesurés sur les surfaces des céréales est réalisé selon trois étapes : l'analyse des sensibilités des données SAR bi-fréquences en fonction des propriétés du sol et en fonction des paramètres biophysiques du couvert végétale et la simulation des signaux radar à travers des modèles de rétrodiffusion des surfaces du sol. L'humidité du sol est issue en inversant les modèles de rétrodiffusion utilisés tout en comparant le potentiel des produits radars utilisés. (Cette partie a été valorisée par la publication I).
- Une répartition spatiale hétérogène de l'humidité du sol dans des parcelles de piments structurés en lignes, irrigués gouttes à gouttes et espacés par un sol nu. L'étude du comportement des signaux radars dans ce contexte s'appuie sur la proposition et l'examen du potentiel d'une version modifiée du Water Cloud Model (WCM) adaptée au contexte d'une répartition spatiale hétérogène de l'humidité du sol. (Cette partie a été valorisée par la publication II).

- **Le quatrième chapitre : Apport des données SAR pour décrire la végétation dans le processus d'estimation l'humidité du sol**

Ce chapitre est dédié à l'analyse du potentiel des données en bande C acquises par Sentinel-1 pour décrire la dynamique de la végétation. Il se scinde en deux parties :

- Dans la première partie, nous avons examiné le potentiel de deux descripteurs du blé calculés à partir des mesures radar pour suivre la dynamique de la végétation : l'indice normalisé du rapport de polarisation et la cohérence interférométrique. Ces deux variables sont utilisées ultérieurement pour

reconstruire le cycle NDVI du blé en fonction de leurs stades phénologiques. Cette partie a été valorisée par la publication III.

- La deuxième partie se fonde sur une étude de la sensibilité du modèle d'estimation de l'humidité de surface aux variables estimées à partir des données SAR en bande C comme étant des descripteurs de végétation. Cette partie a été valorisée par la publication IV.
- **Le cinquième chapitre : Apport de l'humidité du sol de surface dans le suivi de la variabilité climatique à une échelle régionale**

Ce chapitre repose sur l'analyse spatiotemporelle des produits opérationnels d'humidité de surface élaborés à 5cm de profondeur en fonction de la variabilité des étages bioclimatiques sur les trois quarts du territoire tunisien. Les produits d'humidité sont caractérisés par une résolution spatiale de  $1 \times 1$  Km sur six années depuis 2017 jusqu'à 2022 générés à partir des images Sentinel-1 A et B et Sentinel-2. Ces produits sont comparés avec d'autres produits opérationnels d'humidité du sol.



# *Chapitre I*

---

*Apport de la télédétection radar à la  
caractérisation des états de surface*

---

# Chapitre I

## Apport de la télédétection radar à la caractérisation des états de surface

---

*La modélisation des processus hydrologiques tels que l'infiltration, le ruissellement et l'évapotranspiration requiert des informations précises sur les propriétés du sol précisément à l'état hydrique. Le sol est un milieu poreux dont la géométrie est complexe constituant un siège aux flux des phases fluides et gazeuses et un lieu de développement des êtres vivants. Cette structure se caractérise par une dynamique et une évolution spatiotemporelle complexe et variable. Par conséquent, la détermination des états de surface du sol reste un défi. Dans ce chapitre, nous allons présenter un récapitulatif bibliographique sur les notions et l'importance de la caractérisation des états de surface spécifiquement l'état hydrique et l'apport de la télédétection active dans le domaine des micro-ondes pour déterminer le contenu en eau du sol.*

### I.1. Etats de surface continentale


#### I.1.1. Notions et variables des états de surface

Le besoin de modéliser les processus hydrologiques tels que le ruissellement, l'infiltration et l'érosion des sols se soulèvent de plus en plus avec le changement intensif des occupations de sols dans les milieux agricoles pour répondre à une demande alimentaire croissante. Les changements considérables de la couverture végétale et des propriétés des surfaces des sols induisent une forte demande au suivi des états de surface.

Depuis la fin des années 70, la notion de la caractérisation des états de surface du sol est initiée dans les études des processus hydrologiques comme étant un facteur déterminant dans le comportement des écoulements d'eau dans le sol (Armand et al., 2009 ; Auzet et al., 1995 ; Bhattacharyya et al., 2006 ; Collinet & Valentin, 1979 ; Valentin, 1981) et la gestion des catastrophes naturelles (Papy & Douyer, 1991).

La définition des états de surface de sol était introduite dans les études hydrologiques en zone sahélienne en Afrique conduites par (Casenave & Valentin, 1989). Il s'agit d'une caractérisation d'une ou plusieurs surfaces élémentaires ou bien d'un système de surface élémentaire du sol au sein duquels se déroulent les premières interactions sol-atmosphère. Cette surface élémentaire du sol est un ensemble homogène constitué par le couvert végétal, la surface du sol et les organisations pédologiques superficielles qui sont soumises à l'effet synergétique des facteurs météorologiques, fauniques ou anthropiques (Casenave & Valentin, 1989).

Armand, 2009 a proposé une définition de l'état de surface du sol qui désigne l'état structural comprenant la rugosité, les types de surface du sol, les différentes variables de recouvrement de surface (couvert végétale et pierres), l'état hydrique et micro-topographique des premiers centimètres du sol (**Figure 2**).



**Figure 2.** Les interactions des états de surface du sol et les processus hydrologiques sous l'effet des facteurs climatiques et anthropiques (Arnaud, 2009, modifié).

Les états de surface du sol se caractérisent par une dynamique spatiotemporelle variable en fonction des changements climatiques ou bien des forçages anthropiques suite aux intensifications des systèmes de cultures et des pratiques agricoles.

Plus particulièrement, dans les zones semi-arides et arides du sud du bassin Méditerranéen, la variabilité des états des surfaces du sol est plus accentuée dans le temps et dans l'espace. Généralement, la scène agricole est caractérisée par des exploitations dont les superficies sont

limitées et conduites selon la propre logique des agriculteurs (Ameur et al., 2020). Notamment, les facteurs climatiques sont irréguliers en termes de période de retour, des intensités et de répartition spatiale (Jarlan et al., 2015 ; Schilling et al., 2020 ; Trambly et al., 2020).

Les états de surface du sol peuvent être caractérisés soit par des mesures directes et localisées telles que des mesures des propriétés hydrauliques qui peuvent être menées par des simulations des pluies (Heathman et al., 2003), des disques d'infiltration (Schlüter et al., 2020), etc. La topographie de la surface ou autrement la rugosité est l'un des états de surface qui contribue dans l'érosion, le glissement de terre et le transport solide des matériaux (Jester & Klik, 2005)...

La géométrie de la surface peut être mesurée directement sur le sol en utilisant le rugosimètre à aiguilles ou bien la méthode de la chaînette (Poon & Bhushan, 1995 ; Roose, 1996 ; Saleh, 1997). D'autres techniques peuvent caractériser cette géométrie sans contact telles que la technique de photogrammétrie et les techniques lasers (Shao et al., 2023) ou à partir des produits de télédétection (Zribi et al., 2014).

L'état hydrique des sols est l'un des éléments clés dans les processus hydrologiques, météorologiques et agronomiques. Pour quantifier cette variable d'état de surface, plusieurs travaux dans la littérature ont évalué les méthodes et la fiabilité des mesures du contenu en eau du sol. Dans la sous-section suivante, nous détaillons l'importance de l'état hydrique des surfaces du sol dans les processus naturels et les méthodes de quantification de cette variable.

## I.1.2. Etat hydrique des surfaces continentales

### I.1.2.1. Importance de l'état hydrique dans les processus naturels

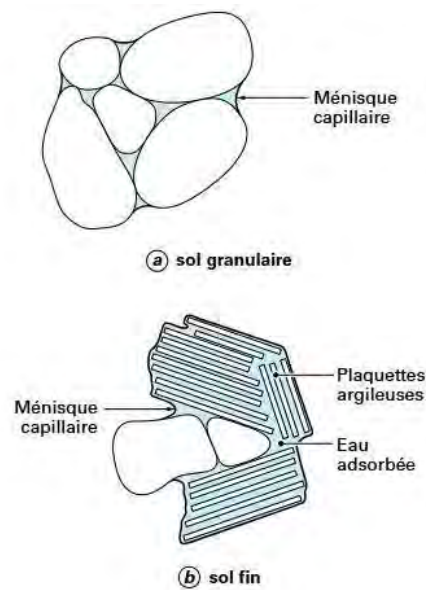
Globalement, les eaux sous forme d'humidité du sol occupent seulement 0.0012% des eaux disponibles sur terres et (Chow et al., 1988). Selon (Childs & Bybordi, 1969), l'humidité du sol est la partie des pores du sol occupée par l'eau. Si l'humidité du sol est égale à la porosité du sol, on parle d'un milieu saturé en eau. Cette porosité est dépendante de la texture et la nature du sol.

D'un point de vue macroscopique, lorsque les molécules d'eau occupent un milieu poreux, elles entrent en contact avec les particules constituant le sol. Dans les zones non saturées, les pores de la surface du sol sont occupés par les deux fluides : l'eau et l'air.

L'eau est soumise aux forces de gravité et de capillarité. Si la texture du sol est fine, les particules d'argile exercent une force d'attraction physico-chimique sur les molécules d'eau. Plus précisément, il s'agit d'une attraction par forces électrostatiques entre les liaisons polarité

des molécules d'eau et les surfaces des particules d'argile. Ces forces électrostatiques diminuent au fur et à mesure que la taille des particules devient plus grossière (**Figure 3**).

Si la texture est grossière, les forces de capillarité entre les particules du sol et la force superficielle du film d'eau qui les entoure diminuent. Dans ce cas, On parle de la notion de rétention d'eau qui désigne le potentiel à retenir l'eau durant une période. La quantité d'eau disponible dans le sol s'affaiblie suite à l'évaporation à partir de la surface du sol dans l'atmosphère ou bien par force de succession exercée par les racines de la couverture végétale.



**Figure 3.** Illustration du phénomène de rétention de l'eau en fonction de la texture du sol : (a) sol granulaire et (b) sol à texture fine (Delage, 2000).

Les conditions météorologiques (l'humidité et la température de l'air, le rayonnement solaire qui fournit l'énergie nécessaire pour la vaporisation de l'eau) et l'état hydrique de la végétation gouvernent les phénomènes d'évaporation et l'évapotranspiration. Ces phénomènes diminuent la quantité des eaux infiltrées à la surface et introduit la vapeur d'eau dans l'atmosphère. En contrepartie, la présence de la végétation s'oppose aux flux d'écoulement superficiels et favorise une direction préférentielle de percolation dans les pores créées par les racines des plantes. Cette dynamique des flux de l'humidité dans les pores des sols en fonction des processus thermodynamiques induit des changements majeurs dans le cycle d'eau (D. Entekhabi et al., 1996). Il s'agit d'une variable primaire qui contrôle l'eau des surfaces, la balance énergétique et le bilan de carbone (Dong et al., 2023).

Après l'introduction des quantités d'eau évaporées dans l'atmosphère, grâce au phénomène de convection, les nuages se condensent. Dans ce cas, on parle du flux turbulent d'énergie qui contribue par son équivalent énergétique au bilan énergétique de la surface. Les nuages participent à la déviation d'une partie de l'énergie solaire et se transforment ultérieurement en précipitations.

Les eaux de pluies alimentent la surface du sol en eau et qui s'ajoutent aux eaux d'irrigation dans les milieux agricoles. Une partie des eaux disponibles dans les surfaces des sols sont extraites par la végétation en dissipant l'énergie emmagasinée dans son appareil végétatif issu de l'énergie solaire pour transformer les molécules d'eau et le CO<sub>2</sub> en matière organique et en oxygène O<sub>2</sub> par photosynthèse. Cette partie du dioxyde de carbone fixé par la végétation comme étant une production primaire brute constitue des flux entrants au bilan de carbone quantifiant les échanges nets des flux de CO<sub>2</sub> entre l'écosystème et l'atmosphère. L'efficacité de ce bilan est étroitement liée au bilan hydrique et thermique résultant des échanges de l'eau et d'énergie entre l'atmosphère et les deux interfaces : sol et végétation.

Dans cette optique, l'estimation de l'humidité du sol constitue un élément majeur dans la compréhension des différents processus naturels. Dans la partie suivante du chapitre, nous allons détailler les méthodes de mesure de l'état hydrique de la surface du sol.

#### I.1.2.2. Méthodes de mesure de l'état hydrique

L'humidité de la surface du sol est une variable d'état de surface dépendante des différents paramètres du sol comme la structure matricielle, la composition minéralogique, la présence de la matière organique, la salinité et la température ambiante (Robinson et al., 2008 ; Susha Lekshmi et al., 2014). La combinaison de ses propriétés sous l'effet des conditions climatiques et topographiques induit une variabilité spatiotemporelle importante du contenu en eau du sol. Les mesures d'humidité principalement se font par deux méthodes : des mesures in-situ en contact avec le sol ou bien des mesures sans contact avec le sol (Susha Lekshmi et al., 2014 ; Vereecken et al., 2008).

##### a. Mesures directes

La première famille des méthodes inclut plusieurs techniques telles que la thermogravimétrie, la diffusion des neutrons (sonde à neutrons), les mesures de résistivité du sol et la technique diélectrique englobant les mesures par réflectométrie temporelle (TDR) et fréquentielle (FDR)

ou bien par capacitance (Bell et al., 1987 ; Dean et al., 1987 ; Robinson et al., 2008 ; Walker et al., 2004).

- Mesures thermogravimétriques


Cette technique est largement utilisée pour déterminer le contenu en eau du sol. Elle est classée comme étant une méthode standard et référence (Susha Lekshmi et al., 2014). Son principe consiste à prélever un échantillon du sol considéré en état humide et le peser ( $\theta_H$ ). Ensuite, cet échantillon qui ne dépasse pas les 100 grammes généralement, est mis à l'étuve pour le séchage à une température entre 100°C et 110°C (Bell et al., 1987 ; Reynolds, 1970 ; Zazueta & Xin, 1994). Cette température est inférieure à 70°C pour les sols organiques et gypseux afin d'éviter la volatilité de la matière organique (Robinson et al., 2008 ; Susha Lekshmi et al., 2014). Après 24 heures, le sol prélevé est repesé et le nouveau poids après séchage est marqué ( $\theta_S$ ). Par la suite, l'humidité du sol pondérale  $M_p$  (%) est calculée selon la formule suivante :

$$M_p(\%) = \frac{\theta_H - \theta_S}{\theta_S} \times 100 \quad (1)$$

La teneur en eau volumétrique est le produit de l'humidité pondérale et la densité apparente. Bien que la méthode gravimétrique soit couramment utilisée, elle reste destructive et consommatrice d'effort et de temps. Il faut attendre 24 heures pour avoir les résultats. De plus, une fois l'échantillon est prélevé dans un point, le suivi de l'évolution temporelle de l'humidité du sol de ce même point est irréalisable puisque le sol est déjà détruit (Zazueta & Xin, 1994).

- Mesures par ThetaProbe

Les ThetaProbes sont des sondes de réflectométrie fréquentielle qui opèrent à des fréquences entre 10 et 150 MHz en fonction des constantes diélectriques d'une manière instantanée (Susha Lekshmi et al., 2014). Le principe de fonctionnement des ThetaProbes a été introduit par (Gaskin & Miller, 1996) sous le nom des sondes MLURI d'humidité (**Figure 4**). Ils ont conçu un instrument composé d'une ligne de transmission d'un signal dont la fréquence est constante (100 MHz) à un réseau de quatre aiguilles. Ce dernier englobe trois aiguilles à une impédance constante qui entourent une aiguille centrale. L'aiguille centrale est reliée à un système de transmission supplémentaire. Son impédance est dépendante des propriétés diélectriques du sol dans lequel elle est insérée (Gaskin & Miller, 1996 ; Matula et al., 2016 ; Robinson et al., 2008).



**Figure 4.** Illustration d'une ThetaProbe composée du corps, la ligne de transmission et du réseau des aiguilles (Gaskin & Miller, 1996).

Grâce à cette différence d'impédance et selon le rapport de (Miller & Gaskin, 1999), le contenu en eau du sol est exprimé comme suit :

$$M_v = (\sqrt{\varepsilon} - a_0)/a_1 \quad (2)$$

Avec  $\varepsilon$  est la constante diélectrique apparente et  $a_0$  et  $a_1$  des constantes dépendantes des types du sol à calibrer. Pour les sols minéraux, les coefficients  $a_0$  et  $a_1$  sont égaux à 1.6 et 8.4, respectivement. Pour les sols organiques, les coefficients sont de l'ordre de 1.3 et 7.7, respectivement. L'erreur pour une calibration générale est estimée à  $\pm 5$  vol.%. La calibration spécifique du Thetaprobe réduit cette erreur à une valeur de  $\pm 2$  vol.%.

Une première approximation linéaire a été établie (Miller & Gaskin, 1999), pour calculer la racine carrée de la constante  $\varepsilon$  :  $\sqrt{\varepsilon} = 4.4 \times V + 1.1$  avec  $V$  est la valeur mesurée par la Thetaprobe en Volt. La ThetaProbe peut être installée d'une manière permanente, en étant insérée au même emplacement pour surveiller la dynamique temporelle de l'humidité du sol, contrairement aux mesures destructives. (Bretreger et al., 2022 ; Robinson et al., 1999).


Pour couvrir la variabilité spatiotemporelle des observations d'humidité de sol, depuis 2009, le réseau des mesures d'humidité du sol intitulé International Soil Moisture Network (ISMN) est financé par l'agence européenne de l'espace (ESA) pour fédérer les mesures d'humidité du sol à des différentes profondeurs des différentes stations dans le monde. Avec 71 réseaux comprenant 2842 stations depuis juillet 2021 (**Figure 5**), ce méta-réseau (<https://ismn.earth/en/>) offre à la communauté des données d'humidité du sol harmonisées avec des bases de données supplémentaires des classes climatiques selon Koppen–Geiger, l'occupation du sol et les caractéristiques des sols et des variables météorologiques (Dorigo et al., 2021 ; Dorigo et al., 2011).





En partant de ce principe, il s'agit d'une source d'énergie qui émet un rayonnement électromagnétique pour observer une scène composée des objets. Ces objets vont renvoyer une partie de l'énergie incidente ou bien émettre sa propre énergie pour être mesurer au niveau du capteur. La source d'énergie peut être naturelle (soleil ou la surface de la terre) ou artificielle.

Nous pouvons faire la différence entre deux domaines de télédétection : le domaine passif et le domaine actif (**Figure 6**). Dans le domaine passif où la source du rayonnement est naturelle, l'état hydrique est déterminé par trois méthodes en fonction de la longueur d'onde ( $\lambda$ ) : le domaine optique qui englobe à son tour le visible ( $\lambda$  entre 0.4 et 0.7  $\mu\text{m}$ ), le proche-infrarouge et le moyen infrarouge ( $\lambda$  entre 0.7 et 2.6  $\mu\text{m}$ ), le domaine d'infrarouge thermique ( $\lambda$  entre 3 et 5  $\mu\text{m}$  et entre 8 et 14  $\mu\text{m}$ ) et le domaine passif des hyperfréquences (notamment les micro-ondes où  $\lambda$  entre 0.1 et 10 cm). Dans le domaine actif des micro-ondes, la source d'énergie est artificielle.



**Figure 6.** Les parties principales du spectre électromagnétique (Girard & Girard, 2010).

- Mesures d'humidité dans le domaine optique

Dans le domaine optique, le rayonnement émis par le soleil est renvoyé partiellement par l'objet illuminé dans la direction du capteur également nommé le radiomètre. Le rapport entre les deux rayonnements réfléchi et émis, désigne la réflectance qui est la capacité d'un objet à réfléchir les rayonnements émis par le soleil (Nicodemus et al., 1977). Cette grandeur est intimement liée à la nature, l'état physique et la structure des objets illuminés. Pour suivre la dynamique et estimer les humidités du sol, plusieurs travaux sont basés sur la sensibilité de la réflectance au contenu en eau du sol dans des différentes bandes de l'optique (Gao et al., 2013).

Selon des équations mathématiques, des indices spectraux étaient calculés pour suivre la dynamique et l'étendue spatiale du contenu en eau du sol. L'indice normalisé des différences d'eau « Normalized Difference Water Index NDWI » est introduit avec (McFeeters, 1996) en fonction de la réflectance des bandes en vert et en proche-infrarouge. Les valeurs positives, entre 0 et 1 de cet indice, caractérisent les plans d'eau.

Xiao et al., (2002) ont initié l'indice Land Surface Water Index (LSWI). Il est calculé en fonction des données en bande proche-infrarouge et l'infrarouge thermique. L'indice MNDWI est une version modifiée du NDWI. Il est introduit par (Singh et al., 2014) et qui a permis de délimiter les zones des plans d'eau et les zones de mixage entre eau et végétation. Cet indice est calculé en fonction des réflectances.

Sadeghi et al., (2015) ont implémenté un modèle physique pour estimer les humidités de sol en surface tout en considérant la réflectance de Fresnel. En comparant les humidités estimées et les valeurs issus sous des conditions maîtrisées dans le laboratoire, l'erreur quadratique moyenne varie entre 0.005 et 0.07 m<sup>3</sup>/m<sup>3</sup>.

L'utilisation du modèle Red-NIR proposé par Gao et al., 2013a facilité l'estimation et la cartographie à une échelle régionale les humidités du sol en utilisant la réflectance des pixels mixtes en bandes rouge et proche infrarouge. L'approche proposée est testée sur deux sites en Chine et en Amérique avec un minimum de coefficient de corrélation de 0.84 et une erreur relative moyenne d'environ 0.18 pour le site en Chine (Gao et al., 2013)

- Mesures d'humidité dans le domaine d'infrarouge thermique

Dans le domaine de l'infrarouge thermique, l'énergie est émise à la surface pour tout corps possédant une température supérieure à zéro absolu. Cette émission est provoquée par des mouvements des particules constituant l'objet. Cette agitation est en relation avec la

température de surface des objets (Land Surface Temperature LST). Selon la loi de Wien, pour la surface de la terre qui se caractérise par une température 273 K, le maximum de l'émission est situé autour de 10.5  $\mu\text{m}$  appartenant à la gamme de l'infrarouge thermique.

Les travaux de (Zhao et al., 2013) ont proposé un modèle multilinéaire modifié pour estimer l'humidité du sol avec une racine de l'erreur quadratique moyenne (RMSE) égale à 0.03  $\text{m}^3/\text{m}^3$ . Les mesures LST ont été associées avec l'indice de végétation NDVI dans un même espace pour extraire la température minimale et maximale qui coïncide avec les conditions les plus sèches et les plus humides, respectivement. En tirant profit de cette relation, Carlson, (2007) a utilisé le modèle de triangle pour tracer les isoplèthes d'humidité surfacique.

Les travaux de (Sadeghi et al., 2015) ont proposé une nouvelle approche qui se base sur le modèle du trapézoïde optique (OPTRAM) en fonction des deux indices NDVI et « SWIR Transformed Reflectance (STR) ». Ce dernier se calcule à partir de la réflectance dans la bande d'infrarouge moyen. Les estimations d'humidité du sol se caractérisent par des valeurs RMSE inférieures à 0.05  $\text{m}^3/\text{m}^3$ .

Les travaux de (Leng et al., 2016) ont combiné les données optiques et thermiques pour estimer le contenu en eau du sol à partir de la modélisation de la relation elliptique entre les cycles diurnes de LST et de l'émission nette de la surface aux courtes longueurs d'onde. Après validation sur trois sites, l'estimation des humidités de surface se caractérise par une valeur moyenne RMSE à l'environ de 0.042  $\text{m}^3/\text{m}^3$ .

Bien que l'utilisation des données dans le domaine optique et thermique soit un outil satisfaisant pour estimer les humidités du sol, les approches développées restent en forte dépendance de la disponibilité des données. D'une part, la présence des nuages contamine les pixels et rendent les images inexploitable. D'autre part, les acquisitions en nuit ne sont pas faisables ce qui limite les données. De plus, l'onde électromagnétique émise ne peut pas pénétrer que de quelques millimètres dans le sol (Babaeian et al., 2019 ; Petropoulos et al., 2015). Alternativement, les produits d'humidité dans le domaine des microondes sont utilisés pour remédier aux limites précédemment citées.

- Mesures d'humidité dans le domaine des micro-ondes

Les travaux d'estimation de l'humidité du sol à partir des images satellites acquises dans le domaine des micro-ondes sont beaucoup plus développés d'un jour à l'autre surtout avec l'émergence de plusieurs produits opérationnels dans les domaines des hyperfréquences

passives et actives (de Jeu & Dorigo, 2016 ; Engman & Chauhan, 1995 ; Owe et al., 1988 ; Prigent et al., 2005 ; Sun et al., 2022).

Dans le domaine passif des micro-ondes, le signal mesuré par les radiomètres hyperfréquences à basse fréquence ( $f < 10$  GHz) est linéairement dépendant de la température de Brillance  $T_B$  et indépendant de la couverture nuageuse et des pluies. Cette température dépend à son tour de l'émissivité et la température physique des émetteurs. L'émissivité est une grandeur qui caractérise la capacité d'un objet naturelle pour transformer l'énergie thermique en énergie électromagnétique par rapport à la capacité de référence d'un corps noir. Dans des milieux agricoles, la température de brillance  $T_B$  est sensible aux effets de la température du sol et de la végétation (Lili Chabaane, 1993 ; Wagner, Blöschl, et al., 2007).

Afin d'estimer les humidités du sol, la simulation de la température de brillance de l'émissivité en fonction des états de surface est une étape primordiale. Il existe principalement deux familles de modèles : la famille des modèles physiques qui se fonde sur des descriptions précises du sol et de végétation et la famille des modèles semi-empiriques qui se base sur des équations simplifiées du transfert radiatif. Bien que l'utilisation des modèles semi-empiriques soit plus simple, elle est limitée par l'ajustement des paramètres qui sont sensibles aux effets de la végétation. Une fois que le modèle est validé, une étape d'inversion sera établie dans le but d'estimer les humidités. Le modèle Tau-Omega développé par (Mo et al., 1982) est souvent utilisé pour estimer l'état hydrique dans le domaine passif des micro-ondes (Babaeian et al., 2019).

Pour la basse fréquence ( $f = 1.4$  GHz), on a principalement deux missions qui délivrent des produits d'humidité : Soil Moisture and Ocean Salinity (SMOS) et Soil Moisture Active and Passive (SMAP). Dans le but de suivre l'humidité du sol et la salinité des surfaces des océans, la mission SMOS s'est lancée depuis 2009. Grâce à cette mission, des produits d'humidité de la surface du sol sont disponibles depuis 2010 jusqu'à présent à une échelle globale en moyenne chaque deux jours avec une résolution spatiale moyenne de 43 Km à une large gamme d'angles d'incidence allant 0 à 60°. Cette mission vise une erreur d'estimation des humidités du sol à l'environ de 0.04 m<sup>3</sup>/m<sup>3</sup> (Kerr et al., 2001, 2010, 2016 ; Wigneron et al., 2017).


Depuis 2015, la mission SMAP développée par la NASA, fournit des produits d'humidité du sol à une échelle globale avec un angle d'incidence constant de 40° issu de son radiomètre dont la résolution spatiale est approximativement 40 Km et la résolution temporelle varie entre 1 et 3 jours. L'estimation de l'humidité du sol à une profondeur de 5cm et le contenu d'eau de la

végétation constitue l'un des objectifs de la mission dont l'erreur ne dépasse pas en valeur absolue  $0.04 \text{ m}^3/\text{m}^3$  et inférieure à  $5 \text{ Kg.m}^{-2}$ , respectivement (Chan et al., 2016, 2018 ; Colliander et al., 2017 ; D. Entekhabi et al., 2010).

Les produits d'humidité des radiomètres avancés (Advanced Microwave Scanning Radiometer 2: AMSR-2) sont générés quotidiennement depuis 2013. Ils couvrent une large gamme de fréquences allant de 6,9 GHz à 89 GHz, avec un angle d'incidence de  $55^\circ$ . Cette variabilité des fréquences induit une variabilité des résolutions spatiales entre 15 Km et 2170 Km (Petropoulos et al., 2015). Les produits sont distribués par « Japan Aerospace Exploitation Agenc (JAXA) ». Il s'agit d'un successeur du AMSR-E, le premier fournisseur des produits d'humidité à une échelle globale depuis 2002 jusqu'à 2011. La résolution temporelle des produits AMSR-2 est estimée de 1 à 2 jours (Babaeian et al., 2019 ; Parinussa et al., 2015 ; Yao et al., 2021).

Dans le domaine actif de la télédétection, la source d'énergie est artificielle émettant les ondes électromagnétiques (plus de détails sur la technique radar dans la partie suivante). En bande C ( $f = 5.255 \text{ GHz}$ ), Le diffusiomètre avancé (Advanced Scatterometer CAT) embarqué sur la plateforme météorologique opérationnelle (MetOp) fournit des produits opérationnels d'humidité dans le domaine des hyperfréquence active (Bartalis et al., 2007 ; Bentamy & Fillon, 2012 ; Figa-Saldaña et al., 2002). Ces produits se caractérisent par une résolution spatiale entre 12.5 Km et 25 Km disponible chaque trois jours avec une erreur d'estimation entre 0.03 et 0.07  $\text{m}^3/\text{m}^3$  (Petropoulos et al., 2015).

La gestion optimisée du secteur agricole commence d'une échelle spatiale fine au niveau des parcelles vers une échelle plus large surtout dans un contexte d'hétérogénéité du milieu agricole (Peng et al., 2021 ; Weiss et al., 2020). Dans cette optique, la situation tire au clair un compromis entre une résolution spatiale fine et une haute répétitivité temporelle (**Figure 7**). Pour remédier ce problème, des travaux sont focalisés sur l'amélioration de la résolution grossière des produits d'humidité de quelques dizaines de kilomètres à une résolution spatiale plus fine en utilisant des données satellites de résolution spatiales de quelques mètres d'où la notion de désagrégation. Il existe plusieurs approches développées dans ce sens qui sont en détails dans la revue de (Peng et al., 2017). Les produits d'humidité à échelle grossière peuvent être désagrégés à l'aide des données optiques (Piles et al., 2011), thermiques (Malbêteau et al., 2016 ; Merlin et al., 2013) et radar (Entekhabi et al., 2014)



**Figure 7.** Les exigences des résolutions temporelle et spatiale des produits d’humidité du sol en fonction des applications : Climatologie, la prévision numérique de la météo (NWP), Hydrologie, gestion des risques, agriculture, foresterie (Peng et al., 2021).

La technique GNSS-R (Global Navigation Satellite System-Reflectometry) constitue un outil innovant dans le domaine des micro-ondes qui permet de mesurer l’humidité du sol. Cette technique se base sur la réception des signaux électromagnétiques émises des satellites GNSS (GPS, GLONASS, BDS et Galileo) en mesurant la réflectométrie des surfaces naturelles avec des mesures radar multistatiques. Elle a prouvé sa pertinence dans la caractérisation des états de surface dans les milieux agricoles (Edokossi et al., 2020 ; Roussel et al., 2016 ; S. Zhang et al., 2017, 2018). Par exemple, les acquisitions validées de l’instrument GLORI aéroporté opérant en bande L (Motte et al., 2016), ont montré leur potentiel dans des différentes applications dans des contextes agronomiques telles que l’estimation des humidités du sol (Zribi et al., 2022, 2023) et la caractérisation de la végétation (Zribi et al., 2018).

Bien que les produits désagrégés aient prouvé leur pertinence dans plusieurs applications à une échelle régional et globale (Sabaghy et al., 2020) ainsi que les produits de la technique GNSS-R (Edokossi et al., 2020 ; Motte et al., 2016), la gestion du secteur agricole demande une information plus fine (Weiss et al., 2020). Ce but a pris un essor considérable avec la disponibilité des données radar du type Radar à Ouverture de Synthèse avec une résolution spatiale de 10 m et une fréquence de revisite de 6 jours avec les acquisitions du satellite Sentinel-1.


Dans la section suivante du manuscrit, nous allons présenter des généralités sur la technique radar et détailler les raisons qui les placent comme étant un outil efficace et recommandé pour le suivi de l'état hydrique de surface.

## I.2. Suivi des états de surface en utilisant la télédétection radar

### I.2.1. Principe d'acquisition des images radar

La technique RADAR (RADIo Detection And Ranging) consiste à l'émission d'une onde électromagnétique par un capteur pour illuminer une scène dans une configuration choisie (fréquence, polarisation et angle d'incidence).

Cette onde se propage dans l'espace dans un plan perpendiculaire à sa trajectoire, faiblement impactée par les conditions d'atmosphère, jusqu'à atteindre la cible. Le diffuseur illuminé interagit avec le rayonnement électromagnétique. Par conséquent, une partie de cette énergie est renvoyée dans la direction d'observation du capteur ce qui désigne l'énergie rétrodiffusée (**Figure 8**). A partir du recueil des échos sous forme d'énergie rétrodiffusée dans la même direction des impulsions émises, une image bidimensionnelle est construite (Polidori, 1996).



**Figure 8.** Principe d'acquisition d'imagerie radar en émettant des impulsions par le capteur radar et la mesure des échos dans la direction de sa vision (Talla Tankam et al., 2010).

### I.2.2. Géométrie des acquisitions des radar à ouverture de synthèse


Le radar acquiert les images en deux dimensions : en distance qui désigne la direction de propagation des ondes électromagnétiques et en azimut qui représente la direction du mouvement en translation de l'antenne (Polidori, 1996). L'intersection des deux directions définit les coordonnées des pixels de l'image tout au long de la longueur de la fauchée pour construire finalement une matrice décomposée d'une série de lignes et de colonnes, également



l'image radar. La résolution spatiale, dans ce cas de figure, est définie en deux directions : une résolution longitudinale ou azimutale et une résolution transversale ou en distance (**Figure 9**). La résolution longitudinale ( $Res_{azimutale}$ ) est calculée en fonction de la distance antenne-cible observée ( $R$ ), la longueur d'onde ( $\lambda$ ) et la longueur de l'antenne ( $L$ ) comme suit :

$$Res_{azimutale} = R \frac{\lambda}{L} = \frac{H}{\cos \theta} \frac{\lambda}{L} \quad (3)$$

Avec  $\theta$  est l'angle d'incidence et  $H$  la hauteur antenne-Nadir.



**Figure 9.** Géométrie des scènes observées lors de l'acquisition des images radar aéroportées en illustrant les deux directions de résolution spatiale (transversale et longitudinale) (<https://streaming.ensg.eu/teledetection/>).


Le radar émet des impulsions et reçoit ultérieurement des impulsions à partir des cibles observées. Pour séparer deux impulsions, il faut que la différence de temps séparant l'arrivée de ces deux impulsions soit supérieure à la durée de l'impulsion ( $\Delta T$ ). De ce principe découle l'expression de la résolution en distance ( $Res_{distance}$ ) et au niveau du sol ( $Res_{distance-sol}$ ) :

$$Res_{distance} = c \frac{\Delta T}{2} \quad (4)$$

$$Res_{distance-sol} = c \frac{\Delta T}{2 \sin \theta} \quad (5)$$

Afin d'améliorer la résolution azimutale des images radar, l'augmentation de la longueur de l'antenne peut être une solution : plus on augmente  $L$ , plus la résolution azimutale sera plus fine. Sur le plan réel, la conception d'une antenne dont la largeur est à l'ordre de quelques dizaines de Kilomètres pour avoir une résolution de quelques mètres, est irréalisable. Les scientifiques sont parties de cette hypothèse mais ils ont substitué longueur kilométrique de l'antenne par une simulation d'une longueur virtuelle. C'est la technique des radars à synthèse

d'ouverture RSO (en anglais Synthetic Aperture Radar SAR). Son principe consiste à simuler une antenne de grande taille afin d'améliorer sa résolution (**Figure 10**). En changeant la position du radar au long de sa trajectoire, la même cible appartenant au faisceau est observée plusieurs fois. Dès que la cible observée quitte le champ du faisceau, la nouvelle longueur de l'antenne est déterminée. La résolution dans la direction transversale ou en distance est la même que celle des radars à ouverture réelle.



**Figure 10.** Principe de la technique des radars à synthèse d'ouverture (Maitre, 2001).

### I.2.3. Mesures des capteurs SAR

Pour décrire la fraction de la quantité d'énergie rétrodiffusée par rapport à l'énergie incidente émise par le capteur, un coefficient de rétrodiffusion est défini et noté ( $\sigma^0$ ). Cette fraction est exprimée en linéaire également naturelle ( $m^2 \cdot m^{-2}$ ). Pour mieux visualiser la variation de ce coefficient, cette grandeur peut être convertie en Décibel selon l'équation suivante :

$$\sigma_{dB}^0 = 10 * \log_{10}(\sigma_{naturel}^0) \quad (6)$$

Selon Zribi et al., 1998, la relation entre les puissances rétrodiffusée et émise est illustrée par l'équation radar suivante :

$$P_r = \iint P_e G_e \sigma_{naturel}^0 \frac{\lambda^2}{(4\pi)^3 R^4} G_r ds \quad (7)$$

Avec  $\sigma_{dB}^0$  : coefficient de rétrodiffusion en (dB),  $\sigma_{naturel}^0$  : coefficient de rétrodiffusion en valeur naturelle ( $m^2/m^2$ ),  $P_r$ ,  $P_e$  : Puissances rétrodiffusée moyennée sur toutes les contributions de la zone illuminée et émise par le capteur, respectivement,  $\lambda$  : longueur d'onde,  $R$  : distance entre l'antenne et la cible et  $G_e$ ,  $G_r$  : Gains de l'instrument d'émission et de réception. D'après cette équation, nous pouvons constater que la mesure radar dépend à la fois

des caractéristiques de l'onde incidente (polarisation, angle d'incidence et fréquence) et des caractéristiques diélectriques (contenu en eau, texture) et géométriques (structure et rugosité) de la cible observée (Ulaby, 1975).

## I.2.4. Sensibilité du signal radar

### I.2.4.1. Caractéristiques physiques du capteur


#### a. Fréquence

Appartenant au domaine des micro-ondes, les ondes électromagnétiques se propagent dans l'espace à une fréquence ( $f$ ) en fonction de la longueur d'onde ( $\lambda$ ). Les deux grandeurs sont inversement proportionnelles ( $f = c / \lambda$  avec  $c$  est la célérité de la lumière) classées par bande (**Tableau 1**).

**Tableau 1.** Plages de fréquence et de longueurs d'onde du signal radar

	Fréquence (GHz)	Longueur d'onde (cm)
Bande P	0.3 – 1	30 – 100
Bande L	1 – 2	15 -30
Bande S	2 – 4	7.5 – 15
Bande C	4 – 8	3.75 – 7.5
Bande X	8 – 12	2.5 – 3.75
Bande Ku	12 – 18	1.67 – 2.5
Bande K	18 – 26.5	1.13 – 1.67
Bande Ka	26.5 - 40	0.75 – 1.13

Les capteurs radars s'opèrent à des longueurs d'onde centimétriques. Cet intervalle de  $\lambda$  constitue une fenêtre atmosphérique donc le signal est faiblement influencé par les conditions climatiques. La **Figure 11** illustre deux images acquises dans le même jour avec un satellite opérant dans le domaine optique (Sentinel-2) et un satellite radar en bande L (ALOS-2) dans la région du barrage El Haouareb au centre de la Tunisie. La présence des nuages a détérioré la qualité de la première image sans avoir influencé la seconde.



(a)

(b)

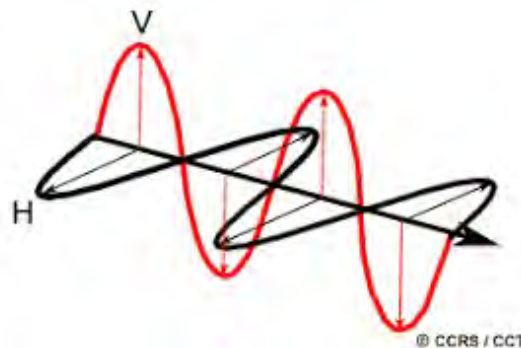
**Figure 11.** (a) Image optique Sentinel-2 avec une résolution  $10 \times 10$  m avec une Couverture nuageuse 64% (b) Image radar ALOS-2 en bande L, Polarisation HH dont la taille des pixels est  $6 \times 6$  m.

### b. Polarisation

Les ondes électromagnétiques sont composées des deux champs électrique et magnétique orthogonaux. L'orientation du champ électrique par rapport au plan de propagation définit la polarisation. Pour la polarisation linéaire (**Figure 12**), nous avons deux directions soit Verticale (V) ou bien Horizontale (H). Ils existent quatre combinaisons possibles de polarisation divisées en deux classes :

- Combinaison parallèle également co-polarisation si les polarisations sont les mêmes à l'émission et la réception : Horizontale- Horizontale (HH) ou Verticale-Verticale (VV).
- Combinaison croisée également cross-polarisation si les polarisations sont différentes à l'émission et à la réception : Horizontale- Verticale (HV), Verticale - Horizontale (VH)


Cette polarisation constitue un paramètre important dans l'interprétation du comportement de la rétrodiffusion des objets (van Zyl et al., 1987).



**Figure 12.** Direction de vibration du champ électrique : Horizontale (H) ou Verticale (V) (Centre Canadien de télédétection : CCRS, <http://www.ccrs.nrcan.gc.ca> ).

### c. Angle d'incidence


L'angle d'incidence est l'angle entre le faisceau du radar et la normale à la surface du sol (**Figure 13**). L'angle d'incidence constitue l'un des paramètres qui influence les coefficients de rétrodiffusion : la rétrodiffusion diminue lorsque l'angle d'incidence augmente (Chanzy, 1993 ; Ulaby et al., 1986).



**Figure 13.** Illustration de l'angle d'incidence (Girard et Girard, 2010).

#### I.2.4.2. Propriétés des cibles illuminées

Les coefficients de rétrodiffusion ( $\sigma^0$ ) sont gouvernés par la configuration du capteur radar incluant la fréquence ( $f$ ), la polarisation et l'angle d'incidence ( $\theta$ ) et les propriétés des cibles observées. La rétrodiffusion d'un sol couvert est la somme de trois contributions (**Figure 14**) : la contribution de la végétation, la contribution du sol nu et la contribution des interactions sol-végétation (Attema & Ulaby, 1978 ; Dobson & Ulaby, 1986).




**Figure 14.** Différents types de contribution dans la rétrodiffusion du signal radar dans des sols couverts (Chahbi, 2015).

Dans les milieux agricoles, les propriétés du sol couvert influencent le processus de rétrodiffusion dans les sols couverts. Ces propriétés englobent (Chanzy, 1993 ; Dobson & Ulaby, 1986 ; Ulaby, 1975 ; Ulaby et al., 1982, 1990):

- Les propriétés propres à la végétation telle que la structure qui est caractérisée par la rugosité, la densité, la hauteur et l'orientation de la végétation ainsi que la quantité et la distribution du contenu en eau des plantes verticalement (en hauteur) et dans les organes de la végétation (tige, feuilles, fruits...)
- Les propriétés du sol nu en termes de rugosité et des propriétés diélectriques (Contenu en eau, texture, salinité et température)

La constante diélectrique ( $\epsilon$ ) constitue le lien entre les mesures d'état hydrique du sol et les coefficients de rétrodiffusion du signal radar exprimée en nombre complexe ( $\epsilon = \epsilon' - j \epsilon''$ ) avec  $\epsilon'$  : la partie réelle et  $\epsilon''$  : la partie imaginaire. Cette constante est liée à la densité du sol, sa texture (**Figure 15**), sa composition minéralogique, sa porosité et la présence des pierres à la surface (Hallikainen et al., 1985 ; Ulaby et al., 1982).



**Figure 15.** Sensibilité de la constante diélectrique et le contenu en eau du sol en fonction de la texture du sol et la fréquence de l'onde (Hallikainen et al., 1985).

La constante diélectrique contribue dans la profondeur de pénétration de l'onde électromagnétique dans le sol avec la relation suivante :

$$\delta_p \approx \frac{\lambda \sqrt{\epsilon'}}{2 \pi \sqrt{\epsilon''}} \quad (8)$$

En se basant sur cette approximation, à une humidité constante, on peut conclure que la profondeur de pénétration des ondes émises par le capteur radar augmente en fonction de l'augmentation de la longueur d'onde. Autrement, la profondeur  $\delta_p$  en bande L est plus importante que celle en bande C et inférieure de celle en bande P.


La description de la rugosité du sol, dans la littérature, se réalise par des différents paramètres statistiques calculés sur un profil de rugosité tels que la hauteur moyenne arithmétique des aspérités, la hauteur maximale entre les pics et les vallées du profil, l'écart type des hauteurs (Hrms) et de la longueur de corrélation (Lc) (Gadelmawla et al., 2002).

Le descripteur Hrms, également la hauteur quadratique moyenne, renseigne sur de la variation des irrégularités au niveau de la surface du sol sur un profil observé. Le paramètre statistique Lc précise la distance à partir de laquelle les hauteurs des points du profil de rugosité sont indépendants statistiquement les uns des autres. Autrement, plus la surface est rugueuse, plus les points sont corrélés ceci induit des valeurs plus élevées de Lc. En fonction des paramètres précédemment cités, d'autres indices sont développés tels que  $Zs = Hrms^2/Lc$  (Zribi & Dechambre, 2003) et  $Zg$  (Zribi et al., 2014).

La rugosité du sol est un facteur déterminant dans la détermination de la direction de distribution des ondes électromagnétiques incidentes. Ce contrôle est en fonction du critère de Rayleigh qui se calcule en fonction de la longueur d'onde émise ( $\lambda$ ) et l'angle d'incidence ( $\theta$ ) :

$$(\theta) : \frac{\lambda}{8 \times \cos(\theta)}$$

Si la hauteur des aspérités de la surface est supérieure à ce critère, la surface est considérée rugueuse. Ainsi, la diffusion de l'onde incidente dans le sens d'illumination augmente et la réflexion diffuse est favorisée ce qui induit une augmentation dans les coefficients de rétrodiffusion (**Figure 16**). Dans le cas contraire, la diffusion des ondes incidentes à travers des surfaces lisses se fait dans une direction contraire au sens d'observation du capteur radar. Il s'agit d'une réflexion spéculaire faisant référence à l'effet miroir. Lorsque la longueur de l'onde permet la pénétration du signal dans un volume, les éléments constituant le volume rétrodiffusent les ondes émises. Dans ce cas, il s'agit d'une réflexion en volume qui caractérise le comportement des micro-ondes face aux canopées de végétation. Les travaux de (Ulaby & Jedlicka, 1984) ont analysé les propriétés diélectriques du volume des plantes.



**Figure 16.** Comportement du signal radar (valeur des coefficients de rétrodiffusion) en fonction de la rugosité des surfaces (Schumann et al., 2012).

### I.2.5. Modélisation du signal radar à travers les scènes agricoles

Dans le but de simuler le comportement du signal radar à travers les milieux agricoles, plusieurs approches ont été établies pour discerner la variation des coefficients de rétrodiffusion face à une variabilité des propriétés de la cible observée (sol nu ou couvert) et des configurations du capteur SAR. Après l'évaluation statistique de la performance des modèles en comparant les coefficients de rétrodiffusion simulés et mesurés par le capteur, nous pouvons estimer les états de surface en inversant les modèles validés. Autrement, le modèle inverse s'alimente des coefficients mesurés par le radar pour estimer en sortie les variables caractéristiques du sol en citant l'exemple de la rugosité, l'humidité et même les variables caractéristiques de la végétation comme l'indice foliaire et la hauteur des plantes. Pour cette partie, nous avons présenté les modèles utilisés en fonction de l'absence ou la présence de la végétation.

#### I.2.5.1. Sol Nu

La simulation de l'interaction des ondes électromagnétiques émises par le radar et le sol nu est sensible aux paramètres du capteur et aux propriétés du sol (rugosité et constante diélectriques). Dans ce contexte, plusieurs efforts sont investis pour établir des approches et construire des modèles qui considèrent cette sensibilité. Les modèles peuvent être des modèles physiques, empiriques et semi-empiriques (Choker et al., 2017).



### a. Modèles physiques

Ces modèles se basent sur des principes physiques pour simuler les interactions onde-sol nu. Nous pouvons citer le modèle du Kirchhoff sous une approximation de phase stationnaire également nommé Geometrical-Optics Model (GOM), le modèle du Kirchhoff sous une approximation scalaire sous le nom Physical-Optics Model (POM) et Small Perturbation Model (SPM). Selon (Ulaby et al., 1990), l'utilisation de chaque type de ces trois modèles dépend de la classe de rugosité en d'autres termes un domaine de validité. Les modèles GOM et POM sont plus adaptés aux sols rugueux et à rugosité moyenne, respectivement. En revanche, le modèle SPM est plus recommandé pour une plage de longueur de corrélation réduite (Ulaby et al., 1990). Le modèle 'Integral Equation Model' (**IEM**), développé par (Fung et al., 1992), appartient à la classe des modèles physiques. Il est le plus utilisé par rapport aux autres modèles puisqu'il couvre une large gamme de rugosité des surfaces agricoles (Baghdadi et al., 2004). Le coefficient de rétrodiffusion est exprimé par ces équations :

$$\sigma_{qp}^0 = \frac{k^2}{2} e^{-2(Hrms.k_z)^2} \sum_{n=1}^{+\infty} Hrms^{2n} |I_{qp}^n|^2 \frac{W^{(n)}(-2k_x, 0)}{n!} \quad (9)$$

$$I_{qp}^n = (2.k_z)^n . f_{qp} . e^{(-Hrms^2 k_z^2)} + \frac{k_z^n [F_{qp}(-k_x, 0) + F_{qp}(k_x, 0)]}{2} \quad (10)$$

Avec  $\sigma_{qp}^0$  le coefficient de rétrodiffusion à une polarisation qp,  $\theta$  est l'angle d'incidence,  $k$  est le nombre d'onde,  $k_z = k \times \cos(\theta)$ ,  $k_x = k \times \sin(\theta)$ , et Hrms est l'écart type des hauteurs.  $I_{qp}^n$  terme en fonction de l'angle d'incidence,  $W^{(n)}(-2k_x, 0)$  est la transformation de Fourier à l'ordre n de la fonction d'autocorrélation.

Afin d'élargir le domaine de validité du modèle et minimiser les erreurs dans l'introduction des mesures de rugosité dans le modèle, (Baghdadi et al., 2004) ont remplacé la longueur de corrélation par une longueur optimisée (Lopt) en fonction du Hrms et les paramètres de configuration du capteur radar (angle d'incidence, fréquence et polarisation). Cette nouvelle version du IEM est nommé dans le manuscrit IEM-B. En bande C, ses longueurs se calculent selon les équations suivantes :

$$Lopt(HH) = 0.162 + 3.006 (\sin(1.23 \theta))^{-1.494} Hrms \quad (11)$$

$$Lopt(VV) = 1.281 + 0.134 (\sin(0.19 \theta))^{-1.59} Hrms \quad (12)$$

$$Lopt(HV) = 0.9157 + 1.2289 (\sin(0.1543 \theta))^{-0.3139} Hrms \quad (13)$$

En bande L (Baghdadi et al., 2015), la calibration de la longueur de corrélation s'est faite en utilisant les données des capteurs AIRSAR, SIR-C, JERS-1, PALSAR-1, ESAR en co-polarisation (HH et VV) selon les formules suivantes :

$$\text{Lopt(HH)} = 2.6590 \theta^{-1.4493} + 3.0484 \text{ Hrms} \theta^{-0.8044} \quad (14)$$

$$\text{Lopt(VV)} = 5.8735 \theta^{-1.0814} + 1.3015 \text{ Hrms} \theta^{-1.4498} \quad (15)$$

### b. Modèles empiriques

Les modèles empiriques sont des modèles simples généralement des relations linéaires établies en fonction des mesures in-situ d'humidité ou de rugosité. Dans les travaux de (Ulaby et al., 1982) ont utilisé une fonction linéaire (exponentielle) entre les coefficients de rétrodiffusion en dB (en linéaire) et les valeurs d'humidité du sol mesurées. Bien que les relations empiriques soient utilisées pour calculer les coefficients de rétrodiffusion des sols nus (Bousbih et al., 2017 ; Ezzahar et al., 2020 ; Ouadi et al., 2020 ; Prévot et al., 1993 ; Zribi et al., 2011), elles restent dépendantes aux sites sur lesquels elles étaient calibrées.

### c. Modèles semi-empiriques

Les modèles semi-empiriques sont des modèles simples composés d'une partie des paramètres empiriquement calibrés et des variables in-situ à introduire. La calibration des paramètres élargit le domaine de validité de ces modèles. Dans cette classe, les modèles semi-empiriques Dubois et Oh sont les plus utilisés pour simuler le comportement des ondes électromagnétiques dans le domaine des micro-ondes.

- **Modèle Dubois**

Le modèle Dubois, établi par (Dubois et al., 1995), est un modèle semi-empirique qui simule les coefficients de rétrodiffusion en polarisation parallèle en fonction de la configuration du capteur radar (angle d'incidence et la longueur d'onde) et du descripteur de la rugosité (Hrms). La validité de ce modèle est limitée lorsque l'humidité du sol est inférieure à 35 vol.%, le produit du nombre d'onde ( $k = 2\pi / \lambda$ ) et le Hrms est inférieur à 2.5 et l'angle d'incidence ( $\theta$ ) entre  $30^\circ$  et  $65^\circ$ . La simulation des données radar en bande C (Baghdadi & Zribi, 2006) et en bande X (Baghdadi et al., 2011) est caractérisée par des RMSE de l'ordre de 4 dB. Cette simulation est probablement biaisée due à la plage de validité restreinte de la rugosité. De ce fait, les travaux de (Baghdadi et al., 2015) ont proposé une nouvelle version du modèle Dubois (Dubois-B). Cette version calibrée en utilisant les données en bandes X et C, a introduit une formule pour les données en polarisation croisée (HV) :

$$\sigma_{\text{HH}}^0 = 10^{-1.287} * (\cos \theta)^{1.227} * 10^{0.009 * \cotan(\theta) * Mv} * (k. \text{Hrms})^{0.86 * \sin \theta} \quad (16)$$

$$\sigma_{\text{VV}}^0 = 10^{-1.138} * (\cos \theta)^{1.528} * 10^{0.008 * \cotan(\theta) * Mv} * (k. \text{Hrms})^{0.71 * \sin \theta} \quad (17)$$

$$\sigma_{\text{HV}}^0 = 10^{-2.325} * (\cos \theta)^{-0.01} * 10^{0.011 * \cotan(\theta) * Mv} * (k. \text{Hrms})^{0.44 * \sin \theta} \quad (18)$$

- **Modèle Oh**

Oh et al., (1992) ont proposé le modèle semi-empirique Oh qui simule les coefficients de rétrodiffusion en fonction des deux ratios de polarisation : le rapport de co-polarisation ( $\frac{\sigma_{HH}^0}{\sigma_{VV}^0}$ ) et le rapport de cross-polarisation ( $\frac{\sigma_{HV}^0}{\sigma_{VH}^0}$ ). Le domaine de validité de ce modèle englobe  $10^\circ < \Theta < 70^\circ$ , des valeurs d'humidité entre 4 et 29.1 vol.%. D'autres versions de ce modèle ont été proposées (Oh, 2004 ; Oh et al., 1994, 2002).

#### d. Comparaison des modèles

L'évaluation du potentiel des modèles, précédemment cités, pour estimer les coefficients de rétrodiffusion, a fait l'objectif de plusieurs travaux dans la littérature. Ces modèles ont été testés dans des différents contextes climatiques et édaphiques. Panciera et al., (2014) ont examiné la performance des trois modèles Oh, IEM et Dubois pour simuler les données en bande L dont les angles d'incidence varient entre  $15^\circ$  et  $45^\circ$  et les valeurs d'humidité fluctuent entre 5 et 39 vol.%. Les résultats ont souligné la pertinence relative du modèle Oh avec RMSE d'environ de 2 dB. Le même ordre de grandeur du RMSE (2dB) caractérise les simulations des données multifréquences (bandes X, C et L) en utilisant le modèle Oh dans (Choker et al., 2017).

En revanche, l'inter-comparaison de (Zribi et al., 1997) des modèles IEM et Oh (la version de 1994) a révélé que le modèle Oh-1994 est plus adéquat pour les sols rugueux à des angles d'incidence moyens en raison de sa tendance à sous-estimer les coefficients de rétrodiffusion des sols lisses. Cette sous-estimation, dans le contexte des sols lisses ( $H_{rms} < 1\text{cm}$ ) et un angle d'incidence de l'ordre de  $20^\circ$ , est soulignée par (Baghdadi & Zribi, 2006) en utilisant les deux versions Oh-1992 et Oh-2002 avec des données en bande C. En contrepartie, les simulations en utilisant IEM a signalé la surestimation des coefficients de rétrodiffusion en HH surtout à des valeurs d'humidité qui dépassent 30 vol.%. Pour élargir les domaines de validité des modèles, d'autres versions des sont proposés pour minimiser les biais de simulation.

L'estimation des coefficients de rétrodiffusion en bande C en utilisant IEM-B et Dubois-B a mis en relief une amélioration relative des performances des simulations. Les valeurs RMSE sont inférieures à 1.45 dB et 2.97 dB en polarisation VV en VH, respectivement (Mirsoleimani et al., 2019).

### I.2.5.2. Sol couvert

La végétation constitue un système complexe en évolution continue dans le temps et dans l'espace. Son évolution obéit à un cycle de développement au cours duquel la densité, la structure, la hauteur et le contenu en eau sont variables d'une phase à une autre. Les mesures des propriétés diélectriques faites par (El-Rayes & Ulaby, 1987) ont mis l'accent sur la variabilité de la distribution du contenu en eau dans les différentes composantes de plusieurs variétés de végétation (tronc, tiges et feuilles) en appuyant les conclusions d'(Ulaby, 1975). Cette dynamique spatiotemporelle complique l'estimation des coefficients de rétrodiffusion de la végétation qui sont sensibles aux propriétés diélectriques et la configuration géométrique des diffuseurs constituant le volume comme les feuilles, les tiges et les fruits (Chanzy, 1993 ; Dabrowska-Zielinska et al., 2007 ; Karam et al., 1988 ; Steele-Dunne et al., 2017 ; Ulaby & El-Rayes, 1987).

Ulaby et al., (1990) ont proposé le modèle MICHIGAN MICrowave Canopy Scattering (MIMICS) pour calculer les coefficients de rétrodiffusion des arbres de forêt. Comme étant un système de deux couches, la contribution de chaque couche est calculée séparément en fonction de ses constituants qui peuvent être périodique (Whitt & Ulaby, 1994). Dans un contexte agricole, (Tour et al., 1994) a adapté MIMICS pour estimer le coefficient de rétrodiffusion du blé et du colza en utilisant des données bi-fréquence en bandes C et L. Le modèle MIMICS a été généralisé avec les travaux de (Karam et al., 1988) pour inclure N couches et il a porté le nom du modèle Karam.

Les modèles MIMICS et Karam se basent sur des notions théoriques physiques assez complexes pour l'inverser ultérieurement pour estimer les humidités de sol. Dans ce cas, d'autres modèles semi-empiriques plus simples étaient privilégiés comme le Water Cloud Model (WCM). Ce modèle est sollicité dans la littérature grâce à sa facilité d'application (Graham & Harris, 2003). Il est fondé par (Attema & Ulaby, 1978), le modèle considère la végétation comme un ensemble de gouttelettes d'eau identiques et sphériques, caractérisées par leur densité et sa hauteur de la canopée. La rétrodiffusion totale  $\sigma_{\text{totale}}^0$  est la somme de la contribution de la végétation  $\sigma_{\text{veg}}^0$ , du sol  $\sigma_{\text{soil}}^0$  atténué par la végétation (un coefficient de transmissivité dans deux sens  $\tau^2$ ) et des interactions sol-végétation  $\sigma_{\text{soil-veg}}^0$  :

$$\sigma_{\text{totale}}^0 = \sigma_{\text{veg}}^0 + \tau^2 \times \sigma_{\text{soil}}^0 + \sigma_{\text{soil-veg}}^0 \quad (19)$$

La contribution du sol nu  $\sigma_{soil}^0$  est calculée en utilisant l'un des modèles déjà cités (voir section I.2.5.1.). Le terme des interactions sol-végétation est souvent négligé surtout avec les données en polarisation parallèle (Dobson & Ulaby, 1986 ; Ulaby et al., 1986)

$$\sigma_{veg}^0 = A V1 \cos \theta (1 - \tau^2) \quad (20)$$

$$\tau^2 = \exp(-2 B V2 \sec \theta) \quad (21)$$

Avec  $\theta$  est l'angle d'incidence, A et B sont deux paramètres à calibrer et à valider en fonction de la configuration du capteur radar et de type de végétation, V1 et V2 sont les descripteurs du couvert végétale (V1 = V2). Le choix du descripteur le plus représentatif et fidèle à la dynamique de végétation est toujours abordé dans la littérature. Dans ce cas, nous pouvons parler de trois classes de descripteurs : des variables biophysiques in-situ, des variables extraites des images satellites ou bien des variable biophysiques estimées à partir des images satellites. Les variables in-situ peuvent être l'indice foliaire, la biomasse, le contenu en eau de la végétation (Zribi et al., 2011, Chauhan et al., 2018 ; El Hajj et al., 2016 ; Haldar et al., 2022).

En utilisant les données satellites, les descripteurs sont des indices calculés à partir des optiques tels que NDVI (Baghdadi et al., 2017 ; Bousbih et al., 2017, 2018 ; Prakash et al., 2012) ou EVI (Wang et al., 2019), ou à partir des données radar comme les paramètres de pureté en polarisation parallèle (Bhogapurapu et al., 2022). D'autres auteurs ont établi des relations empiriques entre les données satellites et les variables biophysiques in-situ pour estimer les descripteurs (Liu & Shi, 2016 ; Ma et al., 2020 ; Ouaadi et al., 2021 ; Periasamy, 2018 ; S. Wang et al., 2021).

Afin d'améliorer la performance du WCM, la communauté scientifique a dédié des efforts considérables pour introduire des modifications à la version simplifiée du WCM sous des hypothèses bien déterminées. (Zhang et al., 2020) ont proposé une nouvelle version du WCM tout en pondérant la contribution de la végétation par la fraction de couvert végétal et la contribution du sol nu par (1-fraction du couvert). Cette proposition repose sur l'hypothèse que les pixels ne sont pas couverts par la végétation de manière variable tout au long de son cycle de croissance et de développement. A partir de l'indice spectral NDVI calculé à partir des images optiques, (He et al., 2014) ont calculé la fraction du couvert pour séparer la contribution du sol nu et de la végétation dispersée. Cette approche résulte des RMSE inférieures à 3.4 vol.% en comparant les mesures in-situ d'humidités et les valeurs estimée. La modification du WCM apportée par Bao et al., 2018 en se basant sur l'approximation de Taylor est validé avec des valeurs RMSE approximativement de 5.3 vol.%.

### I.2.6. Méthodes d'inversion des modèles

L'objectif principale de la simulation du comportement du signal radar vise la validation d'un modèle qu'on puisse l'inverser ultérieurement pour estimer l'humidité du sol dans notre cas. L'étape d'inversion requiert l'utilisation des approches fiables pour minimiser les biais et les incertitudes d'estimation.

Les méthodes d'inversion empiriques directes sont les plus simples à partir sur des expressions mathématiques simples (Baghdadi et al., 2017), soit en utilisant une approche de détection de changement (Gao et al., 2017 ; Nativel et al., 2022 ; Tomer et al., 2016). Notamment, il existe des approches qui sont basées sur le Look-up tables (Rabus et al., 2010 ; Rahman et al., 2007) ou bien des algorithmes de Machine Learning tels que le réseau de neurones (Bousbih et al., 2018 ; El Hajj et al., 2016 ; Nativel et al., 2022 ; Paloscia et al., 2008) ou bien les algorithmes de régression (Ezzahar et al., 2020). Les approches probabilistes peuvent être utilisés aussi tels que Bayesian Framework et la chain Marckov Monte Carlo (Ma et al., 2017).

De point de vue méthodologique, toutes ces approches de modélisation et d'inversion sont développées et optimisées pour estimer l'humidité du sol à une échelle fine à une haute répétitivité temporelle avec le minimum du biais. Sur le plan thématique, quel est l'apport de cette information sur l'état hydrique en surface estimée ?

### I.3. Apport de l'état hydrique estimé par télédétection dans la compréhension des processus naturels

L'état hydrique des surfaces constitue un élément majeur dans un système complexes des trois cycles (hydrologique, énergétique et du carbone) qui gouverne les dynamiques des êtres vivants sur terre. Akbar et al., (2020) ont utilisé l'historique des produits d'humidité de surface depuis 1979 jusqu'à 2019 pour quantifier la répartition des précipitations sous forme des flux d'évapotranspiration, de surface et du drainage.

L'utilisation des produits des humidités de surface est bien étendue pour englober l'identification des transitions des régimes d'évapotranspiration (Dong et al., 2022 ; Feldman et al., 2019 ; Short Gianotti et al., 2020). Cette identification des régimes est conditionnée par une valeur limite d'humidité du sol. Le seuil d'humidité de transition entre un régime d'évaporation limitée par l'eau ou par l'énergie est déterminé en utilisant une série d'humidités du sol associées aux données d'amplitude de température diurne en Afrique (Feldman et al., 2019).

Les données d'humidité surfacique du sol ont été explorées dans d'autres travaux portant sur le fonctionnement et le stress de la végétation (Feldman, Akbar, et al., 2018 ; Feldman, Short Gianotti, et al., 2018 ; Lemordant et al., 2018 ; Mankin et al., 2019) surtout que les résultats des traceurs isotopiques indiquent que certaines espèces de végétation préfèrent l'absorption de l'eau des premiers centimètres du sol (Feldman et al., 2023).

Hayat et al., (2019) ont souligné l'influence des scénarii de séchage et de mouillage de la surface du sol sur la dynamique de l'eau dans le xylème de la feuille de la végétation. Lorsque la surface du sol est sévèrement sèche, la conductance sol-végétation a diminué par 1.65 fois par rapport à l'état humide uniforme. Cette dynamique de l'humidité du sol résulte d'un déficit d'humidité du sol suite à une sécheresse. En se basant sur cette définition, il est possible d'identifier les zones touchées par les risques de sécheresse et de prévoir les zones menacées par la sécheresse hydrologique et agronomique (Cook et al., 2020 ; Dai et al., 2018).

L'humidité du sol est une variable spatiotemporelle de forçage et de calibration des modèles de surface tels que le modèle d'Interaction Soil-Biosphere-Atmosphere ISBA qui simule l'ensemble des flux d'eau avec l'atmosphère et le sol (Decharme & Douville, 2006), le modèle « Two-Source Energy Budget » TSEB, le modèle « Town Energy Balance » TEB dans le milieu urbain. D'ailleurs, l'intégration des données d'humidité de surface à l'échelle de la parcelle a amélioré le potentiel des modèles à simuler l'évapotranspiration. L'apport de l'état hydrique dans les modèles de surface a été révélé avec les travaux de (Hssaine et al., 2018). Ils ont établi un nouveau modèle nommé TSEB-SM dont le but principal est de simuler l'évapotranspiration dans deux parcelles de blé irrigué. La valeur ajoutée de ce modèle consiste à calculer l'évaporation du sol en fonction de la résistance du sol. Cette dernière est estimée à partir des humidités du sol mesurées localement à l'aide des TDR installés sur site. En comparant les simulations de TSEB et TSEB-SM avec les données mesurées par Eddy Covariance, les simulations de l'évapotranspiration par TSEB-SM se caractérisent par une erreur relative inférieure de 14% par rapport à l'erreur relative des simulations du TSEB.

Pour éviter la dépendance des travaux aux mesures in-situ et couvrir la variabilité spatiotemporelle de l'ETP, les mesures localisées ont été remplacées par des produits d'humidité tels que les produits SMOS désagrégés de 1 Km (Ait Hssaine et al., 2020) et les produits d'humidité de sol issus seulement des données Sentinel-1 établies par (Ouaadi et al., 2020), de la synergie entre Sentinel-1 et Sentinel-2 établies par (El Hajj et al., 2017) et des produits SMAP désagrégées par les données MODIS et Landsat établies par (Ojha et al., 2019)

(Hssaine et al., 2021). Grâce à ces produits, l'approche TSEB-SM a été spatialisée pour estimer l'ETP à l'échelle d'un périmètre irrigué.

Dans le secteur agricole irrigué, l'introduction des produits d'humidité du sol, tels que les produits AMSR-E, AMSR2 SMOS et ASCAT, a diminué le biais des examens de l'impact de l'irrigation sur les ressources en eau à une large échelle (Kumar et al., 2015). Cette utilité a été soulignée dans les travaux de (Lawston et al., 2017 ; Nie et al., 2022). Nie et al., (2022) ont confirmé que l'utilisation des produits d'humidité du sol désagrégés SMAP 1 et MODIS-LAI, a réduit la sensibilité du modèle à la caractérisation spatiale de la dynamique de l'irrigation avec un taux de 7 à 43%. En exploitant les données à résolution grossière, Brocca et al., (2018) ont pu identifier les zones irriguées et la quantification des doses d'irrigation dans trois contextes climatiques (semi-aride, semi-humide et humide).

Bien que les produits désagrégés soient utilisés dans l'agriculture conduite en irrigué (Dari et al., 2020 ; Paolini et al., 2022 ; K. Zhang et al., 2022), la résolution grossière ne couvre pas l'hétérogénéité spatiotemporelle de l'irrigation à une échelle parcellaire. Dans le but d'optimiser la gestion des ressources en eau, l'information sur l'irrigation au niveau de la parcelle est exigée pour aller à une échelle régionale. Dans cette optique et avec l'arrivée des données Sentinel-1, plusieurs efforts ont été investis pour inclure les produits d'humidité du sol à résolution fine dans la modélisation de l'irrigation.

En se basant sur la synergie optique (Sentinel-2) / radar (Sentinel-1) et l'inversion du WCM, le travail de (Bousbih et al., 2018) a proposé une approche pour estimer les humidités du sol et générer ultérieurement une carte d'humidité du sol à une profondeur de 5cm de la plaine de Kairouan située dans le centre de la Tunisie dont le climat est semi-aride à aride. A partir de cette carte, une classification des zones irriguées et non irriguées est déduite.

Dans le même contexte méthodique, la synergie optique/radar a constitué un pilier pour les produits opérationnels d'humidité de sol d'(El Hajj et al., 2017). Ces produits aussi ont été testé dans les travaux de (Bazzi et al., 2022) pour détecter les événements d'irrigation à chaque date d'acquisition de Sentinel-1 à une échelle parcellaire. Cette approche est validée sur trois sites (deux sites en France et un site en Espagne). L'utilisation de ces produits a permis la détection des événements d'irrigation à une échelle parcellaire en France (Le Page et al., 2020) et en trois sites à l'Europe (Le Page et al., 2023).



A cette même échelle parcellaire des produits et dans un contexte du semi-aride, le travail de (Ouaadi, et al., 2021) consiste à examiner le potentiel des mesures d'humidité assimilées et des produits d'humidité de surface établies dans (Ouaadi et al., 2020) pour détecter et estimer les doses d'irrigation avec l'approche du FAO 56. L'approche est développée en se basant sur les produits issus seulement des données radar, n'a raté que 30% des événements d'irrigation localisée gouttes à gouttes. Selon les métriques statistiques, l'utilisation des produits (Ouaadi et al., 2020) a révélé son potentiel à quantifier les doses d'irrigation avec un RMSE 28.7 mm par rapport une valeur de 27.1 mm caractérisant les estimations établies à partir des données in-situ (Ouaadi, et al., 2021).

## I.4. Conclusions

Dans ce chapitre, nous avons présenté un récapitulatif de l'importance des états de surface dans la modélisation et la simulation des processus naturelles plus particulièrement l'état hydrique. Ce dernier constitue une variable gouvernante des trois cycles hydrologique, énergétique et du carbone. La communauté scientifique a investi beaucoup d'efforts pour quantifier cet élément clé par des mesures directes dans le sol ou en utilisant des outils à distance comme la télédétection. Depuis des décennies, la télédétection a prouvé sa pertinence pour estimer le contenu en eau de surface dans ses différents domaines de longueur d'onde. Le domaine des micro-ondes est souvent élu comme étant un outil adéquat pour estimer l'humidité du sol suite à la sensibilité des signaux électromagnétiques aux propriétés diélectriques du sol. Dans le domaine passif, la résolution spatiale grossière des produits d'humidité est insuffisante pour couvrir la variabilité spatiotemporelle de l'humidité. Par conséquent, le recours au domaine actif qui fournit des acquisitions par la technique SAR à une résolution spatiale plus fine, est une alternative judicieuse.

Dans ce contexte, la deuxième partie de ce chapitre présente des généralités sur la technique des mesure radar et les différentes approches adoptés pour estimer les humidités du sol à partir des données SAR. Ces approches se basent sur la modélisation et l'inversion du comportement du signal radar face aux surfaces des sols. Dans ce cas, nous pouvons utiliser soit des modèles physiques ou bien des modèles semi-empiriques plus simples comme le WCM. Ce modèle requiert une calibration des paramètres qui sont dépendants à la configuration du capteur radar et du type de la végétation. De plus, la végétation est décrite dans ce modèle par des descripteurs qui sont des variables biophysiques in-situ ou bien des variables extraites des images satellites ou bien des variables biophysiques estimées à partir des images acquises selon des relation empiriques établies. Par la suite, l'estimation des humidités du sol fait l'objet de plusieurs

applications hydrologiques, climatiques et agronomiques. L'apport de cette information de l'état hydrique du sol à une échelle parcellaire est examiné dans la troisième partie de ce chapitre.

A partir de ces conclusions, les travaux de la présente thèse vont contribuer dans plusieurs volets. Le premier volet détaille une comparaison du potentiel des données radar en deux fréquences (bandes L et C) pour estimer les humidités du sol pour deux types de culture (les céréales et les piments). Le deuxième volet concerne l'impact du choix des descripteurs de végétation dans le processus d'estimation d'humidité du sol. Finalement, le troisième volet présente l'apport d'une série temporelle des humidités du sol dans l'évolution climatique d'une région. Chaque volet est concrétisé dans un chapitre tout au long du manuscrit.

## Chapitre II

---

### Description de la zone d'étude et de la base des données

---

# Chapitre II

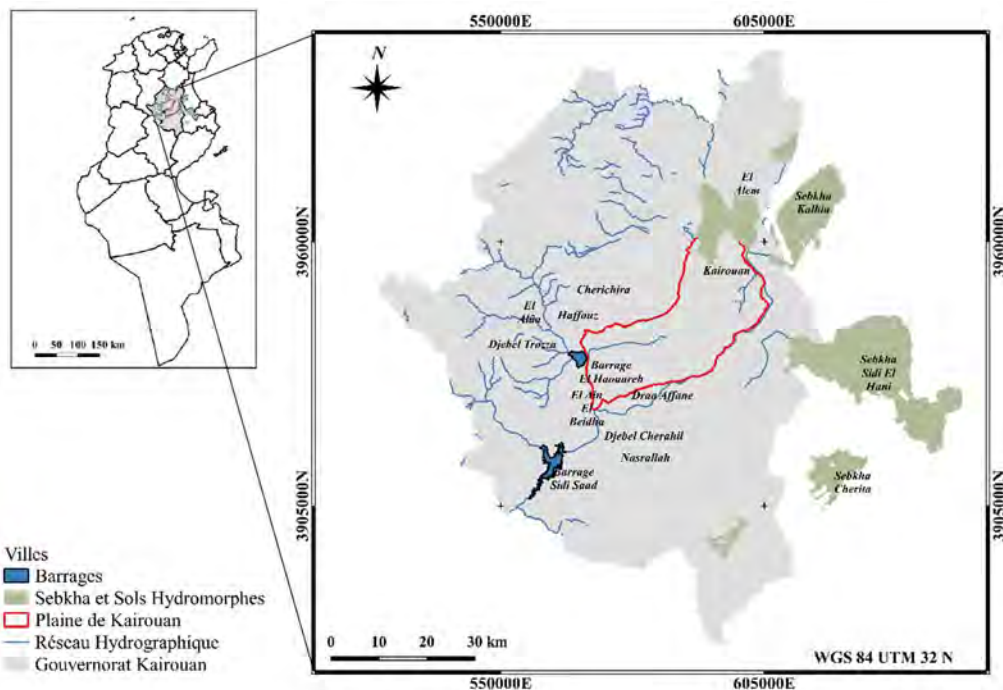
## Description de la zone d'étude et de la base des données

Dans ce chapitre, nous détaillons, dans la première section la situation géographique, géologique, climatique, hydrologique, édaphique et agronomique de la zone d'étude : la plaine de Kairouan. Ensuite, dans la deuxième section, nous décrivons la base de données acquises dans le site d'étude composée des mesures in-situ (humidité et rugosité du sol et variables biophysiques de végétation) et des images satellites acquises par ALOS-2, Sentinel-1 et Sentinel-2.

### II.1. Description du site d'étude : La plaine de Kairouan

#### II.1.1. Situation géographique

La plaine alluviale de Kairouan ( $9^{\circ}23'$ - $10^{\circ}17'$ E,  $35^{\circ}1'$ -  $35^{\circ}55'$ N) couvre une superficie de 3000 Km<sup>2</sup>, disposant du plus important réservoir en eau de la Tunisie centrale. Elle se trouve dans la partie Sud-Est du gouvernorat de Kairouan en s'étalant sur 40 Km dans la direction Est-Ouest et 100 Km dans la direction Nord-Sud (**Figure 17**).



**Figure 17.** Localisation de la plaine de Kairouan dans le gouvernorat de Kairouan.

La plaine de Kairouan occupe la mi-partie sud du bassin Djebibia-El Alem-Kairouan-Nasrallah. Elle est entourée par une série de djebels « montagnes » de l'Ouest notamment Baten, Cherichira, EL Haouareb, Draa Affane et Djebel Cherahil. A l'Est, les collines du Sahel sous forme des dépressions topographiques remplis par des eaux salées (les sebkhas) délimitent la plaine nominativement El Kalbia, El Hani et Cherita (**Figure 17**).

### II.1.2. Contexte géologique

La plaine de Kairouan, à une élévation de 200 m, est caractérisée par une structure géologique complexe et une variabilité lithologique (Ghali, 1993, Nazoumou & Besbes, 2000). Il s'agit d'un bassin d'effondrement dont le seuil est marqué par un dénivelé brutal de 15 m situé au niveau d'un accident tectonique au niveau du barrage El Haouareb (Alazard, 2013).

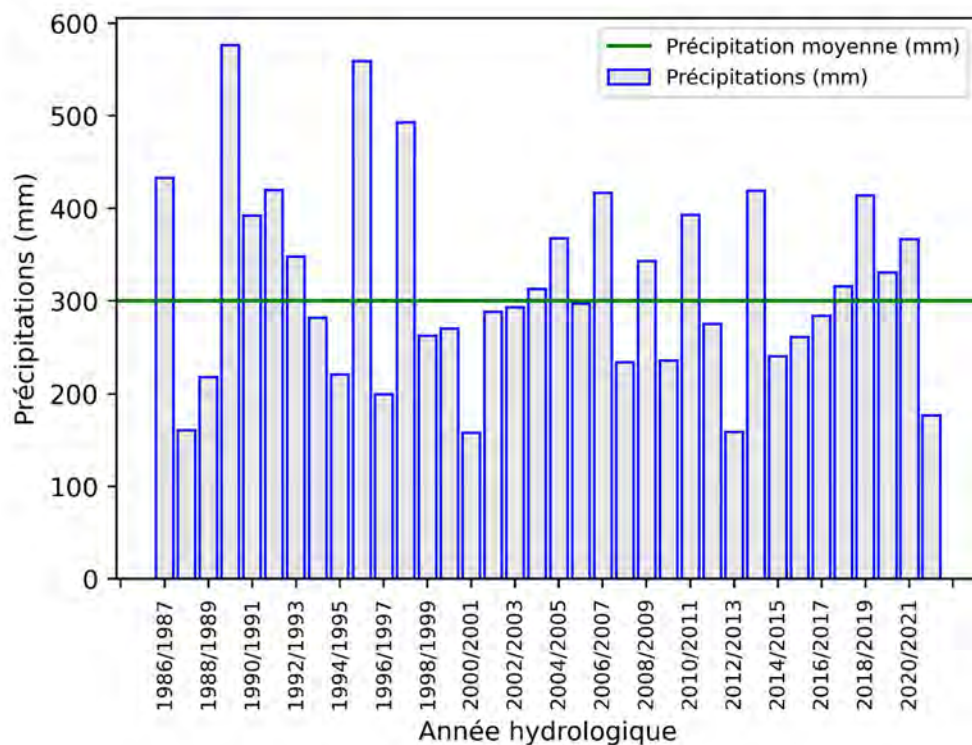
Ce bassin est rempli des sédiments détritiques d'âge Plio-Quaternaire à une épaisseur d'environ 700 m. Cet âge est composé du sable et du silt alternativement avec des couches encroûtées et lenticulaires de sables grossiers et d'argiles (Ammar et al., 2006). Le bassin sédimentaire est entouré par des formations Mio-Pliocène constituées de sables, de silts, d'argiles, de marnes et des conglomérats érodés datant des ères secondaire et tertiaire situés dans les anticlinaux de Draa Affene, Djebel Cherichira et Djebel Baten.

### II.1.3. Contexte Climatique

La plaine de Kairouan se caractérise par un climat qui varie entre le semi-aride et l'aride. Elle est dans une zone de transition entre deux zones à climat tempéré- méditerranéen caractérisant les zones du Tell au Nord de la Tunisie et aride désertique dans le Sud de la Tunisie.

#### II.1.3.1. Pluviométrie

Le régime des précipitations de la plaine de Kairouan se distingue par une saison des pluies du mois de septembre jusqu'au mois de Mai et une saison estivale dont la pluviométrie est quasi nulle. En moyenne, la zone reçoit annuellement environ 300mm. La pluie annuelle d'El Haouareb estimée est de l'ordre de 237 mm (Lacombe et al., 2008). La **Figure 18** illustre les moyennes annuelles des précipitations dans la station synoptique de Kairouan depuis 1986 jusqu'à 2022.




**Figure 18.** Répartition des précipitations annuelles de la station de Kairouan synoptique entre 1986 et 2022.

Ces moyennes sont variables d’une année à une autre marquant les années humides et les années relativement sèches. Sur toute la chronique (1986- 2022), l’année 1989/1990 est la plus humide distinguée par des précipitations de l’ordre de 576.6mm. Des quantités similaires, à l’environ de 559.5mm, sont observées durant l’année 1995/1996.

En contrepartie, pendant les années 1987/1988, 2000/2001, 2012/2013 et 2021/2022, la plaine de Kairouan n’a reçu que des quantités inférieures à 177mm. Ces années constituent les périodes les plus sèches de la chronique. La **Figure 19** représente la moyenne des précipitations entre 1986 et 2022.

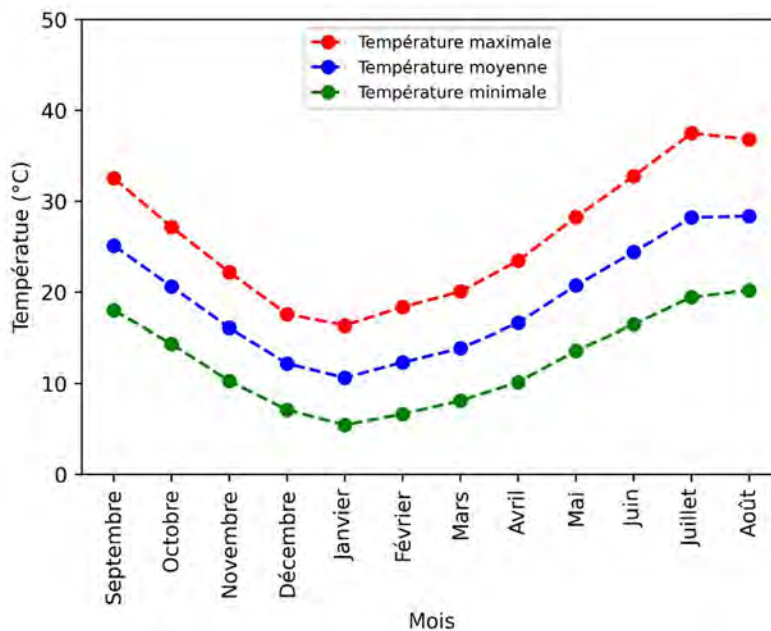
La comparaison inter mensuelle des moyennes des précipitations souligne une irrégularité des pluies d’un mois à un autre. Il s’agit des moyennes élevées enregistrées par excellence en Septembre ( $\approx 46$  mm) et en Mars ( $\approx 45$  mm).



**Figure 19.** Répartition des précipitations moyennes mensuelles de la station de Kairouan synoptique durant la période entre 1986 et 2022.

### II.1.3.2. Température, Vents et Evaporation

La **Figure 20** illustre l'évolution des températures moyennes mensuelles durant la période entre 1986 et 2022. La température varie entre 11°C dans les mois les plus froids (Décembre, Janvier et Février) et peut atteindre en moyenne 30°C durant les mois les plus chauds en Juillet et Août (Bouzaiane et Lafforgue, 1986). Les températures maximales peuvent atteindre des valeurs proches de 37.5 °C.




**Figure 20.** Répartition des températures moyennes, minimales et maximales mensuelles de la station de Kairouan synoptique durant la période entre 1986 et 2022.

D'après Bouzaiane et Lafforgue, 1986, la plaine est dominée par des vents saisonniers de direction Nord-Nord-Ouest pendant l'hiver sous forme d'un vent froid Jebbali arrivant de l'Algérie. Pendant l'été, la plaine est bien ventée dans une direction Sud-Sud Est avec des orages du Nord-Est avec la présence du sirocco qui contribue au dessèchement des sols (Bouzaiane et Lafforgue, 1986).

Les températures élevées et les vents favorisent l'évaporation. Pour quantifier cette variable climatique, plusieurs approches ont été évaluées dans Alazard et al., 2015. Dans le lac d'El Haouareb, l'évaporation varie annuellement entre 1400 et 1900 mm. En combinant les résultats des différents approches utilisés dans (Alazard et al., 2015), la moyenne interannuelle de l'évaporation est d'environ 1700 mm/an avec une incertitude de 15%.

#### II.1.4. Ressources en sols

La plaine de Kairouan occupe la partie Sud-Est de la dorsale Tunisienne. Elle est caractérisée par des sols isohumiques auprès de l'oued Merguellil près du Djebel de Trozza. Cette cuvette alluviale communique avec la plaine de Nasrallah et la plaine de Sidi Saad à travers oued Zeroud (**Figure 21**).




**Figure 21.** Carte de texture des sols de la plaine de Kairouan (extraite de la carte agricole 2000).



Les deux oueds Merguellil et Zeroud marquent la plaine par leurs lits et dépôts sédimentaires qui sont de moins en moins présents vers l'exutoire naturel de la plaine : les sebkhas. Par conséquent, la plaine se distingue par des formations pédologiques peu évoluées présentant des différentes textures : des sols halomorphes salins sur la rive droite du Zeroud, des sols à texture argileuse ou argilo-sableuse, ainsi qu'une texture sableuse grossière en aval des deux oueds. Des sols calcimagnésiques se reposent sur les formations calcaires du Crétacée en contact avec des sols minéraux bruts (lithosols/régosols). Les sols isohumiques, peu évolués et calcimagnésiques forment des associations complexes du sol présentes dans les Nord et Sud de la plaine. Cette diversité des sols induit une variabilité spatiale des textures (**Figure 21**).

Pour couvrir la variabilité spatiale de la texture à une échelle plus fine, plusieurs travaux ont développé des approches pour cartographier le teneur en argile de la plaine de Kairouan en utilisant des données satellites et des données in-situ de la texture (**Figure 22**).



**Figure 22.** Produits de texture des sols de la plaine de Kairouan réalisée à partir : (a) des données optiques Landsat (Shabou et al., 2015), (b) de la synergie des données optiques-radar (Bousbih et al., 2019) et des données radar (c) Zribi et al., 2012 et (d) Gorraab et al., 2015 et à des différentes étendues sur le site d'étude.

A partir des données optiques, Shabou et al., 2015 ont généré la carte du contenu en argile de la plaine à une résolution de 100 m avec un RMSE de l'ordre de 10 %. Pour atteindre le même objectif, Bousbih et al., 2019 ; Gorrab et al., 2015 ; Zribi et al., 2012 ont utilisés les données SAR.

Dans Zribi et al., 2012, la cartographie des quantités d'argile à une résolution spatiale de 50m, se base sur les données SAR en bande X (TerraSAR-X) avec un RMSE de 12%. En utilisant les mêmes données, Gorrab et al., (2015) ont basé leur approche sur la détection des changements pour produire des cartes d'humidité et par la suite la carte de texture. La prise en compte de la variation temporelle des niveaux d'humidité du sol a induit une diminution du RMSE passant de 12% dans l'étude de Zribi et al., 2012 à 11% dans celle de Gorrab et al., 2015.

En partant du même principe, les travaux de Bousbih et al., 2019 ont investi la synergie entre les données optiques et radar (Sentinel-1 en bande C) pour classer la texture du sol en trois classes selon la quantité de l'argile. L'utilisation de la synergie des deux constellations Sentinel 1 et 2 a permis de produire des cartes à une résolution spatiale de 10m.

Tous les résultats mentionnés ont convergé vers la même variabilité spatiale de la teneur en argile et l'importance des données satellites optique et radar pour caractériser la texture en surface. Cette hétérogénéité de texture s'associe avec la complexité lithologique pour renforcer la complexité de la distribution des propriétés hydrauliques de la plaine de Kairouan (Jerbi et al., 2018).


### II.1.5. Contexte hydrologique et hydrogéologique

L'aquifère alluvial du Plio-Quaternaire est alimenté par deux cours d'eau intermittents de flux saisonniers. Ces deux oueds Zeroud et Merguellil drainent deux bassins versants occupant 1330 Km<sup>2</sup> et 8600 Km<sup>2</sup>, respectivement. Dans le but de protéger les villes contre les inondations, deux barrages ont été implémentés sur les deux cours d'eau : barrage Sidi Saad (1978-1981) sur l'oued Zeroud à 20 Km de la plaine de Kairouan et barrage El Haouareb (1986-1989) sur l'oued Merguellil (Chebbi et al., 2008 ; Derwich et al., 2012).

Ces constructions ont participé à la modification du régime hydrologique de la plaine. Les eaux de ruissellement parcourent les lits des oueds perchés et percolent en profondeur pour recharger la nappe. Ce réservoir naturel est la zone de confluence de plusieurs aquifères communicantes entre elles. Le barrage d'EL Haouareb est un relais entre les réservoirs aquifères du bassin amont de Merguellil (Bou Hafna, Haffouz-Chérichira et Ain El Baidha) et la plaine de Kairouan.

Les cartes piézométriques réalisées par (Kingumbi et al., 2007) ont prouvé la convergence des écoulements des nappes profondes vers le seuil d'El Haouareb. Les écoulements d'Ain El Bidha participent au processus de recharge de la nappe à travers les barres calcaires d'âge Crétacé supérieur du Djebel El Haouareb. En profondeur, d'autres jonctions hydrauliques du Plio-Quaternaires relie la plaine de Kairouan au Djebel Cherichira. Selon la topographie, la direction des flux de ruissellement est du Sud-Ouest vers le Nord-Est avec un gradient de transmissivité décroissant de l'Ouest vers l'Est (Nazoumou & Besbes, 2000). Ce gradient est le résultat des écoulements dont la vitesse diminue vers l'Est avec une augmentation du taux d'argile déposé. Par conséquent, les lentilles d'argile s'élargissent et s'interconnectent pour former une couche imperméable séparant la nappe phréatique et la nappe confinée dans le Nord et l'Est de Kairouan (Ammar et al., 2006 ; Nazoumou & Besbes, 2000). Les sebkhas Sidi El Hani et Cherita constituent l'exutoire naturel des eaux de surface et souterraines. L'aquifère est séparée en deux réservoirs séparés par une couche d'argile confinée.

Durant les 40 années après 1968, selon la **Figure 23** extraite des travaux Massuel & Riaux, 2017, la nappe de la plaine de Kairouan témoigne un rabattement de l'ordre de 30 m suite à une exploitation intensives des eaux souterraines et l'approvisionnement en eau potable (Jerbi et al., 2018 ; Leduc et al., 2007, 2017 ; Massuel & Riaux, 2017).



**Figure 23.** Evolution du niveau d'eau dans l'aquifère de la plaine de Kairouan depuis les inondations de 1969, l'implémentation du barrage El Haouareb en 1989 jusqu'à 2010. Ces courbes sont établies à partir des niveaux piézométriques au niveau de P1 et P2 (sur Merguellil jusqu'à 1989 et le barrage El Haouareb après 1989), P3 et P4 (dans la zone de recharge saisonnière) et P5 et P6 (renseignant sur le niveau de l'aquifère de la plaine de Kairouan) (Massuel & Riaux, 2017).

D'ailleurs, cette surexploitation est mise en relief par une augmentation de cinq fois du nombre des forages de 400 en 1960 à 2000 en 2010 (Jerbi et al., 2018). Le nombre de forages illicites a encore beaucoup plus augmenté depuis le 14 janvier 2011 mais il n'y a pas un inventaire exhaustif à ce jour.

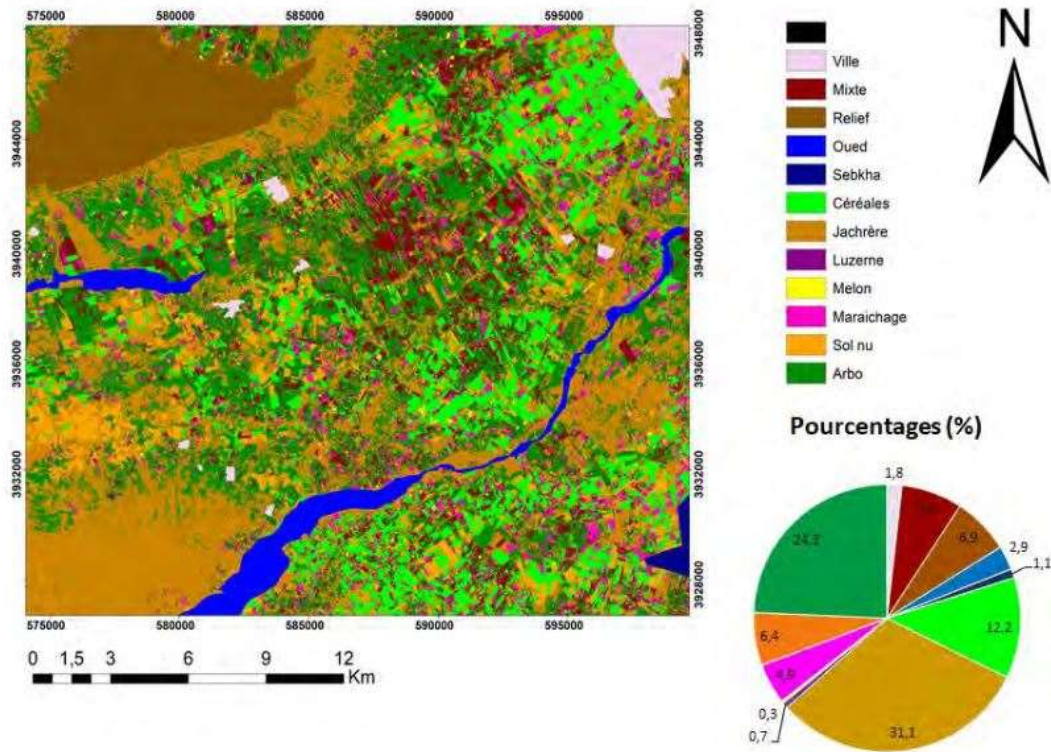
Les formations géologiques, pédologiques, climatiques ainsi que le cadre hydrologique et hydrogéologique conditionnent directement le marché agricole et les occupations des sols dans la plaine de Kairouan.

### II.1.6. Contexte agricole et occupation du sol

Le marché agricole dans la plaine de Kairouan est étroitement lié aux facteurs naturels ainsi qu'aux forçages anthropiques. Selon les cartes d'occupation du sol dans la plaine depuis 2009 (Shabou, 2010, Amri et al., 2011, Zribi et al., 2011), les occupations de sol principales sont des oliviers, des céréales (en pluvial ou irriguées) ou bien des cultures maraîchères de saison hivernale ou estivale. L'existence des cultures saisonnières associés à des cultures annuelles amène la production des cartes d'occupation des sols à une échelle saisonnière. La **Figure 24** illustre l'occupation du sol dans la saison hiver-printemps de l'année 2019/2020. L'occupation de sol se scinde entre arboriculture (24.3 %), jachère (31.1%), des céréales (12.2 %), des cultures mixtes (7.4 %) et du maraîchage (4.9%).

La plupart des producteurs des céréales sont des petits exploitants dans la plaine (62.1 %) dont la superficie de ces parcelles ne dépasse par une dizaine d'hectare (Annuaire agricole, 2018). Ces statistiques soulèvent une autre menace du marché agricole à Kairouan : le morcellement des parcelles qui est accentué par l'héritage et la conversion des statuts fonciers. Ces parcelles, en dehors du cycle des céréales, sont occupées par des cultures maraîchères tels que les pastèques, les melons, les fèves, les féveroles, les tomates, les piments ...

Les cultures maraîchères, à Kairouan, contribuent par 3.49% de la production national agricole tout en procurant 28 % des superficies irriguées. La production des piments est la première consommatrice des eaux d'irrigation par rapport à d'autres cultures maraîchères avec une productivité de 22.9 tonnes / hectare selon les chiffres de l'annuaire agricole de 2018. D'ailleurs, le gouvernorat de Kairouan préoccupe les plus larges superficies irriguées équipées en Tunisie avec un taux de 13.36% (FAO, consulté le 14 juin 2023).



**Figure 24.** Occupation du sol de la plaine de Kairouan, de résolution spatiale de 10 m, produite à partir des données optiques Sentinel-2 et des observations terrain de la campagne hiver-printemps 2019-2020 (Zayani, 2023).

Les sources d'irrigation sont principalement des sources souterraines, en surface et minoritairement des eaux traitées. Sur la plaine de Kairouan, il existe un nombre limité d'agriculteurs qui bénéficient des réseaux d'irrigation publiques sous la tutelle du Groupement de Développement Agricole (GDA). Ce réseau est généralement géré par un chef GDA et un agent du pompage responsable de la distribution des eaux d'irrigation aux agriculteurs selon un calendrier bien déterminé. En contrepartie, la plupart des agriculteurs, pour augmenter la productivité des cultures et faire face à la sécheresse, comptent sur le pompage de leurs propres forages. D'ailleurs, le nombre de forages illicites a considérablement augmenté, surtout après la révolution en Tunisie et on peut même parler d'une économie des eaux souterraines (Collard et al., 2015 ; Finco et al., 2018 ; Leduc et al., 2017 ; Massuel & Riaux, 2017). Cette solution de pompage excessive est considérée comme étant une mal-adaptation aux conditions actuelles de pénurie d'eau et contribue à l'appauvrissement de la nappe (Massuel & Riaux, 2017 ; Snoussi et al., 2022).

Dans la plaine de Kairouan, l'orientation à une gestion optimisée de l'offre des ressources en eau et le pilotage précis de l'irrigation d'une échelle parcellaire à une échelle régionale dans cette zone est nécessaire et urgente.

Dans les travaux de (Saadi et al., 2015), les auteurs ont pu quantifier les volumes d'irrigation à une échelle parcellaire et à l'échelle de trois GDA dans la plaine avec le modèle SAMIR (SAteellite Monitoring IRrigation) et en utilisant les images SPOT4, Take 5 et SPOT5. Ces estimations peuvent être améliorées lorsque l'humidité du sol est disponible dont les résolutions temporelle et spatiale sont fines. Dans ce contexte, nous avons établi une approche pour quantifier l'humidité de la surface du sol à partir des données satellites. Cette variable est un élément nécessaire pour optimiser les doses d'irrigation selon la disponibilité d'eau dans le sol. L'établissement de cette approche requiert une base de données in-situ et satellites. La partie suivante de ce chapitre décrit en détails ces données utilisées.

## II.2. Description de la base de données

### II.2.1. Données In-situ

#### II.2.1.1. Récapitulatif des campagnes terrain

Afin de collecter les mesures in-situ dans la plaine de Kairouan, deux campagnes durant l'année agricole 2019/2020, interrompues par la pandémie COVID et une campagne en 2022 ont été conduites. Pour chaque campagne, nous avons réalisé les mesures terrains dans des parcelles de références que nous avons sélectionnées dont la superficie est généralement supérieure à un hectare. Les mesures terrain sont collectées simultanément aux passages des satellites SAR.

- La première campagne s'est déroulée entre le mois d'octobre 2019 et fin février 2020. Nous avons sélectionné, mi-octobre, des parcelles de référence initialement occupées par des sols nus à différentes rugosités (11 parcelles) et des jachères (4 parcelles). Les rugosités des sols nus sont variables entre des sols lisses et des sols avec un moyen ou un grand labour.

Les variables in-situ mesurées comprennent la rugosité et l'humidité du sol nu et les variables biophysiques des céréales : l'indice foliaire, la hauteur de la végétation et le contenu en eau de végétation. En raison de la pandémie du COVID, cette première campagne qui a duré quatre mois s'est arrêté en mars 2020 sans la finalisation du cycle des céréales, comme prévu initialement. **Le Tableau 2** récapitule les mesures terrain réalisées sur cette campagne par date d'acquisition des images satellites.

- La deuxième campagne consiste à suivre six parcelles de piments durant les trois mois d'été 2020 (juin, juillet et août). Il s'agit de couvrir tout le cycle de développement de ce couvert végétal.

**Tableau 2.** Récapitulatif [min, max] des mesures in-situ collectées lors de la première campagne terrain des paramètres de rugosité (Hrms, Lc), de l'humidité à 5 cm de profondeur Mv (vol.%) et les variables biophysiques (Hauteur (H), Indice foliaire (LAI) et contenu en eau de la végétation (VWC)).

Date	Hrms (cm)	Lc (cm)	Mv (vol.%)	H (cm)	LAI (m <sup>2</sup> /m <sup>2</sup> )	VWC (kg/m <sup>2</sup> )
26/10/2019	[0.46–6.46]	[3.45–10.11]	[6.6–25.5]	-	-	-
27/10/2019	[0.46–6.46]	[3.45–10.11]	[5.8–30.5]	-	-	-
09/11/2019	-	-	[13.6–30.1]	-	-	-
23/11/2019	-	-	[6.0–23.9]	-	-	-
07/12/2019	[0.46–6.46]	[2.8–10.11]	[9.1–30.4]	-	-	-
20/12/2019	[0.46–4.55]	[2.8–10.11]	[7.6–28.5]	[16.8–41.3]	[1.20–2.83]	[0.1–0.9]
04/01/2020	-	-	[4.5–25.9]	[20–49.6]	[0.9–3.1]	[0.1–0.9]
13/01/2020	-	-	[6.5–32.8]	[10.7–53.5]	[0.7–3.62]	-
01/02/2020	-	-	[4.6–28.2]	[15.2–83.2]	[0.31–4.06]	[0.07–0.9]
15/02/2020	-	-	[3.7–32.1]	[25.6–100]	[0.8–4.50]	-
24/02/2020	[0.46–4.55]	[0.8–10.11]	[5.9–33.1]	[28.1–105]	[1.1–4.03]	[0.13–1.09]
25/05/2020	[0.46–3.95]	[2.8–10.11]	[3.4–21.2]	-	-	-

• La troisième campagne est réalisée durant le printemps du 2021/2022 dans une quinzaine des parcelles céréales à partir de la fin de Mars jusqu'à Mi-mai 2022 incluant l'indice foliaire et la hauteur de la végétation. Il s'agit d'une campagne exceptionnelle ayant pour objectif de finaliser les mesures stoppées par la pandémie du COVID en 2022.


**Tableau 3.** Récapitulatif [min, max] des mesures in-situ collectées lors de la deuxième campagne terrain des paramètres de rugosité (Hrms, Lc), de l'humidité à 5 cm de profondeur (entre les lignes de végétation Mvinter-row (vol.%) et sur la ligne des piments Mvvegr-row) et les variables biophysiques des piments (Hauteur (H), Indice foliaire (LAI) et Fraction de couvert (Fc)).

	Hrms(cm)	Lc (cm)	Mvinter-row (vol.%)	Mvvegr-row(vol.%)	Hauteur (m)	LAI (m <sup>2</sup> /m <sup>2</sup> )	Fc
08/06/2020	[1.84–2.54]	[2.98–7.40]	[4.90–6.10]	[12.50–17.50]	[0.19–0.40]	[0.15–0.18]	[0.20–0.33]
17/06/2020	[1.84–2.54]	[2.98–7.40]	[5.70–10.70]	[9.40–23.50]	-	-	-
22/06/2020	-	-	[5.50–21.10]	[5.60–27.60]	[0.17–0.41]	[0.07–0.56]	[0.08–0.43]
24/06/2020	-	-	[5.50–21.10]	[5.60–27.60]	[0.17–0.41]	[0.07–0.56]	[0.08–0.43]
05/07/2020	[1.50–2.54]	[2.98–7.40]	[5.80–27]	[6.80–28.50]	[0.22–0.42]	[0.20–0.45]	[0.20–0.50]
06/07/2020	-	-	[5.80–27]	[6.80–28.50]	[0.22–0.42]	[0.20–0.45]	[0.20–0.50]
20/07/2020	[1.50–2.54]	[2.98–7.40]	[6.40–31.40]	[8.90–30.90]	[0.27–0.55]	[0.30–0.71]	[0.21–0.38]
23/07/2020	[1.50–2.54]	[2.98–7.40]	-	-	[0.22–0.56]	[0.32–0.71]	[0.25–0.38]
03/08/2020	[1.50–2.54]	[2.98–7.40]	[6.80–24.10]	[9.80–31]	[0.35–0.63]	[0.38–0.90]	[0.33–0.46]
04/08/2020	-	-	[6.80–20.10]	[9.80–31]	-	-	-
16/08/2020	[1.50–2.54]	[2.98–7.40]	[5.30–29.50]	[10.80–32.10]	[0.39–0.64]	[0.50–1.75]	[0.17–0.46]
17/08/2020	-	-	[5.30–29.50]	[10.80–32.10]	[0.39–0.64]	[0.50–1.75]	[0.17–0.46]

## II.2.1.2. Descriptif des parcelles de référence de céréales

Les parcelles des céréales irriguées sont sélectionnées dans la plaine de Kairouan entre la zone de Sidi Ali Ben Salem durant la campagne 2019/2020 et Chebika durant la campagne du printemps 2022 (**Figure 25**). Selon les différentes enquêtes avec les agriculteurs, les variétés du blé semés sont Karim, Dhahbi, Portodur, Maali et Salim.

Le semis marque le début du cycle du blé en décembre avec quelques jours de décalage entre les agriculteurs. Ce cycle se scinde en trois périodes : une période végétative, une période reproductrice et une période de formation et de maturation du grain finie par la sénescence.




**Figure 25.** Localisation des parcelles de référence des céréales durant les deux campagnes terrain 2019/2020 et printemps 2022 dans la plaine de de Kairouan.

Selon l'échelle de Gate 1995, la période végétative englobe une phase de germination-levée et une phase levée-tallage (**Figure 26**). Durant cette période, la chaleur, l'aération et l'état hydrique de la plante ainsi que la faculté germinative du grain gouvernent la levée et le tallage du blé (Eliard, 1979, Evans, 1978 ; Masle-Meynard et al., 1981). L'apport des agriculteurs de la plaine en Di-Ammonium Phosphate (DAP) et en ammonite, avec des doses variables entre 150 et 200 Kg par hectare, accélère la vitesse de tallage et le nombre des talles (Austin et Jones, 1975).



La période reproductrice succède la levée par une phase de montaison-gonflement marquée par une croissance active et un besoin accru en éléments nutritifs en azote. Vers mi-Mars dans la zone d'étude, l'éclatement de la gaine avec l'émergence des épis déclare le début de la phase d'épiaison du blé. Ce stade repère le maximum de la croissance de la plante avec l'élaboration du trois quarts de la matière sèche totale. Il s'agit d'une phase sensible au manque d'eau surtout avec les températures élevées qui altèrent à la fois la vitesse et la durée de remplissage des grains (Masle-Meynard et al., 1981 ; Slama et al., 2005).



**Figure 26.** Stades phénologiques du blé suivis lors des missions terrain durant 2019/2020 et printemps 2022 : (a) germination, (b, c) tallage, (d) montaison, (e) floraison, (f, g) remplissage des grains, (h, i) maturité des blés et (j) la récolte.


Après la floraison, le mécanisme de la plante est orienté vers la maturation et le remplissage des grains à partir de la biomasse produite. La partie aérienne du blé commence à jaunir dans les parcelles de Kairouan durant le mois d'avril au cours duquel les agriculteurs donnent le dernier tour d'eau d'irrigation pour renforcer le remplissage des grains.

Avec l'augmentation de la température au mois de Mai, les grains mûrent et perdent l'eau. Vers la fin du mois de Mai-début Juin, le blé est prêt à être récolté et on passe à la phase de sénescence au cours de laquelle la plante s'affaisse et les grains se détachent. Avec l'augmentation actuelle de la température dans la plaine de Kairouan, le séchage des grains devient de plus en plus rapide et par conséquent la récolte devient de plus en plus précoce. Cet aléa climatique induit des changements du calendrier des agriculteurs et l'établissement des stratégies de pilotage des irrigations en précision surtout que le déficit hydrique dans les phases : montaison, floraison et remplissage des grains (Slama et al., 2005).

Pour bien suivre ces différentes phases phénologiques, nous avons examiné l'apport des données radar pour suivre la dynamique du blé durant les deux saisons agricoles 2018/2019 et 2019/2020 de 64 et 66 parcelles, respectivement identifiées dans la plaine de Kairouan.

### II.2.1.3. Descriptif des parcelles de référence de piments

Le déficit hydrique affecte également les autres cultures de la plaine surtout les cultures maraîchères qui sont des consommatrices d'eau par excellence. Vu l'importance de cette culture dans la production agricole de la plaine de Kairouan (GIL, 2015), nous avons sélectionné sept parcelles de piments (*Capsicum annumum*) dont la superficie varie entre 1 et 2.6 ha dans la région de Sidi Ali Ben Salem (Figure 27). Selon les enquêtes avec les agriculteurs, les variétés les plus cultivées en plein champs dans la plaine de Kairouan sont Chaabani, piments Sesseb Baklouti Kairouan, M'sarreh et Starter.



**Figure 27.** Localisation des parcelles de référence des piments durant la campagne terrain d'été 2020 dans la plaine de de Kairouan par deux rectangles en pointillé. Le contenu de chaque rectangle est représenté à droite de la figure.

Les piments, généralement, sont plantés après la récolte des blés vers fin Mai – début Juin. Un déchaumage est conduit pour éliminer les chaumes. Ultérieurement, le sol est labouré et tracé en lignes. Sur ces lignes, les rampes d'irrigation localisée goutte à goutte sont installées pour

alimenter les plantules de piments. Le cycle de développement des piments commence par le développement des feuilles, ensuite l'émergence et la floraison, le développement des fruits et finit par la sénescence de la plante. Les lignes de piments sont séparées par 1 mètre de sol nu, recevant une irrigation localisée à partir des goutteurs à un intervalle de 30 cm (**Figure 28**).

Le développement des mauvaises herbes en sol nu ou bien sous les pieds de la végétation est probable. Dans ce cas, les agriculteurs procèdent un désherbage manuel des adventices souvent accompagnant la récolte des piments. La récolte des piments peut être faite à plusieurs fois en fonction du rendement de la variété plantée (Feldman et al., 2018). L'architecture des parcelles cultivées en rang et irriguées localement a induit une répartition hétérogène de l'humidité du sol dans le sol nu et sur la ligne de la végétation.



**Figure 28.** Stades phénologiques des piments suivis lors des missions terrain durant les trois mois Juin, Juillet et Août 2020.

#### II.2.1.4. Mesures d'humidité

Les mesures d'humidité sont collectées à 20 points spatialement distribuées au niveau de chaque parcelle test en utilisant une sonde portable Thetaprobe dans les cinq premiers centimètres du sol. En se basant sur le même principe expliqué dans la section 2.1.1. du chapitre 1, grâce à la différence d'impédance, l'humidité du sol est mesurée en fonction de la constante diélectrique apparente en fonction du voltage mesuré et des constantes dépendantes des types du sol à calibrer (Miller & Gaskin, 1999).

Sous forme des valeurs volumétriques, ces mesures sont calibrées par des mesures gravimétriques dans des anciens travaux (Zribi et al., 2011, 2014). Les incertitudes des mesures par Thetaprobe à une calibration spécifique est estimée à 2 vol.% par rapport à une erreur de 5 vol.% lorsque la calibration des probes est générale (Miller & Gaskin, 1999). Nous calculons par la suite la moyenne d'une vingtaine des points pour avoir une moyenne par parcelle. Durant les missions terrain, les mesures d'humidité sont prises dans un intervalle de quatre heures autour du passage satellite tout en tenant en compte des irrigations et des pluies tombées. Les valeurs des humidités  $M_v$  varient entre 3 et 33.1 vol.% pour l'année agricole depuis Octobre 2019 jusqu'à Février 2020. Les valeurs d'humidité de surface du sol, en printemps 2022, fluctuent entre 7.7 vol.% et 28.9 vol.%.

Pour les parcelles des piments, la végétation est plantée en rangs avec une répartition hétérogène de l'humidité du sol. Dans ce contexte, nous avons réparti une dizaine de mesures autour des pieds de végétation tout au long de la rangée de la végétation  $M_{v_{veg-row}}$  occupant une partie  $\alpha$  de la parcelle et une dizaine de mesures dans la partie du sol nu qui sépare les rangées des piments  $M_{v_{inter-ro}}$  occupant la proportion  $(1 - \alpha)$  de la parcelle de référence. Une humidité pondérée est calculée ultérieurement selon l'équation suivante :

$$M_v = \alpha \times M_{v_{inter-ro}} + (1 - \alpha) \times M_{v_{veg-row}} \quad (22)$$

Selon les observations sur terrain, nous assumons que 15% des parcelles est occupé par la végétation et 85% des parcelles est occupé par le sol nu. Dans ce cas,  $\alpha$  est prise égale à 0.85. Les humidités  $M_{v_{inter-row}}$  et  $M_{v_{veg-row}}$  varient entre 4.9 vol.% et 31.4 vol.% et 5.6 vol.% et 32.1 vol.%, respectivement.

#### II.2.1.5. Mesures de rugosité

Les mesures de la rugosité de surface du sol contribuent dans la caractérisation de la géométrie des sols. Nous avons utilisé un rugosimètre à aiguilles. Cet outil est sous forme d'un tableau de bord de largeur de 1 m avec 50 aiguilles de 1m de longueur chacune et un intervalle d'échantillonnage de 2cm séparant les aiguilles. Sur chaque parcelle test, nous avons réalisé six profils : trois profils perpendiculaires et trois parallèles à la direction du travail du sol (**Figure 29**).



**Figure 29.** Mesures de rugosité en utilisant le rugosimètre à aiguilles dans les parcelles test.

A partir des clichés prises des profils, nous avons digitalisés les profils pour calculer les paramètres statistiques décrivant la rugosité : l'écart type des hauteurs (Hrms) et la longueur de corrélation (Lc). Le profil de rugosité est représenté par un axe horizontal (ox). Il est caractérisé par des valeurs discrètes d'hauteur noté  $z_i = f(x_i)$  par rapport à cet axe espacé par  $\Delta x$ . Nous pouvons par la suite calculer l'écart type des hauteurs (Hrms) avec  $\bar{z}$  est la moyenne des hauteurs de N points :

$$\bar{z} = \frac{1}{N} \sum_{i=1}^N z_i(x) \quad (23)$$

La longueur de corrélation de la surface est une référence statistique pour estimer l'indépendance statistique des deux points de la surface. Si deux points sont séparés à une distance horizontale supérieure à Lc, elles sont (approximativement) statistiquement indépendantes l'une de l'autre. Cette distance est définie comme étant la distance à partir de laquelle la fonction d'autocorrélation est égale  $= 1/e$ . Durant les campagnes du terrain, les valeurs de Hrms varient entre 0.46 pour les sols lisses et 6.46 cm pour les sols à surface très rugueuse (le cas du labour très profond). La longueur de corrélation varie entre 0.8 et 10.11 cm dont les valeurs élevées correspondent aux sols les plus lisses.

A partir des mesures in-situ de la rugosité et les images SPOT et TerraSAR-X, Gorrab et al., (2015) ont déjà élaboré une carte de la rugosité des sols nus de la plaine de Kairouan en 2013. Cette carte a permis de classer les sols en labourés, lisses et dégradés. En utilisant les indices calculés à partir des données Sentinel-2 entre 03/06/2017 et 30/07/2018, une cartographie du


travail du sol dans la plaine de Kairouan à 10 m de résolution a été établie dans le cadre du mastère de Zayani 2019. Ces cartes ont permis d'identifier les périodes de travail du sol en Juin 2018 à une échelle régionale.

#### II.2.1.6. Mesures des variables biophysiques de la végétation

##### a. Indice foliaire (LAI) et fraction de couvert (Fc)

Les mesures de LAI représentent géométriquement la surface d'une face du tissu photosynthétique d'un côté de la feuille par unité de surface de sol. Il s'agit d'une variable biophysique clé dans le suivi de la dynamique de la végétation (Jonckheere et al., 2004 ; Watson, 1947a, 1947b ; Weiss et al., 2004). Une vingtaine de photos hémisphériques sont prises par parcelle en utilisant un objectif « Fisheye » avec un champ de vue en azimut  $360^\circ$  et en zénith  $180^\circ$ . Selon les travaux de Wilson, 1963, nous pouvons calculer l'indice foliaire à un angle de vue de  $57.5^\circ$ . En partant de ce principe, les images hémisphériques sont traitées ultérieurement pour classer les pixels des images en végétation ou en sol et calculer une valeur moyenne par parcelle LAI  $57.5^\circ$ .

La **Figure 30** illustre les résultats des traitements et de la classification des pixels des images hémisphériques dans des parcelles de blé dans la plaine de Kairouan. La couleur noire indique la présence de la végétation caractérisée par sa couleur verte et la couleur blanche caractérise le sol nu.



**Figure 30.** Exemple illustratif des images hémisphériques acquises sur des parcelles test de blé à différentes phases physiologiques avec les résultats des traitements pour calculer l'indice foliaire.

Avec la maturation de la végétation, la couleur vire du vert vers le jaune. Par conséquent, les valeurs LAI diminuent et la végétation est classée comme étant un sol nu. Durant la première campagne 2019/2020, les valeurs LAI des céréales varient entre 0.31 et 4.5. Sur les parcelles des piments, les valeurs LAI fluctuent entre 0.07 et 1.75.

#### b. Hauteur de végétation (H)

Au niveau de chaque parcelle des céréales ou des piments, 20 mesures de la hauteur sont faites, bien réparties spatialement. La moyenne des hauteurs est calculée par parcelle. Selon le **Tableau 2**, les hauteurs des céréales peuvent atteindre 1 mètre vers la fin du mois de février. Durant la campagne du printemps 2022, la hauteur maximale du blé est de l'ordre de 1.17 m. Pour les cultures maraîchères, la hauteur maximale des piments ne dépasse pas 0.65m (**Tableau 2**).

#### c. Contenu en eau (VWC)

La mesure du contenu en eau de la végétation se base sur un prélèvement des échantillons de végétation fraîche en surface. Les limites de cet échantillonnage sont définies par un cadre en bois de surface  $30 \times 30 \text{ cm}^2$ . Les mesures du contenu en eau n'ont concerné que les céréales. Nous avons effectué 3 prélèvements par parcelle tout en pesant la matière fraîche collectées. Ultérieurement, les échantillons sont séchés à l'étuve à  $80^\circ\text{C}$  pendant 72 heures et repesés une autre fois comme étant matière sèche. Le calcul du contenu en eau s'effectue selon cette formule en termes de kilogramme d'eau par  $\text{m}^2$  de surface :

$$VWC = \frac{Mf - Ms}{S} \quad (24)$$

$Mf$  = poids de la matière fraîche,  $Ms$  = poids de la matière sèche et  $S$  = superficie du cadre en bois. Au long de la période de la campagne 2019/2020, le contenu en eau n'a pas dépassé 1.09 Kg d'eau / $\text{m}^2$  contrairement aux valeurs enregistrées en printemps 2022 qui couvre la deuxième moitié du cycle du blé où les valeurs  $VWC$  varient entre 1.16 et 5.43 Kg d'eau / $\text{m}^2$ . Nous avons observé les valeurs les plus élevées du  $VWC$  durant mi-avril 2022. Cette période concorde avec le palier hydrique du blé.


### II.2.2. Données satellites

#### II.2.2.1. Données SAR

##### a. Données en bande L : ALOS-2

La première génération des satellites, développé par l'agence japonaise et opérant en bande L, a commencé avec le lancement du satellite JERS-1 « Fuyo-1 » en 1992. Ses observations globales ont contribué dans le suivi des dynamiques continentales.

En 2006, le satellite Advanced Land Observing Satellite (ALOS) a pris le relais pour contribuer dans la gestion des risques (Rosenqvist et al., 2014 ; Suzuki et al., 2012). Successivement au satellite ALOS, le satellite Advanced Land Observing Satellite 2 (ALOS-2), également nommé DAICHI-2, est lancé en 24 mai 2014 par l'agence japonaise JAXA au centre de l'espace Tanegashima au Japon à une altitude de 628 Km. Il est équipé d'un capteur PALSAR-2 opérant en bande L à des différents modes d'observation : Spotlight, Stripmap et ScanSAR (**Figure 31**).



**Figure 31.** Différents modes d'acquisition des images ALOS-2 (Stripmap, ScanSAR et Spotlight) et leurs caractéristiques (Japan Aerospace Exploration Agency : JAXA).

Le mode Stripmap est le mode d'imagerie de base. La fauchée est éclairée par un faisceau. Ce dernier est pointé à un angle fixe en élévation et en azimuth. La taille de la fauchée éclairée dépend du mode d'observation en Stripmap, l'intervalle des angles d'incidence et de la polarisation par exemple 50-55 Km pour les résolutions de 3 et 6 m à des angles d'incidence entre 8 et 70° en monopolarisation ou bipolarisation et entre 42.5° et 70 Km pour la résolution de 10 m (Kankaku et al., 2013 ; Rosenqvist et al., 2014 ; Suzuki et al., 2012).

Les données d'ALOS-2 sont systématiques et cohérentes dans le temps et dans l'espace selon un scénario d'observation de base (BOS). Ce scénario BOS est révisé périodiquement pour répondre aux demandes des utilisateurs avec un taux de succès des acquisitions entre 70 et 80% (projet JAXA/ALOS-2, 2017). Les données en bande L utilisées sont acquises en Stripmap sur le site d'étude avec une fréquence d'observation de 14 jours et une résolution spatiale de 6 × 6m en deux polarisations Horizontale-Horizontale (HH) et Horizontale-Verticale (HV) à deux angles d'incidence 28° et 32.5°.



Les images Alos-2 programmées sont calibrées pour convertir les valeurs digitales en coefficients de rétrodiffusion en linéaire. Cette correction est suivie par un géoréférencement en utilisant la méthode des 30 points amères. L'erreur de cette spatialisation est inférieure à 0.5 pixel et en se basant sur une image NDVI calculée à partir des images optiques Sentinel-2. Afin de réduire l'effet du chatoiement, nous avons calculé la moyenne des coefficients de rétrodiffusion ( $\sigma_{HH}^0$ ) et ( $\sigma_{HV}^0$ ) par parcelle de référence. Le **Tableau 4** détaille la configuration des images acquises sur la plaine de Kairouan.

**Tableau 4.** Caractéristiques des images ALOS-2 acquises sur la plaine de Kairouan durant l'année agricole 2019/2020 et les images supplémentaires acquises en 11/2014, 11/2015 et en 2016.

Date	Paramètres du capteur			
	Capteur	Angle d'incidence	Polarisations	Ascendant/Descendant
20/11/2014	ALOS-2	36°	HH + HV	-
19/11/2015	ALOS-2	36°	HH + HV	-
05/03/2016	ALOS-2	28°	HH + HV	-
26/11/2016	ALOS-2	28°	HH + HV	-
26/10/2019	ALOS-2	28°	HH + HV	Ascendant
09/11/2019	ALOS-2	28°	HH + HV	Ascendant
23/11/2019	ALOS-2	28°	HH + HV	Ascendant
07/12/2019	ALOS-2	28°	HH + HV	Ascendant
04/01/2020	ALOS-2	28°	HH + HV	Ascendant
01/02/2020	ALOS-2	28°	HH + HV	Ascendant
15/02/2020	ALOS-2	28°	HH + HV	Ascendant
25/05/2020	ALOS-2	32.5°	HH + HV	Descendant
08/06/2020	ALOS-2	32.5°	HH+HV	Descendant
22/06/2020	ALOS-2	32.5°	HH+HV	Descendant
20/07/2020	ALOS-2	32.5°	HH+HV	Descendant
03/08/2020	ALOS-2	32.5°	HH+HV	Descendant
17/08/2020	ALOS-2	32.5°	HH+HV	Descendant

## b. Données en bande C : Sentinel-1

Dans le but de suivre la dynamique des surfaces continentales et océaniques, la mission SAR Sentinel-1 est initiée par la commission européenne (EC) et l'agence européenne de l'espace (ESA) pour acquérir des images en bande C à une fréquence égale à 5.405 GHz. Il s'agit d'une succession des missions précédentes en bande C la série ERS-1 et 2 de l'ESA et ENVISAT et les deux générations canadiennes RADARSAT-1 et 2.

Deux satellites Sentinel-1A et Sentinel-1B ont été mis en orbite le 03 avril 2014 et 25 avril 2016, respectivement par la fusée Soyuz et depuis le port spatial de l'Europe en Guyane. Ces deux satellites partagent la même orbite avec un déphasage orbitale de 180°. A une altitude de 693 Km, chaque constellation Sentinel-1 se caractérise par un cycle orbital de 12 jours avec 175 orbites par cycle à des angles d'incidence qui varient entre 20° et 45° et des polarisations différentes (VV+VH, HH+HV, HH et VV).

Le jumelage des deux satellites donne des images en bande C chaque 6 jours à différentes résolutions spatiales (largeur de fauchée) en fonction des modes d'acquisitions : Stripmap 5 × 5 m (80 Km), Interferometric Wide Swath 5 × 20 m (250 Km), Extra-Wide Swath 20 × 40 m (400 Km) et Wave-Mode 5 × 5 m (20 × 20 Km). Malheureusement, en Juillet 2022, la mission Sentinel-1 B a pris sa fin suite à une panne en décembre 2021. Par conséquent, depuis le début de 2022, nous avons des acquisitions en bande C chaque 12 jours en attendant le lancement de la constellation Sentinel-1 C à la fin de l'année 2023.

Les acquisitions des satellites Sentinel-1A et Sentinel-1B offrent des images en bande C à une fréquence de 6 jours en deux polarisations : VV (Verticale-Verticale) et VH (Verticale horizontale) pour les deux années 2018/2019 et 2019/2020 et une fréquence de 12 jours durant l'année 2021/2022. L'angle d'incidence à la zone de Merguellil est estimé au de 39°-40°. Les images Sentinel-1 sont acquises en modes Interferometric Wide swath (IW) en deux types de produits : Ground Range Data (GRD) et Single Look Complexe (SLC). Le **Tableau 5** décrit les produits Sentinel-1 utilisés dans les travaux de la thèse.

**Tableau 5.** Caractéristiques des images Sentinel-1 acquises sur la plaine de Kairouan durant les années agricoles (2018/2019, 2019/2020 et 2021/2022).

	Sentinel-1 A et B				
	Type du produit	Résolution des pixels Distance × azimuth (m)	Nombre des acquisitions	Orbite relative	Fréquence de revisite
2018 / 2019	SLC	2.3 × 13.9	60	88 et 95	6 jours
	GRD	10 × 10	60		
2019 / 2020	SLC	2.3 × 13.9	56		
	GRD	10 × 10	56		
2021 / 2022	SLC	2.3 × 13.9	38 (4 images S1-B)		12 jours
	GRD	10 × 10	38 (4 images S1-B)		

- Ground Range Data (GRD)

Les images GRD utilisées sont récupérées de la collection Copernicus de la plateforme Google Earth Engine (GEE) qui sont déjà traitées (<https://developers.google.com/earth-engine/guide/sentinell>). Les images acquises par les constellations Sentinel-1 subissent plusieurs traitements : application du fichier d'orbite, l'élimination du bruit des bordures et du bruit thermique, une calibration radiométrique et une correction terrain.

- Single Look Complexe (SLC)

Pour estimer la cohérence interférométrique, nous avons utilisé des images Sentinel-1 du type Single Look Complexe (SLC). Ces données préservent l'information en amplitude et en phase du signal radar. Les données SLC sont téléchargées de la plateforme d'exploitation des produits Sentinel (PEPS) géré par le CNES (<https://peps.cnes.fr/rocket/#/home>). Chaque acquisition est subdivisée en trois sous-bandes en deux polarisations : Verticale-Verticale (VV) et Verticale-Horizontale (VH). Chaque sous-bande est marquée par des bandes noires.

En utilisant la librairie d'outil Sentinel-1 du SNAP et selon les mêmes traitements de Frison et al., 2018 ; Ouaadi et al., 2020, 2021, nous avons d'abord sélectionné la sous-bande adéquate couvrant la zone d'étude. Ensuite, le fichier d'orbite est appliqué pour déterminer la position du satellite à une précision de 5 cm (Apply-orbit-file). Un co-enregistrement des deux images successivement acquises sur la même orbite (Back-Geocoding), est établi en utilisant un Modèle Numérique de Terrain (MNT) automatiquement téléchargé.

La cohérence interférométrique est estimée à partir des deux images géocodées à une fenêtre de  $15 \times 3$  (distance  $\times$  azimuth).

$$\rho_{pq} = \frac{|\sum_{i=1}^N z_i^* z_i'^*|}{\sqrt{\sum_{i=1}^N |z_i|^2 \sum_{i=1}^N |z_i'|^2}} \quad (25)$$

avec  $z_i$  et  $z_i'^*$  sont le nombre complexe et son conjugué, respectivement et des deux acquisitions et pq est la polarisation du capteur SAR utilisé (VV or VH dans notre cas).

Les bandes noires (Deburst) sont éliminées en procédant un TOPSAR Deburst. Finalement, la cohérence estimée est projetée en WGS 84/UTM zone 32N basé sur un MNT SRTM automatiquement téléchargé (Terrain Correction). Au niveau de chaque parcelle, la moyenne de la cohérence est calculée pour les polarisations VV et VH.

### II.2.2.2 Données optiques : Sentinel-2

Au service des applications dans les domaines d'agriculture, le suivi des écosystèmes, la gestion des forêts, des zones côtières ainsi que la qualité d'eau, les catastrophes et la sécurité civile, la mission Sentinel-2 est lancée dans le but d'acquérir des images dans le domaine optique (Drusch et al., 2012). Les deux satellites jumeaux, Sentinel-2A et Sentinel-2B, lancés en 23 juin 2015 et 7 Mars 2017, respectivement, sont mis en orbite par la fusée Vega à partir du site Guyanien.

Les satellites Sentinel-2 sont des instruments multispectraux à 13 bandes spectrales dont la résolution spatiale varie entre 10 m (quatre bandes), 20 m (six bandes) et 60 m (trois bandes). Les images Sentinel-2 sont produites à des différents niveaux allant de zéro jusqu'à 2A. Les produits des niveaux 1C et 2A sont orthorectifiés et projetés en WGS84/UTM selon des tuiles de  $110 \times 110$  Km. Chaque Sentinel-2 acquit les images tous les 10 jours.

Cette fréquence de revisite est estimée à 5 jours lorsque la revisite des deux satellites Sentinel-2A et Sentinel-2B est combinée. Grâce à la détection des nuages et la correction des effets atmosphériques par la chaîne MAJA (Hagolle et al., 2017), les images Sentinel-2 au niveau 2A sont disponibles aux usagers via le portail THEIA. Cette chaîne de correction en open source est développée conjointement par le CESBIO et le CNES. Plusieurs acquisitions ont été explorées durant les travaux de la présente thèse dont les caractéristiques sont détaillées dans le **Tableau 6**.

**Tableau 6.** Caractéristiques des images Sentinel-2 acquises sur la plaine de Kairouan durant les années agricoles (2018/2019, 2019/2020 et 2021/2022).

	Sentinel-2 A et B		
	Nombre des acquisitions	Orbite relative	Fréquence de revisite
2018-2019	35	22 et 122	5 jours
2019-2020	39		
2021-2022	30		


### II.2.3. Produits satellitaires opérationnels d'humidité de surface

Dans la littérature, il existe plusieurs produits opérationnels d'humidité de surface du sol dans le domaine des micro-ondes. Dans le dernier chapitre, nous avons examiné les produits d'humidité de surface du sol à haute résolution à partir des données Sentinel-1 et Sentinel-2 (HRSM) et des données SMAP.

#### II.2.3.1. Produits HRSM

Les produits HRSM fournissent une spatialisation des estimations de l'humidité du sol à une profondeur de 5 cm dans des parcelles exclusivement des zones agricoles ou des prairies. Les humidités sont estimées à une échelle parcellaire en utilisant l'algorithme « Sentinel Soil Moisture Mapping S<sup>2</sup>MP » développé par El Hajj et al., 2017 à partir des données Sentinel-1 ascendant et Sentinel-2. Cet algorithme est basé sur l'inversion du WCM couplé avec IEM en utilisant le réseau des neurones artificielles (ANN). Sur la zone d'étude, les produits HRSM sont générés en se basant sur la carte d'occupation de sol à une résolution de 100 m (CGLS-LC100) produite par le service d'occupation de sol globale de Copernicus. Ces produits sont caractérisés par une résolution horizontale de 1 Km × 1 Km et une disponibilité toutes les 6 jours.

En totale 289 produits HRSM font l'objet des analyses de l'humidité de surface sur les trois quarts de la Tunisie sur une période depuis 01/01/2017 jusqu'à Juin 2022. Les valeurs des humidités de surface du sol varient entre 5 et 30 vol.%. La **Figure 32** est un exemple illustratif de la variation des humidités durant des dates proches du mois d'avril durant quatre années 2017, 2019, 2020 et 2022.



**Figure 32.** Illustration des produits HRSM en Tunisie pour le mois d'avril sur quatre années (2017, 2019, 2020 et 2022).

### II.2.3.2. Produits SMAP

Dans le but d'examiner le potentiel des produits HRSM, nous avons opté de les comparer avec d'autres produits opérationnels de SMAP. Sur la même période depuis 01/01/2017 jusqu'à Juin 2022, nous avons récupéré les données L3 SMAP acquises sur la zone d'étude. Avec une incertitude de  $\pm 4 \text{ vol.}\%$ , l'humidité du sol à une profondeur de 5 cm est estimée à partir du radiomètre opérant en bande L dont la fréquence est 1.41 GHz. Ces mesures d'humidité sont valides pour le couvert végétal dont le contenu en eau ne dépasse pas  $5 \text{ Kg.m}^{-2}$ . Le produit d'humidité de sol est un composite quotidien valable après 50 heures de l'acquisition avec une résolution spatiale de 36 Km. Il existe d'autres produits opérationnels SMAP d'humidité dont les résolutions spatiales varient entre 3 et 9 Km correspondant aux composites des données radar et de la synergie des données radar-radiomètre. Dans les travaux de thèse, nous avons utilisé les produits composites d'humidité du sol du niveau L3 à une résolution de 36 Km. Sur le site d'étude, nous avons réussi à récupérer 3946 produits en fonction du temps acquisitions le matin (AM) et le soir (PM). Autrement, nous avons analysé 1973 produits AM et 1973 produits PM.

### II.3. Conclusions

Dans ce chapitre, nous avons présenté la zone d'étude dans ses cadres géographique, géologique, climatique, pédologique et hydrologique. De plus, nous avons exposé les problématique hydrologique et hydrogéologique de la zone ainsi que son potentiel agricole. Tous ces facteurs ont permis de la choisir comme un site observatoire et témoin pour optimiser la gestion des ressources hydriques. Dans ce contexte, nous avons opté à examiner le potentiel des données radars disponibles pour estimer le contenu en eau du sol en se basant sur des données in-situ dans la plaine de Kairouan.

Plusieurs campagnes ont été coordonnées durant l'année 2019/2020 pour suivre le cycle du blé comprenant des mesures de la rugosité, l'humidité et les variables biophysiques de la végétation. Malheureusement, l'arrivée de la pandémie COVID durant le développement de la végétation nous a obligé à arrêter le suivi. A l'été de 2020, une nouvelle campagne était conduite pour suivre une végétation saisonnière : les piments. Le manque des données en bande L acquises par ALOS-2 et la continuité de la pandémie nous a empêché de continuer le suivi du cycle des céréales. A partir de Mars 2022, une campagne supplémentaire dans des parcelles de blé a été lancée pour remédier au manque des données.

La base de données satellites est composée des images radars en bande L acquises par ALOS-2 et en bande C acquises par Sentinel-1 A et B et des données optiques acquises par Sentinel-2 A et B. La base de données a été renforcée par des produits opérationnels d'humidité de surface HRSM et SMAP.

Toutes ces données font l'objet de plusieurs travaux détaillés dans les prochains chapitres. Ces derniers visent l'examen du potentiel des données radar pour estimer l'humidité surfacique du sol et l'apport d'une série temporelle des produits opérationnels d'humidité du sol pour interpréter la variabilité climatique sur le territoire Tunisien.

## Chapitre III

---

# Comparaison du potentiel des données en bandes C et L pour estimer l'humidité de surface du sol à une échelle parcellaire

---

*Ayari, E. ; Kassouk, Z. ; Lili-Chabaane, Z. ; Baghdadi, N. ; Bousbih, S. ; Zribi, M. Cereal Crops Soil Parameters Retrieval Using L-Band ALOS-2 and C-Band Sentinel-1 Sensors. Remote Sens. 2021, 13, 1393. <https://doi.org/10.3390/rs13071393>.*

*Ayari, E. ; Kassouk, Z. ; Lili-Chabaane, Z. ; Baghdadi, N. ; Zribi, M. Investigation of Multi-Frequency SAR Data to Retrieve the Soil Moisture within a Drip Irrigation Context Using Modified Water Cloud Model. Sensors 2022, 22, 580. <https://doi.org/10.3390/s22020580>.*



# Chapitre III

## Comparaison du potentiel des données en bandes C et L pour estimer l'humidité de surface du sol à une échelle parcellaire

---

### III.1. Introduction

Durant les dernières décennies, plusieurs efforts ont été alloués pour estimer le contenu en eau du sol avec le minimum d'incertitude. La quantification de cette variable a été basée d'ores et déjà sur des mesures in-situ ponctuelles qui sont incapables de restituer la variabilité spatiotemporelle du contenu en eau du sol. En se basant sur les mesures satellites, l'inversion des données radar est l'une des approches couramment utilisées. Après le lancement de la mission Sentinel-1, la plupart des travaux d'estimation d'humidité du sol ont été développés en utilisant les données en bande C. Des nouvelles missions en bande L sont planifiées dans le futur, ce qui nous a incités à explorer le potentiel de ces données. Dans le cadre de cette thèse, nous avons évalué le potentiel des données en bandes C et L pour estimer les humidités de surface du sol à une échelle parcellaire. L'évaluation des données bi-fréquence a été menée en deux contextes de répartition spatiales de l'humidité du sol : un contexte homogène de grandes cultures sur des parcelles couvertes par des céréales et un contexte hétérogène sur des parcelles couvertes par des cultures en rangs.

Le présent chapitre se scinde en deux parties principalement. La première partie est consacrée à l'approche développée afin d'estimer l'humidité du sol homogènement répartie dans les parcelles des céréales. Ainsi, le potentiel des données en bande C acquises par Sentinel-1 et en bande L acquises par ALOS-2 a été comparée en utilisant cette approche. Cette dernière est détaillée dans l'article suivant : « Ayari, E., Kassouk, Z., Lili-Chabaane, Z., Baghdadi, N., Bousbih, S., & Zribi, M. (2021). *Cereal crops soil parameters retrieval using L-band ALOS-2 and C-band sentinel-1 sensors. Remote Sensing, 13(7), 1393.* »

Nous nous sommes intéressés dans la deuxième partie à la sensibilité des simulations du signal radar à la répartition spatiale de l'humidité et la structure de la végétation dans un contexte

d'hétérogénéité spatiale de l'humidité du sol et le couvert végétal. Cette analyse est détaillée dans l'article suivant : « *Ayari, E., Kassouk, Z., Lili-Chabaane, Z., Baghdadi, N., & Zribi, M. (2022). Investigation of multi-frequency SAR data to retrieve the soil moisture within a drip irrigation context using modified water cloud model. Sensors, 22(2), 580.* »

Dans chaque partie de ce chapitre, nous avons présenté un récapitulatif des travaux avec les articles détaillant les résultats et leurs discussions.

## III.2. Estimation de l'humidité sur sols couverts par des céréales

### III.2.1. Résumé

Afin d'investiguer le potentiel des données en bandes C et L pour estimer l'humidité de sol, des campagnes de collecte des données in-situ ont été conduites sur des parcelles de référence dans la plaine de Kairouan au centre de la Tunisie simultanément aux passages des satellites. Ces mesures comprennent des mesures de rugosité, humidité du sol et des variables biophysiques de la végétation telles que l'indice foliaire, la hauteur et le contenu en eau des céréales. Les images satellites utilisées sont acquises en bande L par le satellite ALOS-2 en co-polarisation Horizontale-Horizontale (L-HH) et en cross-polarisation Horizontale-Verticale (L-HV) et en bande C par les satellites Sentinel-1 en polarisations Verticale-Verticale (C-VV) et en Verticale-Horizontale (C-VH).

Dans une première étape, des analyses de sensibilité des coefficients de rétrodiffusion en fonction des mesures in-situ ont été menées. Une fonction logarithmique relie les variables statistiques de rugosité  $H_{rms}$  et  $Z_s$  aux coefficients de rétrodiffusion. A des valeurs d'humidité du sol inférieures à 10 vol.%, les signaux radar en co-polarisation, L-HH et C-VV, sont fortement impactés par la rugosité de surface avec des coefficients de corrélation supérieurs à 0.7. En utilisant les données en bande L à une polarisation HV et à des différents angles d'incidence entre 28° et 36°, le signal radar est plus impacté par la rugosité de la surface du sol qu'en utilisant les mesures radar en bande C à une polarisation VH et à un angle d'incidence de 39°.

Concernant l'humidité du sol, les analyses de sensibilité sont menées en fonction de trois classes NDVI renseignant sur le développement de la végétation ( $NDVI \leq 0.3$ ,  $0.3 < NDVI < 0.6$  et  $NDVI \geq 0.6$ ). A des conditions de semis, les données en bande L à un angle d'incidence de 28° sont plus sensibles aux mesures in-situ des humidités de surface du sol par rapport aux données en bande C. Pour le cas des couverts denses, les coefficients de rétrodiffusion L-HH et L-HV restent sensibles à l'humidité de surface avec des sensibilités de 0.19 et 0.16 dB/vol.%,


respectivement. La sensibilité des données radar aux variables biophysiques des céréales se caractérise par un comportement contradictoire des signaux en bandes C et L. Cette différence est associée à la capacité du signal en bande L à pénétrer la végétation plus que le signal en bande C.

La simulation du signal radar, dans une seconde étape, s'est faite sur des sols nus et des sols couverts. Pour les sols nus, nous avons comparé le potentiel des modèles Dubois modifié par Baghdadi (Dubois-B), IEM modifié par Baghdadi (IEM-B) et des expressions empiriques en fonction de l'humidité et des variables statistiques de rugosité  $h(Mv, Zs)$  et  $g(Mv, Hrms)$ . En se basant sur la comparaison des modèles de simulation des données radar, nous avons utilisé le modèle IEM-B avec les données en co-polarisation (L-HH et C-VV) et l'équation calibrée et validée  $g(Mv, Hrms)$  pour la base de données entière.

Par la suite, ces modèles sélectionnés sont couplés au Water Cloud Model (WCM) pour simuler le comportement du signal sur les parcelles couvertes en céréales. Le WCM est la somme de la contribution de la végétation, la contribution du sol nu atténuée par la végétation et la contribution des interactions sol-végétation. Dans la plupart des travaux, le terme d'interaction sol-végétation a été négligé. Dans le présent travail, on a testé deux options du WCM : dans la première option, on néglige le terme des interactions sol-végétation et la deuxième option on le considère. La description de la végétation a été introduite dans le WCM en utilisant les valeurs NDVI calculés à partir des données optiques Sentinel-2.

La calibration et la validation des paramètres du WCM sont menées en utilisant 70% et 30% de la base de données, respectivement. Pour estimer l'humidité du sol, les deux options du WCM sont inversées. Les résultats de l'inversion sont illustrés dans la **Figure 33**. En considérant la première option du WCM couplé au IEM-B et les données en co-polarisation, les RMSE varient entre 3.35 vol.% et 4.87 vol.% en utilisant C-VV et L-HH, respectivement. En utilisant l'équation empirique pour simuler le signal sur le sol nu, les RMSE passent à 4.74 vol.% et 6.44 vol.% en utilisant C-VV et L-HH.

L'intégration du terme d'interaction sol-végétation a amélioré l'estimation de l'humidité en utilisant les données radar en cross-polarisation (L-HV et C-VH). En effet, le RMSE a diminué de 13.68 vol.% à 6.81 vol.% en utilisant L-HV face à une amélioration moins importante avec les données C-VH où les RMSE décroît de 7.11 vol.% à 6.75 vol.%.



**Figure 33.** Résultats d'inversion des deux options du WCM couplées aux IEM-B et g(Mv, Hrms) exprimés en RMSE (vol.%) en utilisant les données en bande L (L-HH et L-HV) et en bande C (C-VV et C-VH).

### III.2.2. Article



## Article

# Cereal Crops Soil Parameters Retrieval Using L-Band ALOS-2 and C-Band Sentinel-1 Sensors

Emna Ayari <sup>1,2</sup> , Zeineb Kassouk <sup>2</sup> , Zohra Lili-Chabaane <sup>2</sup>, Nicolas Baghdadi <sup>3</sup> , Safa Bousbih <sup>1,2</sup> and Mehrez Zribi <sup>1,\*</sup>

<sup>1</sup> CESBIO, Université de Toulouse, CNRS/UPS/IRD/CNES/INRAE, 18 av. Edouard Belin, bpi 2801, CEDEX 9, 31401 Toulouse, France; ayari.emna.inat@gmail.com (E.A.); safabousbih1@outlook.fr (S.B.)

<sup>2</sup> Institut National Agronomique de Tunisie, Université de Carthage, LR 7AGR01 GREEN-TEAM. 43 Avenue Charles Nicolle, Tunis 1082, Tunisia; kassouk.zeineb@gmail.com (Z.K.); Zohra.LiliChabaane@inat.u-carthage.tn (Z.L.-C.)

<sup>3</sup> CIRAD, CNRS, INRAE, TETIS, University Montpellier, AgroParisTech, CEDEX 5, 34093 Montpellier, France; nicolas.baghdadi@teledetection.fr

\* Correspondence: mehrez.zribi@ird.fr; Tel.: +33-56155-8525

**Abstract:** This paper discusses the potential of L-band Advanced Land Observing Satellite-2 (ALOS-2) and C-band Sentinel-1 radar data for retrieving soil parameters over cereal fields. For this purpose, multi-incidence, multi-polarization and dual-frequency satellite data were acquired simultaneously with in situ measurements collected over a semi-arid area, the Merguellil Plain (central Tunisia). The L- and C-band signal sensitivity to soil roughness, moisture and vegetation was investigated. High correlation coefficients were observed between the radar signals and soil roughness values for all processed multi-configurations of ALOS-2 and Sentinel-1 data. The sensitivity of SAR (Synthetic Aperture Radar) data to soil moisture was investigated for three classes of the normalized difference vegetation index (NDVI) (low vegetation cover, medium cover and dense cover), illustrating a decreasing sensitivity with increasing NDVI values. The highest sensitivity to soil moisture under the dense cover class is observed in L-band data. For various vegetation properties (leaf area index (LAI), height of vegetation cover (H) and vegetation water content (VWC)), a strong correlation is observed with the ALOS-2 radar signals (in HH(Horizontal-Horizontal) and HV(Horizontal-Vertical) polarizations). Different empirical models that link radar signals (in the L- and C-bands) to soil moisture and roughness parameters, as well as the semi-empirical Dubois modified model (Dubois-B) and the modified integral equation model (IEM-B), over bare soils are proposed for all polarizations. The results reveal that IEM-B performed a better accuracy comparing to Dubois-B. This analysis is also proposed for covered surfaces using different options provided by the water cloud model (WCM) (with and without the soil–vegetation interaction scattering term) coupled with the best accuracy bare soil backscattering models: IEM-B for co-polarization and empirical models for the entire dataset. Based on the validated backscattering models, different options of coupled models are tested for soil moisture inversion. The integration of a soil–vegetation interaction component in the WCM illustrates a considerable contribution to soil moisture precision in the HV polarization mode in the L-band frequency and a neglected effect on C-band data inversion.

**Keywords:** radar; ALOS-2; L-band; Sentinel-1; C-band; soil moisture; soil roughness; vegetation; water cloud model



**Citation:** Ayari, E.; Kassouk, Z.; Lili-Chabaane, Z.; Baghdadi, N.; Bousbih, S.; Zribi, M. Cereal Crops Soil Parameters Retrieval Using L-Band ALOS-2 and C-Band Sentinel-1 Sensors. *Remote Sens.* **2021**, *13*, 1393. <https://doi.org/10.3390/rs13071393>

Academic Editor: John J. Qu

Received: 26 February 2021

Accepted: 31 March 2021

Published: 4 April 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/>).

## 1. Introduction

Soil moisture is a key parameter for various processes in the continental water cycle. It plays an essential role in the separation of precipitation between runoff, infiltration and evaporation from surfaces. It is also a key parameter in water resource management, especially in the estimation of irrigation needs and monitoring of flood events [1–6]. Considerable effort has been devoted to estimate soil moisture in a context of limited contribution of punctual ground measurements.

Over the last thirty years, remote sensing has shown a high potential to retrieve soil moisture. Operational algorithms have also been principally proposed using low-spatial resolution microwave radiometer or scatterometer instruments. In the L-band, satellites such as Soil Moisture and Ocean Salinity (SMOS) and Soil Moisture Active Passive (SMAP) have demonstrated a strong potential for soil moisture retrieval, with a spatial resolution ranging between 25 and 36 km by a revisit time of up to one day [7,8]. Scatterometers, such as ASCAT [9], have provided different products principally based on change detection algorithms. These low-resolution products are particularly adapted to global and regional applications [10].

SAR (Synthetic Aperture Radar) high-resolution data have been particularly adapted to estimate soil moisture at the agricultural field scale. In the last three decades, many experimental and theoretical research studies have proposed methodologies to retrieve soil moisture [11–25]. These studies are based on a succession of radar missions, mainly in the C- and X-bands (ERS, ASAR/ENVISAT, RADARSAT-1, RADARSAT-2, TERRASAR-X, SKYMED, Sentinel-1, etc.).

For bare soils, different models have been proposed to understand and characterize the relationship between radar signals and soil properties, i.e., soil moisture and surface roughness are generally estimated by statistical parameters such as root mean square height (Hrms) and correlation length (Lc). Among these models, there are empirical [26,27] and semi-empirical approaches, such as Dubois and Oh models [28,29], and physical approaches that consider different types of physical approximations, such as the small perturbation model, Kirchhoff [30] or the integral equation model [31], which are the most frequently used by the scientific community. These models have been tested and validated by numerous scientific studies [32–35]. These studies have demonstrated the limitations of these different models, especially for characterizing scattering over surfaces with a high roughness. Different approaches have been proposed to improve these simulations. Baghdadi et al. [36,37] replaced in the IEM-B version the correlation length by a fitting parameter function of Hrms, incidence angle, polarization and radar wavelength.

For surfaces with vegetation cover, backscattering analysis should consider the effect of vegetation cover in addition to that of soil. In this framework, different models have been developed to simulate the radar signal scattered by the surface. These are physical models such as the Karam model [38], Michigan microwave canopy scattering (MIMCS) [39] or semi-empirical or empirical models. The most known among the latter is the water cloud model (WCM) proposed by Attema and Ulaby in 1978 [40].

The WCM considers the total backscattering signal as the sum of a first component, soil scattering attenuated with the vegetation effect, a second component, vegetation volume scattering, and, finally, a third term describing the interactions between soil and vegetation. This last component is generally neglected in scientific studies that use the WCM [30]. For this model, vegetation effect quantification requires the use of vegetation biophysical properties such as leaf area index (LAI), vegetation water content (VWC) or vegetation height (H) [41–44]. In this context, for an operational objective, spectral indices calculated from optical images such as the normalized difference vegetation index (NDVI) are often considered for this description [27,42]. Several studies have highlighted the strong contribution of the synergy of radar and optical data to properly characterize the scattering of surfaces with vegetation cover [45,46]. However, this approach has some limitations due to the saturation of optical indices and is unable to reproduce all the dynamics of vegetation cover with high density levels [45].

The inversion of the radar signal to estimate the soil water content at the agricultural plot scale is essentially based on three types of approaches: (1) a direct inversion approach of the backscattering models described above [47,48], (2) an approach based on machine learning approaches, notably through the use of neural networks [49–51] and (3) approaches that use change detection techniques [52–54].

With the arrival of the Sentinel 1 and 2 Copernicus constellations, these approaches have been tested by several scientific studies. The authors of [55] proposed approaches for

the direct inversion of S1 data using backscatter models. They illustrated accuracies on the order of 5 vol.%. However, this methodology remains relatively fragile in applications outside the calibration sites of the model's parameters. The authors of [51] proposed an algorithm based on neural networks and learning using the coupling of the IEM-B and WCM models. This approach provides soil moisture estimates with an accuracy on the order of 5 vol.% for surfaces with NDVI < 0.7. The authors of [52] proposed an adapted high-resolution approach to change detection, illustrating a precision on the order of 6 vol.%. At a scale of 1 km, [53] also proposed an operational approach based on this change detection technique, and operational products have already been available across Europe.

Most of those approaches considered for backscatter model validation or radar data inversion to retrieve land surface parameters are mainly based on data acquired in the C- and X-bands. Concerning the L-band, data availability remains relatively limited to a few space missions, notably the ALOS and ALOS-2 Japanese missions. In the near future, different L-band missions, such as NISAR and ROSE-L, should be launched. One of the objectives of these missions is to contribute to improving the estimation of land surface parameters, notably soil moisture. Many studies have been proposed to analyze the L-band data potential over agricultural surfaces [56–62]. The authors of [56] used fully polarized L-band airborne observations to evaluate the IEM, Dubois and Oh backscatter models. The authors of [59] investigated and confirmed the potential of ALOS-2 L-band data in retrieving soil moisture even for dense vegetation (NDVI > 0.7). The authors of [61], in a tropical context, tested the WCM on covered fields using the LAI parameter for vegetation effect simulation. An accuracy of 6.7 vol.% for HH(Horizontal-Horizontal) polarization and 7.9 vol.% for HV(Horizontal-Vertical) polarization was reported over marigold crop fields. For turmeric crop fields, RMSE values ranged between 8.7 and 11 vol.% for HH and HV polarization, respectively. They particularly illustrated its high sensitivity to soil moisture even for vegetation with LAI > 2.5. The authors of [58] developed an approach based on polarimetric decomposition over many cultures, leading to RMSE values between 6 and 8 vol.%.


The use of L-band signals still needs to be explored, especially in terms of the potential of the L-band to retrieve surface parameters, compared to that of the C-band. This work aims to contribute to a better understanding of the potential of L-band compared to C-band radar data in terms of sensitivities to soil and vegetation properties, as well as their inversion for retrieving soil moisture. It discusses the scattering behavior, particularly the term of interaction between soil and vegetation often neglected in experimental studies. It focuses on cereal fields. Section 2 of this paper describes the study site and collected satellite and in situ database. Section 3 details the methodology proposed in this study. Section 4 presents the results and discussions in three parts: sensitivity analysis of radar data to surface parameters, simulation of radar signals using backscattering models and inversion applications to retrieve soil moisture over cereal fields. The conclusions are gathered in Section 5.

## 2. Study Zone Description and Database

### 2.1. Study Zone Description

The study was performed on the Merguellil Plain (9°23'–10°17'E, 35°1'–35°55'N), which is a flat landscape covering 3000 km<sup>2</sup> (Figure 1). It is classified as a semiarid zone with a rainy season ranging from September to April and a summer season with almost no rainfall. The mean annual precipitation is 300 mm per year. The average temperature in the coldest months (December, January and February) is 11 °C and can reach 30 °C in summer. The reference evapotranspiration is estimated to be 1600 mm according to the Penman method. The main land use is cereal, olive tree and market garden crops. The plain is a basin that was fed by surface water infiltration before the construction of the El Haouareb and Sidi Saad dams at the level of the Merguellil and Zeroud rivers, respectively. Moreover, it is the confluence zone of several underground water tables

(Bouhaffna, Haffouz–Cherichira and Ain El Bidha) that drain into the Sabkhet El Kalbia outlet [63].



**Figure 1.** (a) Location of study site in the Merguellil area (dashed rectangle colored in red) in central Tunisia. (b) Reference fields on the study site (in the front RGB colored map derived from a Sentinel-2 image).

## 2.2. Dataset Description

### 2.2.1. Radar Images

#### (a) ALOS-2 Radar Data

Multi-incidence images were acquired by the Advanced Land Observing Satellite-2 (ALOS-2) using the L-band SAR antenna Phased Array Synthetic Aperture Radar (PAL-SAR), which was launched by the Japan Aerospace Exploration Agency (JAXA), with a revisit cycle frequency of  $1/14 \text{ days}^{-1}$ . The ALOS-2 images used, in the strip map operation mode, offer a spatial resolution of  $6 \times 6 \text{ m}$  in dual polarizations HH (horizontal–horizontal) and HV (horizontal–vertical) and various incidence angles ( $28^\circ$ ,  $32.5^\circ$  and  $36^\circ$ ). Table 1 summarizes the main characteristics of the L-band SAR images recorded at the Kairouan site.

Images were radiometrically corrected to convert the digital values into backscatter coefficients on a linear scale. This correction was followed by georeferencing according to the UTM projection system, using the control point method, referenced on an NDVI image calculated from the Sentinel 2 optical images. The root mean square (RMSE) control point error is close to 0.5 pixels.

#### (b) Sentinel-1 Constellation Radar Data

Owing to the launch of the Sentinel-1 A (S-1 A) on 3 April 2014 and Sentinel-1 B (S-1 B) on 25 April 2016, C-band SAR images are available with a revisit cycle frequency of 6 days in dual-polarization VV (vertical–vertical) and VH (vertical–horizontal) modes, with an incidence angle of approximately  $39^\circ$ . In the present study, we used seven images in the interferometric wide swath mode (IW) with a spatial resolution of  $10 \times 10 \text{ m}$ , as described in Table 1.

Acquired level 1 ground range detected (GRD) images were processed to derive backscattering coefficients in each pixel through the following steps: thermal noise removal, radiometric calibration followed by terrain correction and speckle filtering (Lee filter).



**Table 1.** Radar parameters of satellite images acquired in 2014–2016, 2019 and 2020 (incidence angle, polarization, path, spatial resolution, acquisition mode and ascending or descending).

Date	Sensor Parameters					
	Sensor	Angle	Polarizations	Pixel Spacing	Mode	Ascending/ Descending
20/11/2014	ALOS-2	36°	HH + HV	6 × 6 m	Strip Map	-
19/11/2015	ALOS-2	36°	HH + HV	6 × 6 m	Strip Map	-
05/03/2016	ALOS-2	28°	HH + HV	6 × 6 m	Strip Map	-
26/11/2016	ALOS-2	28°	HH + HV	6 × 6 m	Strip Map	-
26/10/2019	ALOS-2	28°	HH + HV	6 × 6 m	Strip Map	Ascending
27/10/2019	Sentinel-1	39°	VV + VH	10 × 10 m	Interferometric wide swath	Ascending
09/11/2019	ALOS-2	28°	HH + HV	6 × 6 m	Strip Map	Ascending
09/11/2019	Sentinel-1	39°	VV + VH	10 × 10 m	Interferometric wide swath	Descending
23/11/2019	ALOS-2	28°	HH + HV	6 × 6 m	Strip Map	Ascending
07/12/2019	ALOS-2	28°	HH + HV	6 × 6 m	Strip Map	Ascending
20/12/2019	Sentinel-1	39°	VV + VH	10 × 10 m	Interferometric wide swath	Ascending
04/01/2020	ALOS-2	28°	HH + HV	6 × 6 m	Strip Map	Ascending
13/01/2020	Sentinel-1	39°	VV + VH	10 × 10 m	Interferometric wide swath	Ascending
01/02/2020	ALOS-2	28°	HH + HV	6 × 6 m	Strip Map	Ascending
01/02/2020	Sentinel-1	39°	VV + VH	10 × 10 m	Interferometric wide swath	Descending
15/02/2020	ALOS-2	28°	HH + HV	6 × 6 m	Strip Map	Ascending
01/02/2020	Sentinel-1	39°	VV + VH	10 × 10 m	Interferometric wide swath	Descending
24/02/2020	Sentinel-1	39°	VV + VH	10 × 10 m	Interferometric wide swath	Ascending
25/05/2020	ALOS-2	32.5°	HH + HV	6 × 6 m	Strip Map	Descending

### 2.2.2. Sentinel-2 Optic Data

Optical images were acquired by Sentinel-2A, launched on 23/06/2015, and Sentinel-2B, launched on 07/03/2017. They offer images with a 10 m resolution and a passage frequency of 1/5 days<sup>-1</sup>. S2 surface reflectance images, cloud free selected, were downloaded from the THEIA-LAND site and orthorectified and corrected for atmospheric effects using the MAJA processor for cloud detection and atmospheric correction (<https://www.theia-land.fr>, accessed on 31 March 2021).

The NDVI vegetation index, expressed as  $NDVI = (RNIR - RRED)/(RNIR + RRED)$ , where RNIR is the near-infrared (NIR) reflectance and RRED is the red reflectance, was calculated from the optical images. The NDVI pixel values were then averaged for each reference field and each acquisition date [27,45,55].

### 2.2.3. In Situ Measurements

In situ campaigns were carried out at the same time as the ALOS-2 acquisitions (two dates in 2014/2015, two dates in 2016 and eight dates in 2019/2020) and Sentinel-1 satellite acquisitions (7 dates in 2019/2020). Seventeen reference fields were considered with 8 bare soil fields with different types of roughness, ranging from smooth to ploughed surfaces, and 9 irrigated cereal fields. The surface areas of these study fields ranged between 0.5 and 7 ha.

The in situ measurements made in the test fields involved the characterization of the following parameters: moisture and roughness measurements were carried out for the soil characterization, and LAI, VWC and H vegetation property measurements were recorded for the fields with vegetation cover. Table 2 provides details of the dates of the field campaigns and the corresponding types of measurement.

## (a) Roughness

Roughness is a measure of microtopographic height variations at the soil surface. This was characterized by means of a 1-m-long pin profiler with a resolution equal to 2 cm. Six roughness profiles, 3 parallel and 3 perpendicular to the tillage row direction, were established in all reference fields during three different ground campaigns. The test fields are totally flat and homogenous with soil tillage with very limited directional structures. The proposed number of profiles is a priori sufficient to allow an accurate estimation of the roughness, as shown by [27] over the same site.

Two main surface roughness parameters, Hrms and Lc, were determined from the mean height correlation function, which was computed from the digitized soil profiles [64]. Significant variations in the values of Hrms were observed between successive ground campaigns, ranging from 0.46 (very smooth soils) to 6.46 cm (ploughed soils), resulting mainly from the influence of rain and cultural practices (tillage, sowing, etc.).

## (b) Soil Moisture (Mv)

Soil moisture measurements were collected from each reference field at 20 randomly distributed points using a hand-held Theta probe for each considered date. These moisture measurements were calibrated by gravimetric measurements recorded during previous campaigns simultaneously over the same reference fields [45]. During the missions, moisture measurements were taken at the same image acquisition time with a time lag of approximately 2 h in order to limit any temporal variation in soil water content. In the case of the presence of precipitations or irrigations exactly during the satellite acquisitions, the data are generally not considered because the temporal variations could be very strong on a very limited duration. The recorded volumetric values varied between 3.0 vol.% issued in dry conditions and 42.9 vol.% in wet conditions due to precipitation or irrigation (Table 2).

## (c) Vegetation Parameters

- Vegetation Heights (H):

In each cereal plot, 20 height measurements were taken, which were well distributed spatially. The height values reached 1 m towards the end of February during the stem extension growth stage.

- Leaf Area Index (LAI):

LAI is defined as the total one-sided area of leaf tissue per unit ground surface area. According to this definition, LAI is dimensionless. For each reference field, we considered approximately twenty hemispherical digital images, which were processed to retrieve this vegetation parameter based on the vegetation gap fraction [27]. LAI measurements were performed during the 2019–2020 agricultural season. During all measurement campaigns, the computed value of LAI ranged between 0 and 4.5 (Table 2). The highest values of LAI were observed mainly in the irrigated reference fields.

- Vegetation Water Content (VWC):

Measurement of the water content of the vegetation was based on fresh surface vegetation sampling. The spatial limits of this sampling were defined by a wooden frame. We took 3 samples per plot and weighed the fresh material collected. The samples were dried in an oven at 80 °C for 72 h and reweighed again as dry matter. The water content was calculated according to the following equation in terms of kilograms of water per m<sup>2</sup> of surface area:

$$\text{VWC} = \frac{Wf - Ws}{s} \quad (1)$$

where  $Wf$  is the weight of the fresh material,  $Ws$  is the weight of the dry vegetation and  $s$  is the surface area of the wooden frame. The obtained values ranged between 0.07 kg of water/m<sup>2</sup> at the start of the cycle to 1.09 kg of water/m<sup>2</sup> in February.

**Table 2.** In situ measurements (min-max) during campaigns from 2014 to 2020 with the roughness parameters (root mean square height (Hrms), correlation length (Lc)), soil moisture (Mv) and cereal parameters (vegetation height (H), leaf area index (LAI) and vegetation water content (VWC)).

Date	Measurements					
	Hrms (cm)	Lc (cm)	Mv (vol.%)	H (cm)	LAI (m <sup>2</sup> /m <sup>2</sup> )	VWC (kg/m <sup>2</sup> )
20/11/2014	[1.10–3.52]	[2.83–6.86]	[3.0–9.3]	-	-	-
19/11/2015	[0.56–4.34]	[2.48–8.89]	[5.2–9.6]	-	-	-
05/03/2016	[0.56–3.24]	[2.48–7.69]	[4.5–8.7]	-	-	-
26/11/2016	[0.49–4.55]	[2.87–9.58]	[10.2–42.9]	-	-	-
26/10/2019	[0.46–6.46]	[3.45–10.11]	[6.6–25.5]	-	-	-
27/10/2019	[0.46–6.46]	[3.45–10.11]	[5.8–30.5]	-	-	-
09/11/2019	-	-	[13.6–30.1]	-	-	-
23/11/2019	-	-	[6.0–23.9]	-	-	-
07/12/2019	[0.46–6.46]	[2.8–10.11]	[9.1–30.4]	-	-	-
20/12/2019	[0.46–4.55]	[2.8–10.11]	[7.6–28.5]	[16.8–41.3]	[1.20–2.83]	[0.1–0.9]
04/01/2020	-	-	[4.5–25.9]	[20–49.6]	[0.9–3.1]	[0.1–0.9]
13/01/2020	-	-	[6.5–32.8]	[10.7–53.5]	[0.7–3.62]	-
01/02/2020	-	-	[4.6–28.2]	[15.2–83.2]	[0.31–4.06]	[0.07–0.9]
15/02/2020	-	-	[3.7–32.1]	[25.6–100]	[0.8–4.50]	-
24/02/2020	[0.46–4.55]	[0.8–10.11]	[5.9–33.1]	[28.1–105]	[1.1–4.03]	[0.13–1.09]
25/05/2020	[0.46–3.95]	[2.8–10.11]	[3.4–21.2]	-	-	-

### 3. Methodology

In this section, we present different backscattering models that are validated by our ground truth collected data in the Results section. In the case of bare soils, different empirical, semi-empirical and physical backscattering models are considered. In the case of surfaces with vegetation coverage, the water cloud model (WCM) with various options is discussed.

#### 3.1. Bare Soil Backscattering Models

##### 3.1.1. Empirical Relationships

Empirical models used to characterize the relationship between the backscattering coefficients  $\sigma$  and soil surface parameters are presented as follows:

$$\sigma_{\text{bare soil.pq}}^0 = g(\text{Mv}, \text{Hrms}) = \alpha_{\text{pq}} * \text{Mv} + \beta_{\text{pq}} * \text{Log}(\text{Hrms}) + \gamma_{\text{pq}} \quad (2)$$

$$\sigma_{\text{bare soil.pq}}^0 = h(\text{Mv}, \text{Zs}) = \alpha'_{\text{pq}} * \text{Mv} + \beta'_{\text{pq}} * \text{Log}(\text{Zs}) + \gamma'_{\text{pq}} \quad (3)$$

where Mv is the soil moisture (vol.%), Hrms is the root mean square of heights (cm), pq is the radar polarization and  $\alpha_{\text{pq}}$ ,  $\beta_{\text{pq}}$  and  $\gamma_{\text{pq}}$  and  $\alpha'_{\text{pq}}$ ,  $\beta'_{\text{pq}}$  and  $\gamma'_{\text{pq}}$  are constants requiring calibration and validation.

The roughness effect is introduced by a logarithmic regression between the Hrms or Zs parameter, defined as  $\text{Hrms}^2/\text{Lc}$  [26], and the radar signal. This empirical relation is generally considered to be logarithmic because of the strong saturation of the radar signal for high roughness levels [30].

##### 3.1.2. Dubois Calibrated Model (Dubois-B)

The Dubois model is a semi-empirical model applied for copolarized radar signals over bare soils. Its input variables include radar parameters (polarization, incidence angle and wavelength), soil moisture and roughness Hrms measurements [28]. The Dubois model validity range includes soil moisture values <35 vol.%, k.Hrms value <2.5 and incidence angles  $\Theta > 30^\circ$ .

A modified version of the Dubois model (Dubois-B) was proposed by [65] in the three polarizations of HH, VV and HV to minimize the discrepancy between simulated and real

backscattering coefficients. For HH, VV and HV polarizations, expressions are written as follows:

$$\sigma_{HH}^0 = 10^{-1.287} * (\cos \theta)^{1.227} * 10^{0.009 * \cotan(\theta) * Mv} * (k.Hrms)^{0.86 * \sin \theta} \quad (4)$$

$$\sigma_{VV}^0 = 10^{-1.138} * (\cos \theta)^{1.528} * 10^{0.008 * \cotan(\theta) * Mv} * (k.Hrms)^{0.71 * \sin \theta} \quad (5)$$

$$\sigma_{HV}^0 = 10^{-2.325} * (\cos \theta)^{-0.01} * 10^{0.011 * \cotan(\theta) * Mv} * (k.Hrms)^{0.44 * \sin \theta} \quad (6)$$

where  $k$  is the wavenumber, which is equal to  $2\pi/\lambda$ ,  $\lambda$  is the wavelength,  $\theta$  is the incidence angle in radian,  $Mv$  is in vol.% and  $Hrms$  is in cm.

### 3.1.3. IEM-B Model

The IEM, proposed by [31], is a physical model. It calculates the backscattering coefficient over bare soils. Its inputs include the dielectric constant retrieved from soil moisture and the height correlation function (exponential or Gaussian), as well as the radar parameters (polarization, wavelength and incidence angle). The IEM validity range is limited by  $k.Hrms > 3$ .

The IEM is expressed as [31]

$$\sigma_{pp}^0 = \frac{k^2}{2} e^{-2k_z^2 s^2} \sum_{n=1}^{+\infty} s^{2n} \left| I_{pp}^n \right|^2 \frac{W^{(n)}(-2k_x, 0)}{n!} \quad (7)$$

where  $\sigma_{pp}^0$  is the backscattering coefficient at pp polarization,  $\theta$  is the radar incidence angle,  $k$  is the wavenumber,  $k_z = k \times \cos(\theta)$ ,  $k_x = k \times \sin s(\theta)$ , and  $s$  is the root mean surface height.  $I_{pp}^n$  is a function of the radar incidence angle, the relative dielectric constant of the soil  $\epsilon_r$ , and the Fresnel reflection coefficient.  $W^{(n)}(-2k_x, 0)$  is the Fourier transform of the  $n$ th power of the surface correlation function.

Despite the important contribution of this model to simulations with high-precision backscattering over bare soils, different studies have shown some limitations in adequately describing soil geometry [33–35], particularly for high roughness levels. Over the years, many studies have updated versions of the IEM to minimize discrepancies with SAR backscattered coefficients over natural areas. The authors of [66] proposed a modified advanced integrated equation model (AIEM) by considering a transitional model to calculate the Fresnel reflection coefficient. Other improvements were focused on the IEM inputs. Correlation length ( $L_c$ ) measurements are, in general, uncertain. The authors of [36] replaced  $L_c$  with an optimized parameter,  $L_{opt}$ , that was directly linked to the  $Hrms$  roughness parameter in the IEM-B version in the C-band (Equations (8) and (9)):

$$L_{opt}(Hrms.\theta.VV) = 1.281 + 0.134 * (\sin(0.19 * \theta))^{-0.159} * Hrms \quad (8)$$

$$L_{opt}(Hrms.\theta.HV) = 0.9157 + 2.6590 * (\sin(0.1543 * \theta))^{-0.3139} * Hrms \quad (9)$$

In the L-band, the authors of [37] used a fitting parameter,  $L_{opt}$ , for HH polarization and a Gaussian correlation function, as shown in equation (10):

$$L_{opt}(Hrms.\theta.HH) = 2.6590 * \theta^{-1.4493} + 3.0484 Hrms * \theta^{-0.8044} \quad (10)$$

### 3.2. Water Cloud Model (WCM) Backscattering Model over Vegetation Cover

The WCM was used to model the radar signal backscattered for vegetation-covered surfaces. Vegetation is described as a set of identical, spherical water droplets characterized by their density and canopy height [40]. The total backscattering coefficient  $\sigma^0$  is expressed as follows:

$$\sigma_{pq}^0 = \sigma_{vegetation,pq}^0 + \sigma_{soil-vegetation,pq}^0 + \tau^2 \sigma_{soil,pq}^0 \quad (11)$$

where  $\sigma_{\text{vegetation}}^0$  is the vegetation contribution component and  $\tau^2$  is the two-way vegetation attenuation of the bare soil backscattering coefficient  $\sigma_{\text{soil}}^0$ . Multi-backscattering effects are considered in the term  $\sigma_{\text{soil-vegetation}}^0$ .

$$\tau^2 = \exp(-2 * B * V1 * \sec \theta) \quad (12)$$

$$\sigma_{\text{vegetation,pq}}^0 = A * V2 * \cos \theta * (1 - \tau^2) \quad (13)$$

where A and B are parameters that depend on the characteristics of the vegetation canopy and V1 and V2 are vegetation descriptors. The impact of the choice of descriptors was discussed in [67]. In the present case, we consider the NDVI, which is strongly related to the vegetation parameters, as shown in Section 2.

The multi-scattering term is generally neglected in experimental studies, and total backscattering is then written as follows:

$$\sigma_{\text{pq}}^0 = \sigma_{\text{vegetation,pq}}^0 + \tau^2 \sigma_{\text{soil,pq}}^0 \quad (14)$$

However, a number of studies have illustrated the importance of the multi-scattering term, notably in HV polarization. The authors of [15] considered the following term, describing the coherent interaction between the canopy and ground:

$$\sigma_{\text{soil-vegetation,pq}}^0 = 2 * k_s * (d * R_{\text{pq}} * \tau^2) \quad (15)$$

where  $k_s$  is the volume scattering coefficient,  $d$  is the canopy depth and  $R_{\text{pq}}$  is the Fresnel reflectivity in the pq polarization mode.

In this study, we propose an approximation of this term by considering a third term to calibrate:

$$\sigma_{\text{soil-vegetation,pq}}^0 = C_{\text{pq}} * V2 * \tau^2 * (1 - \tau^2) * \cos \theta * 10^{\left(\frac{\alpha * Mv}{10}\right)} \quad (16)$$

in which the  $C_{\text{pq}}$  parameter is dependent on the characteristics of the vegetation cover, and the  $\alpha$  parameter is estimated directly from the linear relationship between the radar signal and soil moisture in dB/vol.%.

In this approximation, the formulation of the volume scattering coefficient is deduced from Expression (12), V2 is the vegetation descriptor, directly related to the canopy depth, and, finally, the expression of the Fresnel coefficient is expressed from the relationship between the soil moisture and radar signal.

### 3.3. Statistical Parameters for Accuracy Assessment

Datasets were subdivided into two parts: 70% of the database for model calibration, and 30% for validation. The training data were used to calculate the different parameters to be estimated in the empirical and semi-empirical models.

The root mean square error (RMSE) and bias were considered to estimate the precision of the models.

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=0}^N (P_i^{\text{estimated}} - P_i^{\text{measured}})^2} \quad (17)$$

$$\text{Bias} = \frac{1}{N} \sum_{i=0}^N (P_i^{\text{estimated}} - P_i^{\text{measured}}) \quad (18)$$

where N is the number of data samples,  $P_i^{\text{estimated}}$  is the estimated value of sample  $i$  and  $P_i^{\text{measured}}$  is the measured value of sample  $i$ .


## 4. Results and Discussion

### 4.1. Relationship between NDVI and Vegetation Parameters

Analysis of the optical data potential was conducted by plotting the NDVI index as a function of the vegetation parameters measured in the test field (Figure 2). The

NDVI values covered an interval starting from 0.2 for cereals after sowing to values of approximately 0.8 at the stem extension phase.

The NDVI values show moderate correlations with R values of 0.74 and 0.59 for H and VWC, respectively. Figure 2 illustrates this strong relationship between NDVI and LAI, generally considered for modeling of the vegetation backscattering contribution, with a high correlation equal to 0.79. We consider NDVI as a key parameter for describing vegetation cover, basing on the results observed in many other studies [42,51], in the remainder of this study, concerning backscattering and inversion models.



**Figure 2.** Relationship between LAI in situ measurements and normalized difference vegetation index (NDVI) derived from Sentinel 2 images.

#### 4.2. Sensitivity of Radar Signal to Surface Properties

##### 4.2.1. Sensitivity to Soil Roughness

Signal behavior is strongly influenced by soil roughness and moisture. Figure 3 shows the sensitivity of L-band SAR data as a function of roughness parameters (Hrms and Zs). To avoid the impact of soil moisture on this backscattering behavior, we analyzed the relationship between the roughness and radar signal only with moisture values less than 10 vol.%. Table 3 details the statistical correlation coefficients for all relationships between roughness parameters (Hrms and Zs) and the dual-frequency radar signals with ALOS-2 in dual polarizations HH and HV according to three incidence angles (28°, 32.5° and 36°) and Sentinel-1 data in VV and VH polarizations at a 39° incidence angle.

**Table 3.** Statistics of relationships between radar signal and roughness parameters (Hrms and Zs), for L-HH and L-HV (ALOS-2), at three incidence angles, 28°, 32.5° and 36°, and for C-VV and C-VH (Sentinel-1), at a 39° incidence angle where soil moisture values are under 10 vol.%.


Sensor	ALOS-2			Sentinel-1				
	Polarization	L-HH	L-HV	C-VV	C-VH			
Incidence Angle	28°	32.5°	36°	28°	32.5°	36°	39°	39°
$R(\sigma^0 = f(\text{Hrms}))$	0.86	0.93	0.83	0.77	0.83	0.82	0.85	0.56
$R(\sigma^0 = f(\text{Zs}))$	0.87	0.92	0.7	0.73	0.82	0.75	0.88	0.55

Using the Hrms parameter, high correlation coefficients ranging between 0.83 and 0.93 in L-HH multi-incidence data and between 0.77 and 0.83 in L-HV multi-incidence data can be observed. Using the Zs parameter, correlation coefficients between 0.7 and 0.92 are observed for the multi-incidence L-HH data and between 0.73 and 0.82 for the L-HV data. We observe approximately the same level of correlation for the two roughness parameters. We also observe a range of radar signals related to the variation in roughness approximately equal to 10 dB and 8 dB for L-HH and L-HV, respectively.

For Sentinel-1 C-VV data, we observe high correlation coefficients equal to 0.88 and 0.85 for the  $Z_s$  and  $H_{rms}$  parameters, respectively. A lower level of correlation is observed for the C-VH data, where the  $R$  values reach a maximum of 0.56 for the same roughness range.

Different reasons can degrade the correlation observed between the radar signals and the roughness parameters: the absence of information on the shape of the height correlation function, the complexity of the scattering for strong roughness levels and, finally, the possible uncertainties in the roughness ground measurements.

Under low-soil moisture conditions, according to Table 3, we observe a signal dynamic due to soil roughness approximately equal to 8 dB and 6 dB for C-VV and C-VH, respectively, which is close to the observed range in [27]. This could give more weight to the use of L-band data in mapping soil practices and, at the same time, be considered a probable, more important noise factor in estimating soil moisture from L-band radar data.



**Figure 3.** ALOS-2 radar data ( $28^\circ$  incidence angle) as a function of roughness parameters  $Z_s$  and  $H_{rms}$ . (a)  $Z_s$  and HH polarization, (b)  $H_{rms}$  and HH polarization, (c)  $Z_s$  and HV polarization, (d)  $H_{rms}$  and HV polarization.

#### 4.2.2. Sensitivity to Soil Moisture

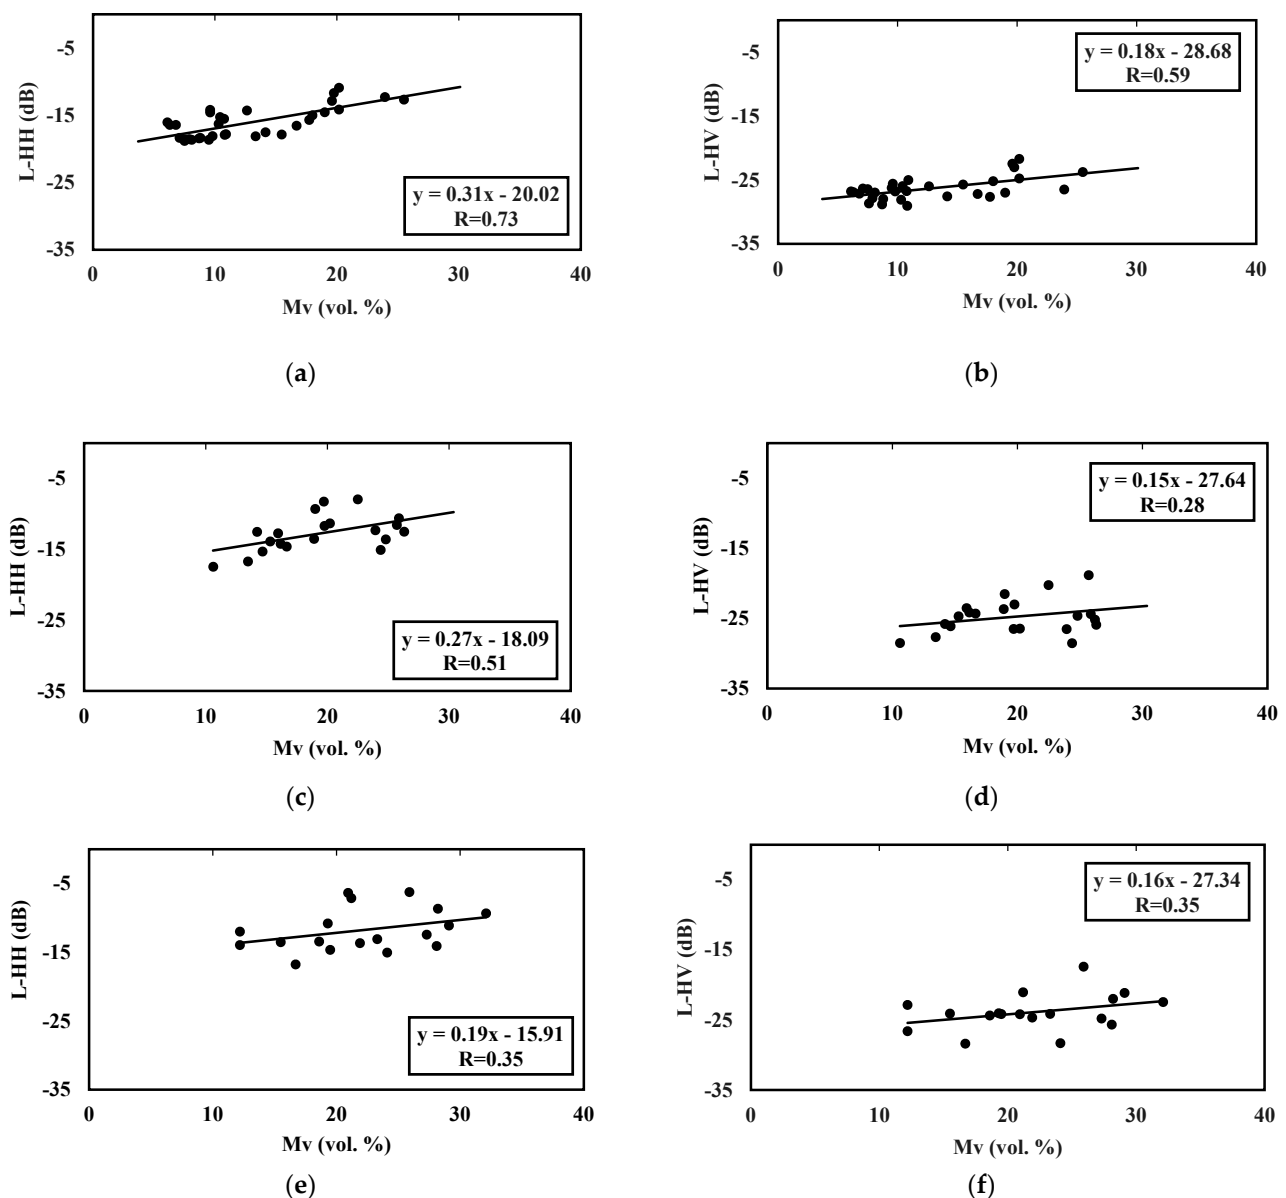
In this section, we analyze the sensitivity of L- and C-band radar data to soil moisture. In this context, to avoid the vegetation cover effect, we consider three classes of vegetation: a first class of bare soil or very dispersed vegetation ( $NDVI < 0.3$ ), a second class with medium density ( $0.3 < NDVI < 0.6$ ) and, finally, a third class with dense vegetation ( $NDVI > 0.6$ ). Only surfaces after tillage for cereal sowing, with approximately the same roughness, are considered in this analysis to avoid other effects due to roughness for bare soils.

Figure 4 illustrates the relationships found for the L-HH and L-HV data for the three considered classes. We first observe a decrease in the sensitivity of the radar signal to soil moisture with an increase in vegetation cover for both polarizations. This sensitivity decreases by 0.31 and 0.18 dB/vol.% ( $NDVI < 0.3$ ) to 0.27 and 0.15 dB/vol.% for  $NDVI$

values between 0.3 and 0.6 and finally to 0.19 and 0.16 dB/vol.% (NDVI > 0.6) in HH and HV, respectively. All statistics are also illustrated in Table 4.

The moisture sensitivity is generally lower for HV polarization, which could be explained by the volume scattering effect in the cross-polarization case, especially in the presence of the canopy. This last result is generally observed by experimental scientific studies [27,44]. For the densest canopies (NDVI > 0.6), the sensitivity of L-HH data to soil moisture remains significant. However, the correlation is weak ( $R = 0.35$ ), which makes the conclusion about the sensitivity of the radar signal to moisture rather fragile.

In the C-band, Table 4 shows that the sensitivity of the radar signal to soil moisture decreased by 0.26 and 0.24 dB/vol.% to 0.17 and 0.08 dB/vol.% for the vegetation medium density class and finally to 0.07 and 0.09 dB/vol.% for the denser canopy classes in VV and VH, respectively.



**Figure 4.** ALOS-2 radar data as a function of soil moisture: NDVI < 0.3 (HH (a); HV (b)), 0.3 < NDVI < 0.6 (HH (c); HV (d)) and NDVI > 0.6 (HH (e); HV (f)).

The inter-comparison of the results obtained for the L- and C-bands shows a higher sensitivity of the L-band in HH polarization to soil moisture for the high density covered soils (0.19 dB/vol.% for L-HH configuration and 0.07 dB/vol.% for C-VV configuration).



In the case of HV polarization, a lower sensitivity to soil moisture is generally observed for all tested configurations. This is particularly due to the effect of stronger volume scattering in cross-polarization.

In all studied cases, the correlations observed for all configurations remain relatively moderate even in the case of bare soil. This could be explained, in particular, by the effect of the surface roughness, illustrated earlier in this section. These results are in agreement with other studies [59–62].

In the case of tropical crops (marigold and turmeric), [61] confirmed the strong sensitivity of the L-band radar signal to soil moisture for LAI values greater than 2.5. The authors of [60] also observed a high potential of L-band data in HH polarization to penetrate wheat and grassland covers, even where NDVI > 0.7.

These results confirm the contribution of L-band data compared to C-band data in estimating soil moisture, especially in the densest canopies.

**Table 4.** Radar data linear relationship as a function of soil moisture for ALOS-2 data in dual polarizations HH and HV at a 28° incidence angle and for Sentinel-1 data in VV and VH polarizations at an approximately 39° incidence angle.

Sensor	ALOS-2				Sentinel-1			
	L-HH		L-HV		C-VV		C-VH	
Configuration	Slope (dB/vol.)	R	Slope (dB/vol.)	R	Slope (dB/vol.)	R	Slope (dB/vol.)	R
Parameters								
NDVI ≤ 0.3	0.31	0.73	0.18	0.59	0.26	0.56	0.24	0.47
0.3 < NDVI < 0.6	0.27	0.51	0.15	0.28	0.17	0.59	0.08	0.33
NDVI ≥ 0.6	0.19	0.35	0.16	0.35	0.07	0.20	0.09	0.37

#### 4.2.3. Sensitivity of Radar Signal to Vegetation Parameters

In this section, we evaluate the sensitivity of ALOS-2 and S-1 radar data as a function of vegetation parameters (VWC, LAI and H). To limit the effect due to soil moisture, we considered data at only high moisture levels (greater than 20 vol.%). In this context, the radar signal is close to saturation with respect to the effect of soil moisture. Figure 5 represents radar signals and L-HH, L-HV, C-VV and C-VH data as a function of vegetation parameters under the considered wet soil moisture conditions.

Despite a relatively limited number of samples (between 9 and 13 samples), a sensitivity of the radar signal to canopy properties is observed with ALOS-2 SAR data for both L-HH and L-HV configurations. This sensitivity is relatively the same for both polarizations. The correlation is weaker for the L-HV configuration than for the L-HH configuration. This could be explained particularly by the complex volume scattering behavior observed in the HV polarization mode.

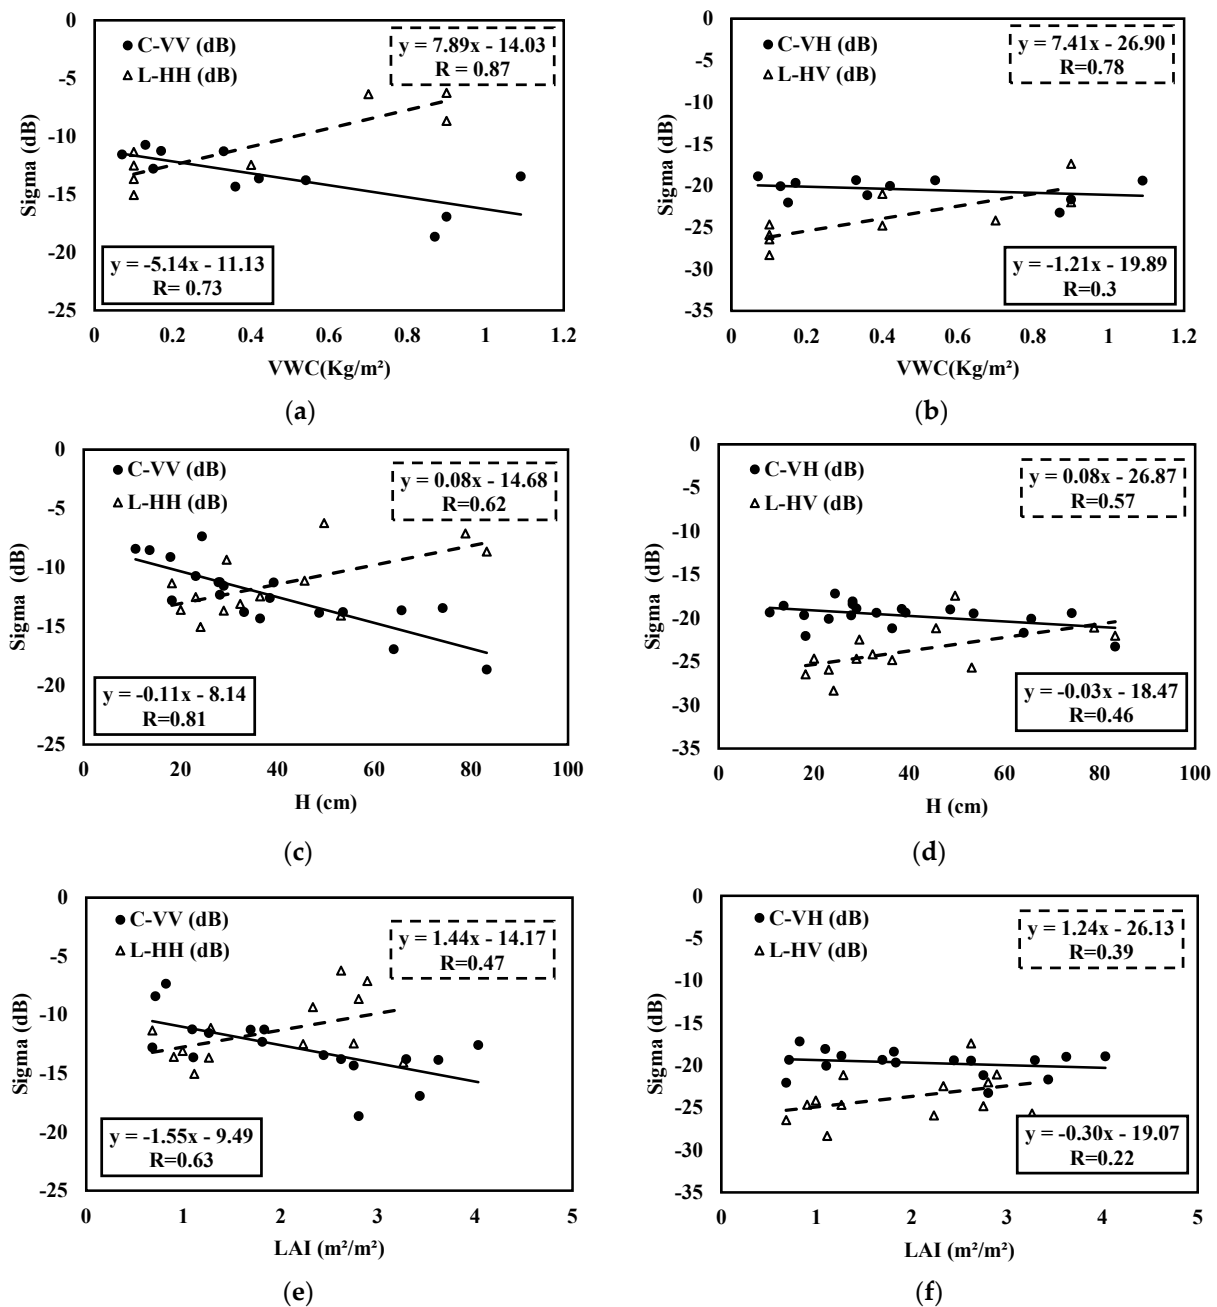
The L-band trends show the strongest correlation with VWC, with R values equal to 0.87 and 0.78 in the HH and HV polarizations, respectively, followed by height and then LAI (Figure 5).

The L-band data have a higher penetration of radar waves into the canopy compared to C data. Therefore, the correlation with LAI, which displays information more related to leaf superior cover without information about the cover structure, is weakest.

An increase in the L-HH radar signal is observed with increasing cereal canopy parameters. This trend has already been observed, in particular, in [59] over wheat fields, where the L-HH signal increases as a function of LAI and vegetation height. In contrast to the VV polarization data, which illustrate a decrease in the radar signal for the first period of growth due to a strong attenuation of the signal over cereals with vertical geometry, the HH polarization data show weak attenuation and then a more dominant contribution due to volumetric scattering. This behavior with a decrease in the radar signal with the growth of the vegetation cover is clearly observed in the S1 data (Figure 5) and in other studies using X-band data [68]. However, we also observe in different studies a reversal of the trend with the development of cereals, probably related to a stronger dominance of volume scattering [69].

In contrast to the L-band data, a moderate correlation is observed between the radar signals in the C-VV configuration and LAI parameter ( $R$  equal to 0.63). This result is consistent with other past studies performed with S1 data. This correlation remains relatively strong for the other vegetation parameters ( $H$  and  $VWC$ ). However, the C-VH data illustrate a weak correlation with the different vegetation parameters analyzed, with an  $R$  value less than 0.46.

Comparing the cross-polarization results for the L- and C-bands, we note that different behaviors are mainly attributed to penetration depths with different contributions of volume scattering and sensor configurations, such as incident angles, since we worked on the same cereal fields.



**Figure 5.** Radar data as a function of vegetation parameters using linear regression with continuous line for C-band data and dashed line for L-band data: (a) L-HH (ALOS-2) and C-VV (Sentinel-1) as a function of VWC, (b) L-HV and C-VH as a function of VWC, (c) L-HH and C-VV as a function of vegetation height ( $H$ ), (d) L-HV and C-VH as a function of  $H$ , (e) L-HH and C-VV as a function of LAI, (f) L-HV and C-VH.

### 4.3. Simulations of Radar Backscattering Coefficients

In this section, after a relatively simple analysis of radar signals' sensitivities to the different surface parameters, separately, the objective is to use different backscattering models for a global analysis of relationships between surface parameters and multi-configuration radar signals. Simulations concern two different types of land use: bare soil and soil covered by cereals.


#### 4.3.1. Case of Bare Soils

In this section, we first validate the Dubois-B and IEM-B models using our multi-incidence, multi-polarization and dual-frequency database acquired on bare soil.

Figure 6 illustrates the results retrieved for L-band data for the two tested models. For the L-HH configuration, we observe a better consistency between the data and the IEM-B model compared to the results obtained using the semi-empirical Dubois-B model. For the three incidence angles ( $28^\circ$ ,  $32.5^\circ$  and  $36^\circ$ ), the simulations in the L-HH configuration show an RMSE lower than 2.1 dB with IEM-B, while with Dubois-B, the RMSE is between 2.4 and 2.7 dB. Table 5 gives statistical parameters regarding the comparison between the measured ALOS-2 data and simulated L-band signal with the IEM-B and Dubois-B models in dual polarization. In the L-HV configuration, the IEM-B model presents very low performances compared to the L-HH results for the three incidence angles with RMSE values between 3.2 and 4.5 dB.

As illustrated in Figure 7 and Table 5, IEM-B and Dubois-B exhibit the best performances with the C-VV data configuration, with RMSE values between 1.3 and 1.5 dB, respectively. For the C-VH configuration, we note a high discrepancy between simulations and real data, with RMSE values equal to 1.7 and 2.3 dB for the IEM-B and Dubois-B models, respectively, and bias exceeding  $-3.5$  dB.

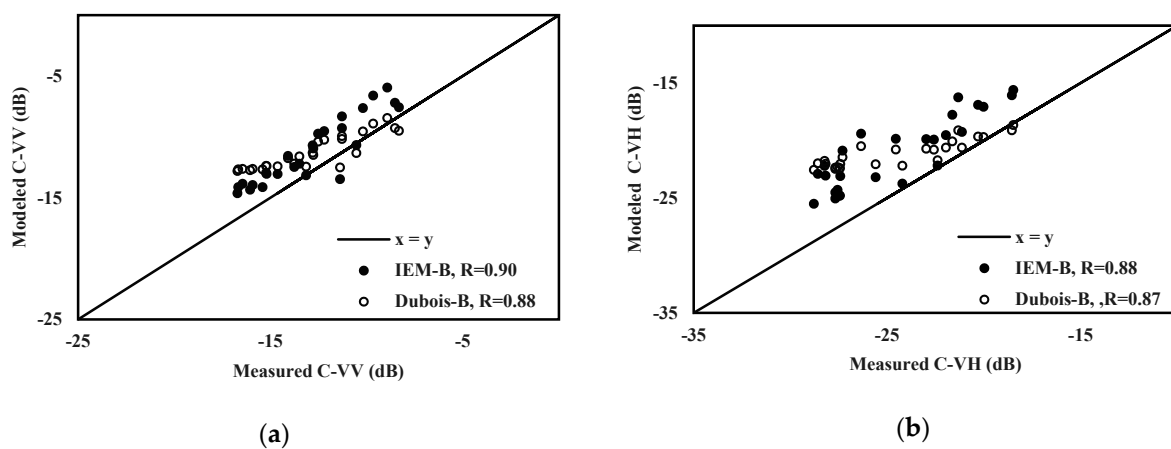
Based on these results, only the IEM-B model in the polarizations (HH and VV) is considered further in the simulation of the scattered signal from the bare soil coupled with the WCM model. The other simulations of IEM-B and Dubois-B are considered too degraded to contribute to the overall simulation of the total radar signal over a surface with vegetation cover.



**Figure 6.** Comparison between modeled (with Dubois-B and IEM-B) and measured radar backscattering coefficients in L-band: (a) L-HH, (b) L-HV. Only incidence angle of  $28^\circ$  is illustrated.

**Table 5.** Statistical precision coefficients with IEM-B and Dubois-B models for ALOS-2 data (L-HH and L-HV) and Sentinel-1 data (C-VV and C-VH).

Model		IEM-B				Dubois-B			
Configuration		L-HH		L-HV		L-HH		L-HV	
Statistic parameter (dB)		Bias	RMSE	Bias	RMSE	Bias	RMSE	Bias	RMSE
ALOS-2	28°	1.3	2.0	0.3	3.2	−0.4	2.5	−2.5	2.9
	32.5°	0.5	1.9	−0.6	3.3	−1.7	2.7	−2.7	2.3
	36°	2.0	2.1	5.6	4.5	−0.5	2.4	−2.6	2.7
Configuration		C-VV		C-VH		C-VV		C-VH	
Statistic parameter (dB)		Bias	RMSE	Bias	RMSE	Bias	RMSE	Bias	RMSE
Sentinel-1	39°	−1.8	1.3	−3.5	1.7	−1.6	1.5	−3.4	2.3

**Figure 7.** Comparison between modeled (with Dubois-B and IEM-B) and measured radar backscattering coefficients: (a) C-VV, (b) C-VH.

The empirical expressions proposed in Section 3.1.1. are tested on the 39° incidence angle Sentinel-1 data and 28° incidence angle L-band data acquired during 2019–2020. The use of empirical equations first requires parameter calibration. In this context, the actual dataset is divided randomly into two parts: the first part for model calibration (70% of the data) and 30% for empirical model validation.


Table 6 illustrates the calibration parameters and statistical precision (RMSE and R) between the calibrated empirical expressions (Equations (2) and (3)) and L-band data considered for calibration. The calibrated relationship  $h(M_v, Z_s)$  between the radar signal and the  $M_v$  and  $Z_s$  parameters shows RMSE values equal to 1.2 dB in L-HH and 1.0 dB in L-HV. On the other hand, for the  $g(M_v, Hr_{rms})$  calibrated relationship, RMSEs of 1.4 dB in L-HH and 1.0 dB in HV are retrieved.

Empirical models are also tested for Sentinel-1 data, showing high accuracy in simulating signals over bare soils. In the C-VV configuration, RMSE values are equal to 1.2 dB and 1.3 dB using  $g(M_v, Hr_{rms})$  and  $h(M_v, Z_s)$  relationships, respectively. In the C-VH polarization, RMSE values are equal to 1.3 dB for the  $h(M_v, Z_s)$  case and 1.4 dB for the  $g(M_v, Hr_{rms})$  case, where R is approximately 0.89 and 0.9, respectively. The results show very similar accuracies with the two empirical expressions  $h$  and  $g$ .

**Table 6.** Calibration parameters and statistical precision coefficients with the proposed empirical expressions  $h$  and  $g$  for ALOS-2 (L-HH and L-HV) and for Sentinel-1 (C-VV and C-VH) data.

Model	$h(Mv, Zs)$				$g(Mv, Hrms)$			
Sensor	ALOS-2		Sentinel-1		ALOS-2		Sentinel-1	
Configuration	L-HH	L-HV	C-VV	C-VH	L-HH	L-HV	C-VV	C-VH
$\alpha$	0.182	0.109	0.237	0.241	0.174	0.102	0.232	0.238
$\beta$	1.452	1.18	2.347	3.597	2.69	2.37	1.219	1.826
$\gamma$	-16.01	-26.48	-16.43	-28.27	-18.14	-28.27	-14.42	-25.03
RMSE (dB)	1.2	1.0	1.3	1.4	1.4	1.0	1.2	1.3
R	0.88	0.84	0.85	0.89	0.82	0.85	0.87	0.9

Figure 8 illustrates comparisons between the calibrated empirical models and radar datasets considered just for validation (30% of database, 9 samples for each polarization). We observe a good agreement between the calibrated models and radar data, with RMSE ranging from 1.4 dB to 2.0 dB for the L-HH and L-HV configurations using  $h(Mv, Zs)$  and 1.3 dB and 1.8 dB with  $g(Mv, Hrms)$ , respectively. For the S-1 data,  $h(Mv, Zs)$  relationship validation using real data gives RMSE values equal to 1.0 and 1.9 dB for the C-VV and C-VH configurations, respectively. Similar statistical precision ranges characterize  $g(Mv, Hrms)$  validation, where RMSE values are equal to 1.1 and 1.9 dB for the C-VV and C-VH configurations, respectively. Having two empirical models  $g$  and  $h$  with very similar accuracies, only the model  $g$  is kept afterwards for coupling with the WCM model.

**Figure 8.** Validation of the empirical backscattering models with multi-configuration real data: (a) L-HH and L-HV data with  $g(Mv, Hrms)$ , (b) L-HH and L-HV data with  $h(Mv, Zs)$ , (c) C-VV and C-VH data with  $g(Mv, Hrms)$ , (d) C-VV and C-VH data with  $h(Mv, Zs)$ .

#### 4.3.2. Case of Vegetation-Covered Soil

In this section, we analyze simulations of L- and C-band radar signals over fields with vegetation cover. To represent the soil contribution to the total backscattering coefficients, we use the aforementioned results retrieved in Section 4.3.1. Referring to bare soil model outcomes, in Section 4.3.1., IEM-B (for L-HH and C-VV configurations) and the empirical model  $g(Mv, Hrms)$  (for all configurations, L-HH, L-HV, C-VV, C-VH), for which the results illustrate good consistency over bare soils, are considered for bare soil component modeling.

By considering these various models for soil backscattering, using WCM option 1 (without an interaction component) illustrated in equation 14 and NDVI as a vegetation descriptor, the calibration of the A and B coefficients is proposed by using 70% of the dataset and the least square method. Table 7 summarizes the retrieved A and B parameters for different options and the corresponding statistical parameters (RMSE and R) of the comparison between the calibrated models and the dataset used for calibration.

The term B, related to the attenuation of the soil backscattered signal by the vegetation cover, is approximately at the same level for L-band configurations in the tested models. For L-HH and L-HV cases, with all proposed soil models, the B values ranged between 0.34 and 0.76 and 0.53 and 1.54 for the Sentinel-1 data in the C-VV and C-VH configurations, respectively.

Concerning the backscattering associated with the vegetation cover, the A parameter is certainly lower in the L-HV polarization than in L-HH, in agreement with the levels of the total L-HV signal compared to the L-HH signal. The same conclusions are observed for the C-VV and C-VH configurations. The A and B parameters retrieved with the S-1 data are close to those retrieved by Bousbih et al. (2017) over the same site with measurements realized in 2015–2016.

The use of the empirical model  $g(Mv, Hrms)$  for soil backscattering allows good agreement between the calibrated WCM model and the real data, with an RMSE lower than 1.7 dB for both the L-HH and L-HV configurations and reaching an RMSE maximum value of 1.4 dB for the C-VV and C-VH configurations. The IEM-B model applied to the co-polarizations also shows a reasonable performance with RMSE and R values equal to 2.0 dB and 0.72, respectively, for L-HH and 1.3 dB and 0.86 for the C-VV data.

**Table 7.** WCM option 1 parameters A and B calibration, with statistical precision coefficients for the case of two soil backscattering models, for ALOS-2 and Sentinel-1 data multi-polarizations.

Model	g(Mv, Hrms)				IEM-B	
	Sensor	ALOS-2		Sentinel-1		ALOS-2
Configuration	L-HH	L-HV	C-VV	C-VH	L-HH	C-VV
A	0.038	0.003	0.081	0.027	0.034	0.117
B	0.4	0.343	0.555	0.529	0.756	1.541
R	0.77	0.64	0.83	0.93	0.72	0.86
RMSE (dB)	1.6	1.7	1.4	1.3	2.0	1.3

In the second part of this section, we propose WCM calibration when the second option with soil–vegetation interaction is added, as described by equation (16). In this case, the total backscattering over cereal test fields is the sum of backscattering over bare soils attenuated by vegetation cover, the contribution of vegetation covers and, finally, the multiscattering component. With the added soil–vegetation interaction term in the WCM expression, three parameters (A, B and a newly added parameter, C, which also depends on vegetation properties) require calibration.

Table 8 illustrates the three calibrated parameters of A, B and C and the statistical coefficients (R and RMSE) when considering the two soil backscattering models ( $g(Mv, Hrms)$  and IEM-B). According to Table 8, RMSE values range from 1.6 to 2.4 dB in the L-HH configuration and equal 1.6 dB in L-HV for  $g(Mv, Hrms)$ .

For the L-HH case, the attenuated B parameter values range between 1.4 and 2.8. For the L-HV configuration, the B value is equal to 2.28 for the *g* soil model. The A parameter values (ranging between 0.023 and 0.052) in the L-HH configuration are higher than those retrieved with the L-HV case (equal to 0.004). The C parameter records values between 0.054 and 0.128 in the L-HH case and equal to 0.009 in the L-HV case.

In the C-band case, the A parameter values vary between 0.09 and 0.13 in the VV polarization and equal 0.025 for the VH polarization. The B parameter values are close to those found in the L-band, indicating large signal attenuation by vegetation [57].

For the C-VV and C-VH configurations, the C values are weak, resigning the negligence of the soil–vegetation interaction contribution to the total backscattering coefficients. In the following section, we evaluate the soil moisture inversion capabilities using the two WCM options with calibrated parameters in multiple configurations.

**Table 8.** Calibration parameters and statistical precision coefficients with the second WCM option 2 in L-HH, L-HV, C-VV and C-VH.

Model	g(Mv, Hrms)				IEM-B	
	ALOS-2		Sentinel-1		ALOS-2	Sentinel-1
Sensor	ALOS-2		Sentinel-1		ALOS-2	Sentinel-1
Configuration	L-HH	L-HV	C-VV	C-VH	L-HH	C-VV
A	0.023	0.004	0.130	0.025	0.052	0.09
B	1.4	2.28	2.66	3.85	2.78	3.08
C	0.054	0.009	0.007	−0.01	0.128	0.097
R	0.78	0.66	0.87	0.89	0.88	0.87
RMSE (dB)	1.6	1.6	1.2	1.8	2.4	1.2

#### 4.4. Soil Moisture Estimation

In this section, we aim to use different validated backscattering models for soil moisture estimation. For this section, two methods of inversion were carried out on over 30% of the dataset. Knowing the backscattered radar signal (in the L-HH, C-VV, L-HV or C-VH configurations), the NDVI characterizing the vegetation cover and the soil roughness, we estimate the soil moisture through a direct inversion of the calibrated expressions in the case of semi-empirical models or through look-up tables for IEM-B. Both options of the WCM are tested (with and without the addition of the soil–vegetation interaction term). Table 9 focuses on statistical parameters by representing bias and RMSE values for different inversion configurations and dual-frequency data.

Considering option 1 of the WCM model, we observe satisfactory results with estimated moisture accuracies between moderate and high for the L-HH configuration, with RMSEs between 4.9 and 6.4 vol.%, by considering IEM-B and *g*(Mv, Hrms) models, respectively.

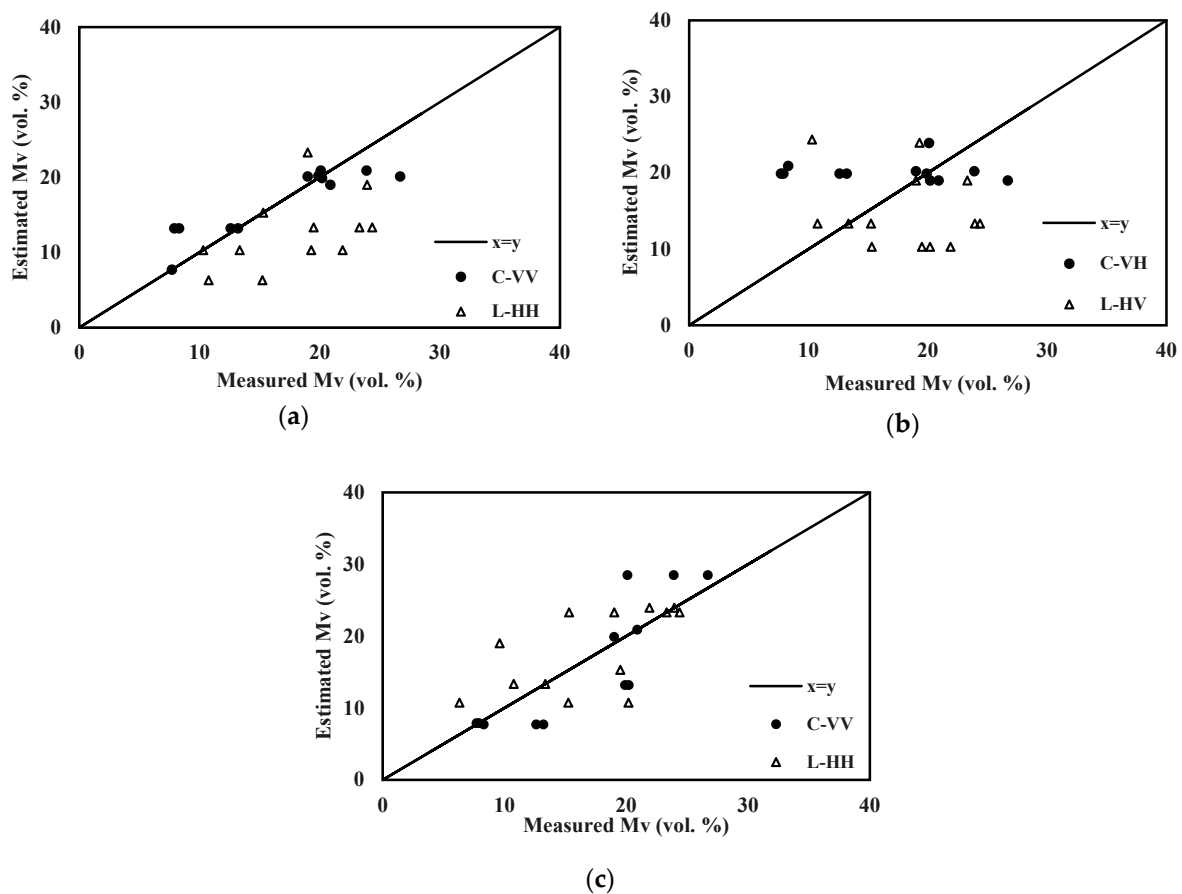
The best estimates are made by the IEM-B model, with RMSE values ranging between 3.4 and 4.9 vol.% for C-VV and L-HH polarizations, respectively. With the semi-empirical approach for soil scattering, there is a degradation that could be explained by less precision in the simulation of roughness behavior, particularly for low-frequency data. In fact, the precision of the C-VV configuration is equal to 4.7 vol.% with the *g* soil model. On the other hand, a lower accuracy is retrieved for the L-HH configuration, with RMSEs equal to 6.4 vol.% for the *g* model.

The application of this WCM option in cross-polarization concerns only the *g* soil semi-empirical model. In this case, the results are strongly degraded compared to the results in C-VV and L-HH, with accuracies (RMSE) on the order of 13 vol.% for the ALOS-2 data and 7.1 vol.% for the Sentinel-1 data. These results are consistent with previous studies showing the poorer accuracy of moisture inversion using cross-polarization. They are also consistent with many studies showing the importance of taking into account the soil–vegetation interaction component in the simulation of canopy scattering for the case of a cross-polarization configuration.

The application of WCM option 2 illustrates performances relatively close to those retrieved for the WCM option 1 in the case of the L-HH configuration, with RMSEs relatively stable between 4.8 and 6.1 vol.% and also the same precision quality as the C-VV configuration. However, for the case of the L-HV configuration, the effect of taking into account the ground–vegetation interaction is very important. Indeed, this integration makes it possible to go from very degraded to moderate accuracies between 6 and 7 vol.%.

In contrast, the integration of the soil–vegetation component into the WCM model induces a limited improvement when retrieving soil moisture in the C-VH polarization and insists on the adequacy of simplified WCM use in the C-band frequency. This could be explained by the limited contribution of soil–vegetation interactions in the context of a limited wave penetration ability.

Figure 9 shows the inter-comparison between the in situ soil moisture and estimated values for the application of WCM option 2 with different types of soil scattering models at the L- and C-band frequencies. Each point corresponds to one tested field.



**Figure 9.** Inter-comparison between ground measurements and estimated soil moisture values using different inversion approaches based on WCM option 2 (with interaction component contribution) (a) with g model, L-HH and C-VV, (b) with g model, L-HV and C-VH and (c) with IEM-B model, L-HH and C-VV.

This result highlights the importance of considering the soil–vegetation interaction component in the modeling of the radar signal, especially in the L-HV configuration. The best performance is illustrated with IEM-B coupled to WCM option 1 in the C-VV configuration, with an RMSE value of approximately 3.3 vol.%, and coupled to WCM option 2 in the L-HH configuration, with an RMSE of less than 5 vol.%.

The contribution of the L-band seems evident for dense covers; however, noise coming from vegetation volume scattering and a more important effect due to roughness could degrade the precision of soil moisture estimation. To analyze the benefits and limitations of the L-band compared to other frequency bands and particularly the C-band, it will



be very useful in the future to analyze polarimetric measurements acquired in different frequency bands.

**Table 9.** Inversion statistical precision coefficients in L-HH, L-HV, C-VV and C-VH configurations in the case of two options of the WCM.

Model		g(Mv, Hrms)				IEM-B	
	Configuration	L-HH	L-HV	C-VV	C-VH	L-HH	C-VV
Option 1	Bias (vol.%)	−0.86	−3.62	−1.84	1.6	−1.24	1.05
	RMSE (vol.%)	6.44	13.68	4.74	7.11	4.87	3.35
Option 2	Bias (vol.%)	1.86	2.93	−0.10	−2.88	2.76	0.73
	RMSE (vol.%)	6.12	6.81	3.17	6.75	4.85	4.65

## 5. Conclusions

In the present study, we analyzed the potential of L- and C-band radar data for soil moisture estimation over cereal agricultural fields in the semiarid plain of Kairouan (central Tunisia).

Based on multi-incidence, multi-polarization and dual-frequency data, an analysis of the sensitivities of radar signals to soil parameters (roughness and moisture) and vegetation properties was proposed. For the L-band, multi-incidence (28°, 32.5° and 36°) dual-polarization (HH and HV) data are strongly influenced by soil roughness. According to the analyzed results under low-soil moisture conditions, statistical values show high correlations between radar signals and roughness parameters (Hrms and Zs). A range of approximately 10 dB in radar signals is observed for the roughness effect. For the same range of roughness parameters, S-1 radar data, acquired in the C-band, show a lower dynamic range, between 8 and 6 dB, for VV and VH polarizations, respectively. The sensitivity of the ALOS-2 signal to soil moisture decreases with vegetation development by 0.31 and 0.18 dB/vol.% (NDVI < 0.3) to 0.27 and 0.15 dB/vol.% for NDVI values between 0.3 and 0.6 and finally to 0.19 and 0.16 dB/vol.% (NDVI > 0.6) in HH and HV, respectively. The sensitivity of the Sentinel-1 signal to soil moisture decreases by 0.26 and 0.24 dB/vol.% in the bare soil class and low vegetation density to 0.17 and 0.08 dB/vol.% for the medium density vegetation class and finally to 0.07 and 0.09 dB/vol.% for the denser canopy class in VV and VH polarizations, respectively.

The observed results underline the L-band signal sensitivity to vegetation parameters (VWC, LAI and vegetation height). The highest correlations, equal to 0.87 and 0.78, for HH and HV polarizations, respectively, are observed with the VWC parameter. This could be particularly explained by the high penetration of L-band radar signals in vegetation covers.

The simulation of L- and C-band radar signals was discussed for bare and covered soils. For bare soils, two empirical models dependent on roughness (Hrms or Zs parameters) and soil moisture, the semi-empirical Dubois-B model and, finally, the IEM-B model were tested. The best simulations are found with the two empirical approaches calibrated in the available polarizations and the IEM-B model in only like-polarization. Validations with a set of real data different from those used for calibration illustrate, for example, an RMSE equal to 1.3 dB, 1.8dB, 1.1dB and 1.9dB for L-HH, L-HV, C-VV and C-VH for empirical model g(Mv, Hrms), respectively.

Concerning the surfaces with vegetation cover, two options were considered for the WCM: option 1 with two components in which the soil component is attenuated by the vegetation cover, and option 2, which includes the addition of the soil–vegetation interaction to the first two components.

After calibration of the two WCM options, the proposed models were tested to invert the radar signal and estimate the soil moisture.

Concerning the L-HH configuration, the use of option 1 enables an estimation with a high to moderate precision between 4.9 and 6.4 vol.% for the different types of considered soil scattering models. The L-HV configuration, on the other hand, shows very degraded

results with this WCM first option. Regarding the C-VV configuration, the same WCM option grants soil moisture retrieval with RMSE values varying between 3.3 and 4.7 vol.% for different soil backscattering models facing approximately 7 vol.% C-VH polarization. The use of WCM option 2 maintains a relatively stable accuracy for the case of the L-HH configuration. It enables a clear improvement in the estimates in the L-HV data case with an RMSE between 6 and 7 vol.% for different types of soil backscattering models. According to the present results, consideration of the soil–vegetation interaction component seems essential for the exploitation of L-HH data in soil moisture estimation.

In the future, a simultaneous inversion approach for the two parameters roughness and moisture will be proposed, with the use of the artificial neural network (NN) technique to firstly derive the soil roughness (Hrms) from the L-HH data in order to then consider the derived Hrms and C-band data for soil moisture estimation. Moreover, this proposed estimate of soil moisture will be considered for irrigation mapping and detection over the studied site.

**Author Contributions:** E.A., M.Z., Z.K. and Z.L.-C. conceived and designed the experiments; E.A. and S.B. performed the experiments; E.A. and M.Z. analyzed the data; E.A., M.Z., Z.K., Z.L.-C. and N.B. contributed to the materials/analysis tools; E.A. and M.Z. wrote the paper. All authors have read and agreed to the published version of the manuscript.

**Funding:** This study was funded by the Viana (ERA-Net ARIMNet) Project; the PHC Utique IPASS Project; the Chaams (ERANET3-602 CHAAMS) Project; the Irrigation+ ((ESA n°4000129870/20/I-NB) Project; and the TAPAS TOSCA/CNES project.

**Data Availability Statement:** Data are available in Theia Land site <https://www.theia-land.fr/> (accessed on 31 March 2021) and Environment Information System of CESBIO site <http://osr-cesbio.ups-tlse.fr/portailsie/> (accessed on 31 March 2021).

**Acknowledgments:** We extend our warm thanks to the technical teams at the IRD and INAT (Institut National Agronomique de Tunisie) who participated in the ground truth measurement campaigns and data processing.

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

## References

1. Koster, R.D.; Dirmeyer, P.A.; Guo, Z.; Bonan, G.; Chan, E.; Cox, P.; Gordon, C.T.; Kanae, S.; Kowalczyk, E.; Lawrence, D.; et al. Regions of Strong Coupling Between Soil Moisture and Precipitation. *Science* **2004**, *305*, 1138–1140. [[CrossRef](#)] [[PubMed](#)]
2. Anguela, T.P.; Zribi, M.; Hasenauer, S.; Habets, F.; Loumagne, C. Analysis of surface and root-zone soil moisture dynamics with ERS scatterometer and the hydrometeorological model SAFRAN-ISBA-MODCOU at Grand Morin watershed (France). *Hydrol. Earth Syst. Sci.* **2008**, *12*, 1415–1424. [[CrossRef](#)]
3. Saux-Picart, S.; Otlé, C.; Decharme, B.; André, C.; Zribi, M.; Perrier, A.; Coudert, B.; Boulain, N.; Cappelaere, B.; Descroix, L.; et al. Water and energy budgets simulation over the AMMA-Niger super-site spatially constrained with remote sensing data. *J. Hydrol.* **2009**, *375*, 287–295. [[CrossRef](#)]
4. Manfreda, S.; Scanlon, T.M.; Caylor, K.K. On the importance of accurate depiction of infiltration processes on modelled soil moisture and vegetation water stress. *Ecohydrology* **2009**, *3*, 155–165. [[CrossRef](#)]
5. Massari, C.; Brocca, L.; Moramarco, T.; Tramblay, Y.; Lescot, J.F.D. Potential of soil moisture observations in flood modelling estimating initial conditions and correcting rainfall. *Adv. Water Resour.* **2014**, *74*, 44–53. [[CrossRef](#)]
6. Habets, F.; Gascoin, S.; Korkmaz, S.; Thiéry, D.; Zribi, M.; Amraoui, N.; Carli, M.; Ducharme, A.; Leblois, E.; LeDoux, E.; et al. Multi-model comparison of a major flood in the groundwater-fed basin of the Somme River (France). *Hydrol. Earth Syst. Sci.* **2010**, *14*, 99–117. [[CrossRef](#)]
7. Kerr, Y.H.; Waldteufel, P.; Wigneron, J.-P.; Delwart, S.; Cabot, F.; Boutin, J.; Escorihuela, M.-J.; Font, J.; Reul, N.; Gruhier, C.; et al. The SMOS Mission: New Tool for Monitoring Key Elements of the Global Water Cycle. *Proc. IEEE* **2010**, *98*, 666–687. [[CrossRef](#)]
8. 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.; et al. The Soil Moisture Active Passive (SMAP) Mission. *Proc. IEEE* **2010**, *98*, 704–716. [[CrossRef](#)]
9. Wagner, W.; Lemoine, G.; Rott, H. A Method for Estimating Soil Moisture from ERS Scatterometer and Soil Data. *Remote Sens. Environ.* **1999**, *70*, 191–207. [[CrossRef](#)]
10. 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**, *115*, 3390–3408. [[CrossRef](#)]

11. Chen, K.; Yen, S.; Huang, W. A simple model for retrieving bare soil moisture from radar-scattering coefficients. *Remote Sens. Environ.* **1995**, *54*, 121–126. [[CrossRef](#)]
12. McNairn, H.; Brisco, B. The application of C-band polarimetric SAR for agriculture: A review. *Can. J. Remote Sens.* **2004**, *30*, 525–542. [[CrossRef](#)]
13. Srivastava, H.S.; Patel, P.; Sharma, Y.; Navalgund, R.R. Large-Area Soil Moisture Estimation Using Multi-Incidence-Angle RADARSAT-1 SAR Data. *IEEE Trans. Geosci. Remote Sens.* **2009**, *47*, 2528–2535. [[CrossRef](#)]
14. Pierdicca, N.; Pulvirenti, L.; Bignami, C. Soil moisture estimation over vegetated terrains using multitemporal remote sensing data. *Remote Sens. Environ.* **2010**, *114*, 440–448. [[CrossRef](#)]
15. Du, J.; Shi, J.; Sun, R. The development of HJ SAR soil moisture retrieval algorithm. *Int. J. Remote Sens.* **2010**, *31*, 3691–3705. [[CrossRef](#)]
16. Balenzano, A.; Mattia, F.; Satalino, G.; Davidson, M.W.J. Dense Temporal Series of C- and L-band SAR Data for Soil Moisture Retrieval Over Agricultural Crops. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2011**, *4*, 439–450. [[CrossRef](#)]
17. Santi, E.; Dabboor, M.; Pettinato, S.; Paloscia, S. Combining Machine Learning and Compact Polarimetry for Estimating Soil Moisture from C-Band SAR Data. *Remote Sens.* **2019**, *11*, 2451. [[CrossRef](#)]
18. Gorrab, A.; Zribi, M.; Baghdadi, N.; Mougenot, B.; Lili-Chaabane, Z. Retrieval of both soil moisture and texture using TerraSAR-X images. *Remote Sens.* **2015**, *7*, 10098–10116. [[CrossRef](#)]
19. Wang, H.; Magagi, R.; Goita, K.; Jagdhuber, T.; Hajnsek, I. Evaluation of Simplified Polarimetric Decomposition for Soil Moisture Retrieval over Vegetated Agricultural Fields. *Remote Sens.* **2016**, *8*, 142. [[CrossRef](#)]
20. Wang, H.; Magagi, R.; Goita, K.; Jagdhuber, T. Refining a Polarimetric Decomposition of Multi-Angular UAVSAR Time Series for Soil Moisture Retrieval Over Low and High Vegetated Agricultural Fields. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2019**, *12*, 1431–1450. [[CrossRef](#)]
21. Verhoest, N.E.C.; Lievens, H.; Wagner, W.; Alvarez-Mozos, J.; Moran, M.S.; Mattia, F. On the soil roughness parameterization problem in soil moisture retrieval of bare surfaces from Synthetic Aperture Radar. *Sensors* **2008**, *8*, 4213–4248. [[CrossRef](#)]
22. Ma, C.; Li, X.; McCabe, M.F. Retrieval of High-Resolution Soil Moisture through Combination of Sentinel-1 and Sentinel-2 Data. *Remote Sens.* **2020**, *12*, 2303. [[CrossRef](#)]
23. Shi, J.; Wang, J.; Hsu, A.Y.; O'Neill, P.E.; Engman, E.T. Estimation of bare surface soil moisture and surface roughness parameter using L-band SAR image data. *IEEE Trans. Geosci. Remote Sens.* **1997**, *35*, 1254–1266.
24. El Hajj, M.; Baghdadi, N.; Zribi, M.; Rodríguez-Fernández, N.; Wigneron, J.P.; Al-Yaari, A.; Al Bitar, A.; Albergel, C.; Calvet, J.-C. Evaluation of SMOS, SMAP, ASCAT and Sentinel-1 Soil Moisture Products at Sites in Southwestern France. *Remote Sens.* **2018**, *10*, 569. [[CrossRef](#)]
25. Mohanty, B.P.; Cosh, M.H.; Lakshmi, V.; Montzka, C. Soil Moisture Remote Sensing: State-of-the-Science. *Vadose Zone J.* **2017**, *16*, 1–9. [[CrossRef](#)]
26. Zribi, M.; Dechambre, M. A new empirical model to retrieve soil moisture and roughness from C-band radar data. *Remote Sens. Environ.* **2003**, *84*, 42–52. [[CrossRef](#)]
27. Bousbih, S.; Zribi, M.; Lili-Chabaane, Z.; Baghdadi, N.; El Hajj, M.; Gao, Q.; Mougenot, B. Potential of Sentinel-1 Radar Data for the Assessment of Soil and Cereal Cover Parameters. *Sensors* **2017**, *17*, 2617. [[CrossRef](#)] [[PubMed](#)]
28. Dubois, P.; Van Zyl, J.; Engman, T. Measuring soil moisture with imaging radars. *IEEE Trans. Geosci. Remote Sens.* **1995**, *33*, 915–926. [[CrossRef](#)]
29. Oh, Y.; Sarabandi, K.; Ulaby, F.T. An empirical model and an inversion technique for radar scattering from bare soil surfaces. *IEEE Trans. Geosci. Remote Sens.* **1992**, *30*, 370–381. [[CrossRef](#)]
30. Ulaby, F.T.; Moore, R.K.; Fung, A.K. *Microwave Remote Sensing: Active and Passive. 3-From Theory to Applications*; Artech House: Norwood, MA, USA, 1986.
31. Fung, A.; Li, Z.; Chen, K. Backscattering from a randomly rough dielectric surface. *IEEE Trans. Geosci. Remote Sens.* **1992**, *30*, 356–369. [[CrossRef](#)]
32. Zribi, M.; Taconet, O.; Le Hégarat-Masclé, S.; Vidal-Madjar, D.; Emblanch, C.; Loumagne, C.; Normand, M. Backscattering behavior and simulation comparison over bare soils using SIR-C/X-SAR and ERASME 1994 data over Orgeval. *Remote Sens. Environ.* **1997**, *59*, 256–266. [[CrossRef](#)]
33. Baghdadi, N.; Zribi, M. Evaluation of radar backscatter models IEM, OH and Dubois using experimental observations. *Int. J. Remote Sens.* **2006**, *27*, 3831–3852. [[CrossRef](#)]
34. Baghdadi, N.; Saba, E.; Aubert, M.; Zribi, M.; Baup, F. Evaluation of Radar Backscattering Models IEM, Oh, and Dubois for SAR Data in X-Band Over Bare Soils. *IEEE Geosci. Remote Sens. Lett.* **2011**, *8*, 1160–1164. [[CrossRef](#)]
35. Choker, M.; Baghdadi, N.; Zribi, M.; El Hajj, M.; Paloscia, S.; Verhoest, N.E.C.; Lievens, H.; Mattia, F. Evaluation of the Oh, Dubois and IEM Backscatter Models Using a Large Dataset of SAR Data and Experimental Soil Measurements. *Water* **2017**, *9*, 38. [[CrossRef](#)]
36. Baghdadi, N.; Gherboudj, I.; Zribi, M.; Sahebi, M.; King, C.; Bonn, F. Semi-empirical calibration of the IEM backscattering model using radar images and moisture and roughness field measurements. *Int. J. Remote Sens.* **2004**, *25*, 3593–3623. [[CrossRef](#)]
37. Baghdadi, N.; Zribi, M.; Paloscia, S.; Verhoest, N.E.C.; Lievens, H.; Baup, F.; Mattia, F. Semi-Empirical Calibration of the Integral Equation Model for Co-Polarized L-Band Backscattering. *Remote Sens.* **2015**, *7*, 13626–13640. [[CrossRef](#)]

38. Karam, M.; Fung, A.; Antar, Y. Electromagnetic wave scattering from some vegetation samples. *IEEE Trans. Geosci. Remote Sens.* **1988**, *26*, 799–808. [[CrossRef](#)]
39. Ulaby, F.; McDonald, K.; Sarabandi, K.; Dobson, M. Michigan Microwave Canopy Scattering Models (MIMICS). *Int. J. Remote Sens.* **1990**, *11*, 1223–1253. [[CrossRef](#)]
40. Attema, E.P.W.; Ulaby, F.T. Vegetation modeled as a water cloud. *Radio Sci.* **1978**, *13*, 357–364. [[CrossRef](#)]
41. Graham, A.J.; Harris, R. Extracting biophysical parameters from remotely sensed radar data: A review of the water cloud model. *Prog. Phys. Geogr. Earth Environ.* **2003**, *27*, 217–229. [[CrossRef](#)]
42. Baghdadi, N.; El Hajj, M.; Zribi, M.; Bousbih, S. Calibration of the Water Cloud Model at C-Band for Winter Crop Fields and Grasslands. *Remote Sens.* **2017**, *9*, 969. [[CrossRef](#)]
43. Weiß, T.; Ramsauer, T.; Löw, A.; Marzahn, P. Evaluation of Different Radiative Transfer Models for Microwave Backscatter Estimation of Wheat Fields. *Remote Sens.* **2020**, *12*, 3037. [[CrossRef](#)]
44. Ouada, 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](#)]
45. Zribi, M.; Chahbi, A.; Shabou, M.; Lilichabaane, Z.; Duchemin, B.; Baghdadi, N.; Amri, R.; Chehbouni, A. Soil surface moisture estimation over a semi-arid region using ENVISAT ASAR radar data for soil evaporation evaluation. *Hydrol. Earth Syst. Sci.* **2011**, *15*, 345–358. [[CrossRef](#)]
46. Fieuzal, R.; Baup, F.; Marais-Sicre, C. Monitoring wheat and rapeseed by using synchronous optical and radar satellite data—From temporal signatures to crop parameters estimation. *Adv. Remote Sens.* **2013**, *2*, 162–180. [[CrossRef](#)]
47. Kim, S.B.; Moghaddam, M.; Tsang, L.; Burgin, M.; Xu, X.; Njoku, E.G. Models of L-band radar backscattering coefficients over global terrain for soil moisture retrieval. *IEEE Trans. Geosci. Remote Sens.* **2014**, *52*, 1381–1396. [[CrossRef](#)]
48. Kim, S.B.; van Zyl, J.J.; Johnson, J.T.; Moghaddam, M.; Tsang, L.; Colliander, A.; Dunbar, R.S.; Jackson, T.J.; Jaruwatanadilok, S.; West, R.; et al. Surface Soil Moisture Retrieval Using the L-Band Synthetic Aperture Radar Onboard the Soil Moisture Active–Passive Satellite and Evaluation at Core Validation Sites. *IEEE Trans. Geosci. Remote Sens.* **2017**, *55*, 1897–1914. [[CrossRef](#)] [[PubMed](#)]
49. Notarnicola, C.; Angiulli, M.; Posa, F. Soil moisture retrieval from remotely sensed data: Neural network approach versus Bayesian method. *IEEE Trans. Geosci. Remote Sens.* **2008**, *46*, 547–557. [[CrossRef](#)]
50. Santi, E.; Paloscia, S.; Pettinato, S.; Fontanelli, G. Application of artificial neural networks for the soil moisture retrieval from active and passive microwave spaceborne sensors. *Int. J. Appl. Earth Obs. Geoinf.* **2016**, *48*, 61–73. [[CrossRef](#)]
51. El Hajj, M.; Baghdadi, N.; Zribi, M.; Bazzi, H. Synergic use of Sentinel-1 and Sentinel-2 images for operational soil moisture mapping at high spatial resolution over agricultural areas. *Remote Sens.* **2017**, *9*, 1292. [[CrossRef](#)]
52. Gao, Q.; Zribi, M.; Escorihuela, M.J.; Baghdadi, N. Synergetic Use of Sentinel-1 and Sentinel-2 Data for Soil Moisture Mapping at 100 m Resolution. *Sensors* **2017**, *17*, 1966. [[CrossRef](#)] [[PubMed](#)]
53. Bauer-Marschallinger, B.; Freeman, V.; Cao, S.; Paulik, C.; Schauffer, S.; Stachl, T.; Modanesi, S.; Massari, C.; Ciabatta, L.; Brocca, L.; et al. Toward Global Soil Moisture Monitoring With Sentinel-1: Harnessing Assets and Overcoming Obstacles. *IEEE Trans. Geosci. Remote Sens.* **2018**, *57*, 520–539. [[CrossRef](#)]
54. Foucras, M.; Zribi, M.; Albergel, C.; Baghdadi, N.; Calvet, J.-C.; Pellarin, T. Estimating 500-m Resolution Soil Moisture Using Sentinel-1 and Optical Data Synergy. *Water* **2020**, *12*, 866. [[CrossRef](#)]
55. Bousbih, S.; Zribi, M.; El Hajj, M.; Baghdadi, N.; Lili-Chabaane, Z.; Gao, Q.; Fanise, P. Soil Moisture and Irrigation Mapping in A Semi-Arid Region, Based on the Synergetic Use of Sentinel-1 and Sentinel-2 Data. *Remote Sens.* **2018**, *10*, 1953. [[CrossRef](#)]
56. Panciera, R.; Tanase, M.A.; Lowell, K.; Walker, J.P. Evaluation of IEM, Dubois, and Oh Radar Backscatter Models Using Airborne L-Band SAR. *IEEE Trans. Geosci. Remote Sens.* **2014**, *52*, 4966–4979. [[CrossRef](#)]
57. Dabrowska-Zielinska, K.; Inoue, Y.; Kowalik, W.; Gruszczynska, M. Inferring the effect of plant and soil variables on C- and L-band SAR backscatter over agricultural fields, based on model analysis. *Adv. Space Res.* **2007**, *39*, 139–148. [[CrossRef](#)]
58. Jagdhuber, T.; Hajnsek, I.; Bronstert, A.; Papathanassiou, K.P. Soil Moisture Estimation under Low Vegetation Cover Using a Multi-Angular Polarimetric Decomposition. *IEEE Trans. Geosci. Remote Sens.* **2012**, *51*, 2201–2215. [[CrossRef](#)]
59. El Hajj, M.; Baghdadi, N.; Bazzi, H.; Zribi, M. Penetration Analysis of SAR Signals in the C and L Bands for Wheat, Maize, and Grasslands. *Remote Sens.* **2018**, *11*, 31. [[CrossRef](#)]
60. El Hajj, M.; Baghdadi, N.; Zribi, M. Comparative analysis of the accuracy of surface soil moisture estimation from the C- and L-bands. *Int. J. Appl. Earth Obs. Geoinf.* **2019**, *82*, 101888. [[CrossRef](#)]
61. Zribi, M.; Muddu, S.; Bousbih, S.; Al Bitar, A.; Tomer, S.K.; Baghdadi, N.; Bandyopadhyay, S. Analysis of L-Band SAR Data for Soil Moisture Estimations over Agricultural Areas in the Tropics. *Remote Sens.* **2019**, *11*, 1122. [[CrossRef](#)]
62. Sekertekin, A.; Marangoz, A.M.; Abdikan, S. ALOS-2 and Sentinel-1 SAR data sensitivity analysis to surface soil moisture over bare and vegetated agricultural fields. *Comput. Electron. Agric.* **2020**, *171*, 105303. [[CrossRef](#)]
63. Amri, R.; Zribi, M.; Duchemin, B.; Lili-Chabaane, Z.; Gruhier, C.; Chehbouni, A. Analysis of vegetation behaviour in a semi-arid region, using SPOT-VEGETATION NDVI data. *Remote Sens.* **2011**, *3*, 2568–2590. [[CrossRef](#)]
64. Zribi, M.; Gorrab, A.; Baghdadi, N. A new soil roughness parameter for the modelling of radar backscattering over bare soil. *Remote Sens. Environ.* **2014**, *152*, 62–73. [[CrossRef](#)]

65. Baghdadi, N.; Choker, M.; Zribi, M.; El Hajj, M.; Paloscia, S.; Verhoest, N.E.C.; Lievens, H.; Baup, F.; Mattia, F. A New Empirical Model for Radar Scattering from Bare Soil Surfaces. *Remote Sens.* **2016**, *8*, 920. [[CrossRef](#)]
66. Wu, T.-D.; Chen, K.; Shi, J.; Fung, A. A transition model for the reflection coefficient in surface scattering. *IEEE Trans. Geosci. Remote Sens.* **2001**, *39*, 2040–2050. [[CrossRef](#)]
67. 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](#)]
68. Fontanelli, G.; Paloscia, S.; Zribi, M.; Chahbi, A. Sensitivity analysis of X-band SAR to wheat and barley leaf area index in the Merguellil Basin. *Remote Sens. Lett.* **2013**, *4*, 1107–1116. [[CrossRef](#)]
69. El Hajj, M.; Baghdadi, N.; Belaud, G.; Zribi, M.; Cheviron, B.; Courault, D.; Hagolle, O.; Charron, F. Irrigated Grassland Monitoring Using a Time Series of TerraSAR-X and COSMO-SkyMed X-Band SAR Data. *Remote Sens.* **2014**, *6*, 10002–10032. [[CrossRef](#)]

### III.3. Estimation de l'humidité sur sols couverts par des piments

#### III.3.1. Résumé

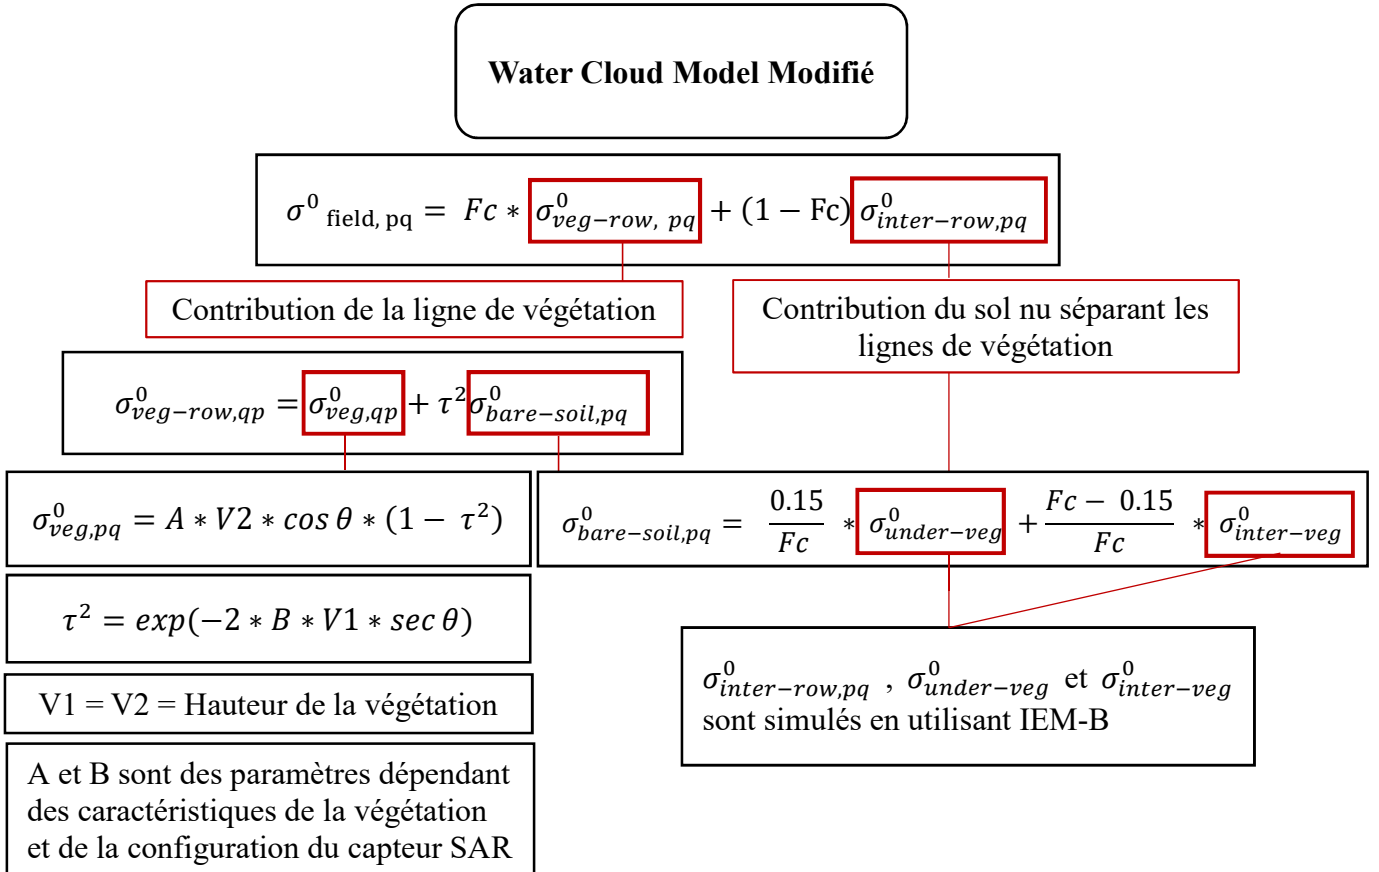
Dans la première partie du chapitre, l'humidité du sol a été estimée sur des parcelles des céréales irriguées par des asperseurs. Dans ce cas, l'humidité du sol est homogènement répartie sur les parcelles de références analysées. Les cultures maraîchères saisonnières font partie de la production agricole irriguée dans cette zone. Dans un contexte d'optimisation des doses d'irrigation, nous avons opté dans cette partie du chapitre à analyser le potentiel des données bi-fréquence (en bande C et L) pour estimer l'humidité du sol surfacique des cultures en lignes irriguées gouttes à gouttes.

Pendant les trois mois d'été 2020 (Juin, Juillet et Août), les données in-situ, englobant des mesures localisées d'humidité du sol à une profondeur de 5cm ; de rugosité et des variables biophysiques de la végétation, ont été mesurées sur des parcelles de piments. Ces dernières ont été sélectionnées dans la plaine de Kairouan occupées par des rangs de piments séparés par un mètre de sol nu. La végétation est irriguée gouttes à gouttes. Par conséquent, l'humidité du sol liée à l'irrigation est localisée sur les lignes de végétation en créant une répartition hétérogène de l'humidité de surface du sol.

En se basant sur l'architecture des parcelles, l'humidité du sol par parcelle est le résultat d'une somme pondérée des humidités mesurées sur la ligne de la végétation et des humidités mesurées sur les sols nus séparant les rangs des piments. Les variables biophysiques mesurées comprennent des mesures d'hauteur des piments (H), l'indice foliaire (LAI) et la fraction de couvert (Fc). En fonction des données bi-fréquences acquises par ALOS-2 et Sentinel-1, les analyses de sensibilité des coefficients de rétrodiffusion ont mis en évidence une sensibilité plus marquée des données en bande L à l'humidité du sol, calculée par parcelle. Cette sensibilité varie entre 0.16 et 0.18 dB/vol.%, tandis que celle des données en bande C ne dépasse pas 0.06 dB/vol.%

En termes de polarisation, les données en co-polarisation (L-HH et C-VV) sont plus corrélées aux mesures d'humidité que les données en polarisation croisée (L-HV et C-VH). En fonction des mesures des variables biophysiques des céréales, les signaux radar en bande L sont plus corrélés à la hauteur et à l'indice foliaire des piments que les signaux en bande C. D'après ces résultats, nous avons gardé les données en co-polarisation (L-HH et C-VV) pour simuler le comportement du signal radar sur les parcelles des piments et éviter l'impact du volume de la

végétation en cross-polarisation. Avec cette répartition hétérogène de l'humidité de surface du sol, nous avons proposé une modification du WCM décrite dans la **Figure 34**. Les coefficients de rétrodiffusion par parcelle est la somme de la contribution des lignes des piments ( $\sigma_{veg-row}^0$ ) pondérée par la fraction de couvert (Fc) et la contribution du sol nu séparant les lignes de végétation ( $\sigma_{inter-row,pq}^0$ ) pondérée par (1-Fc).



**Figure 34.** Organigramme décrivant le WCM modifié avec les équations utilisées

La contribution de la ligne de la végétation est la somme de la contribution des piments ( $\sigma_{veg}^0$ ) et la contribution du sol nu ( $\sigma_{bare-soil}^0$ ) sur la ligne de la végétation atténuée par la végétation. Par la suite la contribution des piments est calculée en fonction des mesures in-situ de la hauteur des piments comme étant le descripteur de végétation dans notre cas. La contribution du sol nu est la somme de la contribution du sol nu sous les pieds de la végétation  $\sigma_{under-veg}^0$  pondérée par  $0.15/Fc$  et la contribution du sol nu séparant les pieds successifs des piments  $\sigma_{inter-veg}^0$  pondérée par  $(Fc - 0.15)/Fc$ .

Toutes les contributions du sol nu sont simulées en utilisant le modèle IEM-B. La version modifiée du WCM requiert une calibration et une validation des deux paramètres A et B qui

dépendent des caractéristiques de la végétation et de la configuration des satellites. L'estimation de ces paramètres s'est basée sur une cross-validation à 3 niveaux en utilisant 2/3 de la base de données pour la calibration et le 1/3 de la base des données pour la validation.

Afin d'examiner la performance du modèle proposé, des simulations ont été faites dans des conditions maîtrisées : l'humidité du sol nu entre les lignes varie entre 5 et 40 vol.%, l'humidité sur la ligne de végétation fluctue entre 10 et 40 vol.%, la hauteur de la végétation est entre 0.1 et 0.7 et une fraction de couvert entre 0.1 et 0.6. Les simulations consistent à fixer des conditions et varier les autres. Par exemple, à chaque fraction de couvert constante, nous avons varié la hauteur de la végétation et nous avons examiné la sensibilité du signal simulé aux humidités du sol. Ultérieurement, les sensibilités du signal sont représentées en fonction de la variabilité des variables biophysiques : Hauteur (H) et fraction de couvert (Fc).

Ces simulations ont mis en relief le potentiel du modèle proposé à simuler un signal sensible à l'humidité du sol. Lorsque la Fc est inférieure à 0.3 et la hauteur ne dépasse pas 0.3 m, la sensibilité des coefficients rétrodiffusés simulés C-VV ne dépasse pas 0.08 dB/vol.%. Cette même sensibilité est atteinte avec les données en bande L (L-HH) lorsque la fraction de couvert égale à 0.4 et la hauteur est inférieure à 0.5m. Grâce à sa profondeur de pénétration, les résultats des simulations insistent sur le potentiel des données en bande L à estimer l'humidité du sol d'un contexte de répartition spatiale hétérogène sur les parcelles des cultures en lignes

### III.3.2. Article



## Article

# Investigation of Multi-Frequency SAR Data to Retrieve the Soil Moisture within a Drip Irrigation Context Using Modified Water Cloud Model

Emna Ayari <sup>1,2</sup> , Zeineb Kassouk <sup>2</sup>, Zohra Lili-Chabaane <sup>2</sup>, Nicolas Baghdadi <sup>3</sup>  and Mehrez Zribi <sup>1,\*</sup> 

<sup>1</sup> CESBIO (CNRS/UPS/IRD/CNES/INRAE), 18 Av. Edouard Belin, bpi 2801, CEDEX 9, 31401 Toulouse, France; ayari.emna.inat@gmail.com

<sup>2</sup> National Agronomic Institute of Tunisia, Carthage University, LR17AGR01 InteGRatEd Management of Natural Resources: remoTE Sensing, Spatial Analysis and Modeling (GREEN-TEAM), Tunis 1082, Tunisia; zeineb.kassouk@inat.u-carthage.tn (Z.K.); Zohra.LiliChabaane@inat.u-carthage.tn (Z.L.-C.)

<sup>3</sup> CIRAD, CNRS, INRAE, TETIS, University of Montpellier, AgroParisTech, CEDEX 5, 34093 Montpellier, France; nicolas.baghdadi@teledetection.fr

\* Correspondence: mehrez.zribi@ird.fr; Tel.: +33-56155-8525

**Abstract:** The objective of this paper was to estimate soil moisture in pepper crops with drip irrigation in a semi-arid area in the center of Tunisia using synthetic aperture radar (SAR) data. Within this context, the sensitivity of L-band (ALOS-2) in horizontal-horizontal (HH) and horizontal-vertical (HV) polarizations and C-band (Sentinel-1) data in vertical-vertical (VV) and vertical-horizontal (VH) polarizations is examined as a function of soil moisture and vegetation properties using statistical correlations. SAR signals scattered by pepper-covered fields are simulated with a modified version of the water cloud model using L-HH and C-VV data. In spatially heterogeneous soil moisture cases, the total backscattering is the sum of the bare soil contribution weighted by the proportion of bare soil (one-cover fraction) and the vegetation fraction cover contribution. The vegetation fraction contribution is calculated as the volume scattering contribution of the vegetation and underlying soil components attenuated by the vegetation cover. The underlying soil is divided into irrigated and non-irrigated parts owing to the presence of drip irrigation, thus generating different levels of moisture underneath vegetation. Based on signal sensitivity results, the potential of L-HH data to retrieve soil moisture is demonstrated. L-HV data exhibit a higher potential to retrieve vegetation properties regarding a lower potential for soil moisture estimation. After calibration and validation of the proposed model, various simulations are performed to assess the model behavior patterns under different conditions of soil moisture and pepper biophysical properties. The results highlight the potential of the proposed model to simulate a radar signal over heterogeneous soil moisture fields using L-HH and C-VV data.

**Keywords:** ALOS-2; Sentinel-1; soil moisture; row vegetation; modified water cloud model; drip irrigation



**Citation:** Ayari, E.; Kassouk, Z.; Lili-Chabaane, Z.; Baghdadi, N.; Zribi, M. Investigation of Multi-Frequency SAR Data to Retrieve the Soil Moisture within a Drip Irrigation Context Using Modified Water Cloud Model. *Sensors* **2022**, *22*, 580. <https://doi.org/10.3390/s22020580>

Academic Editor: George P. Petropoulos

Received: 30 November 2021

Accepted: 10 January 2022

Published: 12 January 2022

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



**Copyright:** © 2022 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/>).

## 1. Introduction

Over the last few decades, the agricultural sector water demand has increased to ensure food security for a growing population [1,2]. In arid and semi-arid areas, the irrigated sector has increased the pressure on water resources under climatic irregularities, i.e., successive years of drought or flooding [1,3,4]. This critical situation becomes increasingly complicated with the insufficient use of water in agricultural fields [5,6]. To improve water resource management in the agricultural sector, soil moisture estimation is a key component to optimize irrigation scheduling and precision irrigation [7,8].

Remote sensing has demonstrated a high potential to retrieve soil moisture from agricultural field scales to regional scales owing to the resolution and repetition frequency of remote-sensing data acquisitions compared to punctual measurements of the soil moisture [9–12]. Based on synthetic aperture radar (SAR) data, many studies have been devoted

to soil moisture estimation in the X-, C- and L-bands [12–29]. The developed approaches to estimate soil moisture using SAR data generally have not considered the heterogeneity of soil moisture at a pixel scale which remains a persistent challenge.

To relate radar signals to in situ measurements, such as soil moisture and roughness [30] and biophysical vegetation parameters across covered fields, different radar backscattering models have been employed [31,32]. Some of the aforementioned models are based on physical approaches, such as the Karam model based on the physical interactions of electromagnetic waves with vegetation [33,34], and semi-empirical approaches, such as the Michigan microwave canopy scattering model that divides the vegetation canopy into multilayer compositions [31,35–38] and the water cloud model (WCM) [18,27,39–46].

The simplicity of the WCM makes it widely used in the literature where backscattering is the sum of the contributions of three components, namely, vegetation, soil scattering attenuated with the vegetation effect and soil-vegetation interactions. Bare soil backscattering is calculated through a wide range of models coupled to the WCM including physical approaches, such as the geometric optic model (GOM) [21], integral equation model (IEM) [47], AIEM [28,48], and IEM modified by Baghdadi (IEM-B) [18,49], and semi-empirical approaches, such as the Oh model [50–52] or empirical models requiring calibration and validation (particularly exponential [21,53] or linear relationships [43,44], respectively).

In previous studies relying on the WCM, the soil–vegetation interaction term has generally not been considered. However, some studies have proposed different expressions for this term, e.g., as a function of the Fresnel reflectivity and volume scattering coefficients in [36,37] or via calibrated semi-empirical equations in [21,49]. To evaluate the vegetation effect, various studies have explored the impact of canopy descriptors such as biophysical parameters (crop height, leaf area index, biomass, vegetation coverage fraction or vegetation water content) [38,51,54], SAR polarization ratios [51,55–58] or indices derived from optical images, such as the normalized difference vegetation index (NDVI) [18,43,44,49,59].

To estimate the soil moisture within a homogenous vegetation context, several techniques have been employed to invert models, including direct inversion [44,49], change detection [29,60,61], Bayesian approaches [62], look-up tables [49,52] and artificial neural networks (ANNs) [23,63–67].

WCM parametrization of vegetation and soil variables has been performed based on experimental data relating the model performance to the quality and robustness of in situ data [32]. The scientific community has dedicated considerable effort to improving the accuracy of the WCM. Therefore, different versions of the WCM have been reported in the literature, demonstrating a notable improvement in the simplified WCM under corresponding assumptions [16,38,47,68,69]. Zhang et al. [21] suggested a modified version of the WCM using the vegetation proportion based on the hypothesis that vegetation does not cover pixels with the same proportion across the various growth stages. As a result, the total backscattering signal was determined as the sum of the vegetation coverage fraction contribution and the proportion of bare soil backscattering. The obtained soil moisture retrieval results using artificial neural networks (ANNs) trained by X-band data yielded maximum RMSE values of 4.3 vol.%, 4.6 vol.%, and 6.4 vol.% for the three corn growth stages: emergence, trefoil, and jointing stages, respectively.

He et al. [47] proposed a modified WCM under relatively sparse vegetation conditions. They separated the contributions of covered and underlying ground according to the vegetation coverage fraction calculated as a function of the normalized difference vegetation index. Consequently, using C-band SAR data, the backscattering coefficients modeled with a modified version of the WCM achieved a higher sensitivity to patchy vegetation conditions than did the simplified WCM. The RMSE value, characterizing the relationships between the measured backscattering and predicted coefficients, decreased from 2.04 dB to 1.40 dB and from 2.45 dB to 1.69 dB in HH and VV polarizations, respectively. This approach provided a higher soil moisture estimation accuracy, and the RMSE values were smaller than 3.4 vol.%. Bao et al. [16] proposed an improved WCM based on the

Taylor approximation using Sentinel-1 data. Model validation yielded an RMSE value of approximately 5.3 vol.% for soil moisture estimation.

Most studies have been developed to retrieve soil moisture using C- and X-band SAR data rather than L-band data due to the limited availability of SAR data at the L-band frequency. The Japan Aerospace Exploration Agency (JAXA) provides Advanced Land Observing Satellite (ALOS) and ALOS-2 L-band images on request. In the near future, the European Space Agency (ESA) will deploy the Radar Observing System for Europe–L-band (ROSE-L) Mission for land and geohazard monitoring, where soil moisture retrieval is one of the main objectives [70]. Therefore, actual scientific research should consider the potential of L-band data to estimate soil parameters, such as the roughness and soil moisture content.

Regarding covered fields, Zribi et al. [18] explored the potential of ALOS-2 L-band data to estimate the soil moisture in tropical areas, as applied to turmeric and marigold vegetation, thereby providing an accuracy lower than 8.7 vol.% and 11 vol.% in HH and HV polarizations, respectively. In semi-arid areas, Ayari et al. [49] proposed an approach to retrieve the soil moisture content in cereal fields using the NDV as a vegetation descriptor in the WCM with L-band data rather than C-band data. The developed approach improved the soil moisture estimation accuracy using L-band data in HV polarization, and the root mean square error (RMSE) value was smaller than 7 vol.%, thus highlighting the potential of the IEM-B model coupled with the WCM for soil moisture estimation in the HH polarization case. Wang et al. [52] focused on WCM parametrization using L-band data as a vegetation descriptor under VH polarization. The overall accuracy of soil moisture estimation was improved, and the unbiased root mean squared error (ubRMSE) values on soil moisture were smaller than 9.8 vol.% across different crop types (canola, corn, beans, and wheat).

Referring to the previously mentioned works, the L-band data potential for soil moisture estimation should be explored within other contexts and assumptions. For example, radar signal modeling across spatially heterogeneous agricultural fields remains a challenge, as most approaches have been developed for homogeneous crop fields, such as cereal fields. Furthermore, localized irrigation is a source of complexity in SAR signal modeling and subsequent soil moisture estimation. In the case of drip irrigation, soil moisture is not distributed homogeneously across the entire plot [71].

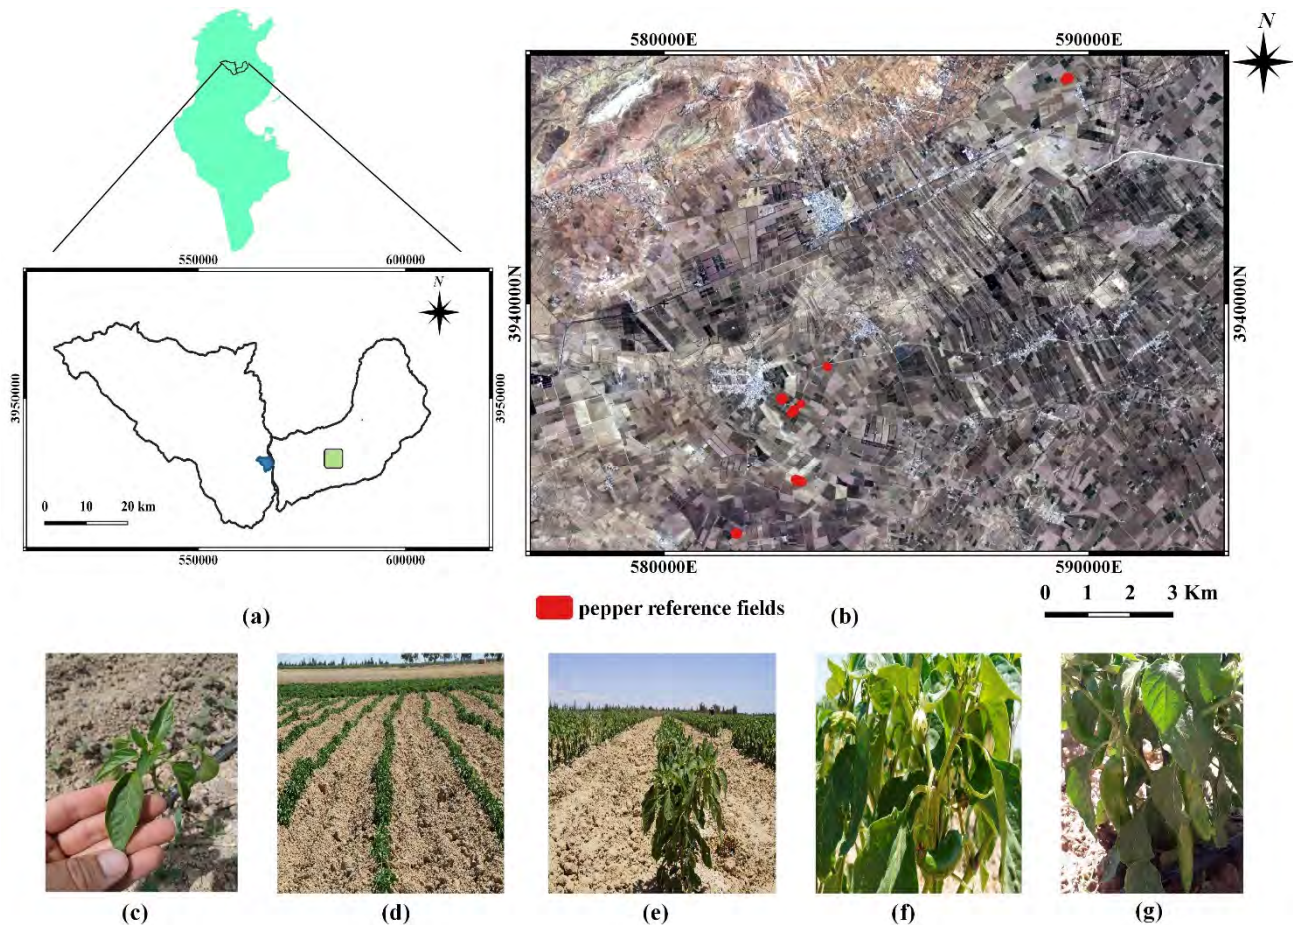
Hence, this work aims to compare the L-band and the C-band potentials for soil moisture retrieval under the same conditions, i.e., locally irrigated heterogeneous crops using a modified version of the water cloud model. This article is divided into five sections. Section 2 describes the study zone and the dataset used, including satellite images, and gathered data (soil properties and biophysical parameters) and presents the proposed methodology for radar signal modeling and soil moisture estimation. Section 3 details the results and discusses them and is divided into four parts: radar sensitivity to soil moisture heterogeneity, radar sensitivity to heterogeneous vegetation cover parameters, calibration, and validation of the modified WCM and sensitivity of the modified WCM to soil moisture. Section 4 draws conclusions.

## 2. Materials and Methods

### 2.1. Study Site

The present study was carried out in a semi-arid area: the Merguellil Plain (9°23′0–10°17′0 E, 35°10′0–35°55′0 N) in the Kairouan Plain, central Tunisia, as shown in Figure 1. The Kairouan Plain is a flat landscape extending over 3000 km<sup>2</sup> receiving approximately 300 mm of precipitation annually with a rainy season ranging from September to April and a summer season with almost no rainfall. The temperature varies between 11 and 30 °C. The Kairouan Plain water table is fed by surface infiltration and transferred from several water tables, such as Bouhaffna, Haffouz-Chrichira and Ain El Bidha. The study area is characterized by large, irrigated fields of cereal, olive tree and market garden crops [72]. As a result, the irrigation water demand increase has enhanced the pressure exerted on the

aquifer, leading to overexploitation reflected by a decrease in the water level between 0.25 and 1 m per year [73].



**Figure 1.** (a) Location of the study area in the Kairouan Plain at the center of Tunisia (red mark). (b) Reference pepper fields in the study area delimited by Sentinel-2 images in yellow. Photos of selected pepper growth stages in the reference fields (c) leaf development stage (d) pepper crop rows during leaf development stage (e) flowering stage (f) fruit development stage (g) fruit ripening stage.

In the study area, pepper is a leading seasonal garden crop in the summer. For three months starting from June, reference fields soil is ploughed and fertilized to prepare seed beds. After transplanting, pepper seedlings were drip irrigated. The drip irrigation is supplied by lines of irrigation tape and spaced emitters. Subsequently, leaves start to develop until inflorescence emergence and flowering. Afterwards, the flowers transform to fruits. The mature peppers are harvested multiple times until the senescence of pepper plants.

## 2.2. Dataset Description

### 2.2.1. Satellite Images

#### (a) Optical data: Sentinel-2


After the launch of Sentinel-2 (S-2) A and B on 23 June 2015 and 7 March 2017, respectively, optical data became free and open access with a spatial resolution varying between  $10\text{ m} \times 10\text{ m}$  and  $60\text{ m} \times 60\text{ m}$ , and a revisit time of up to 5 days in 13 spectral bands at visible and mid-infrared wavelengths. In the present study, we used S-2 surface reflectance products downloaded from the Theia site (<https://www.theia-land.fr/>, accessed on 8 January 2022), already orthorectified and atmospherically corrected with a mask of clouds and shadows owing to the MAJA algorithm.

On each acquisition date and using red visible and near infrared bands with center wavelengths of approximately 665 and 833 nm, respectively, we calculated the *NDVI* and averaged this index for each reference field as expressed in the following equation [18,44,74,75]:

$$NDVI = \frac{R_{NIR} - R_{Red}}{R_{NIR} + R_{Red}} \quad (1)$$

where  $R_{NIR}$  and  $R_{Red}$  are the surface reflectance in the two bands, near infrared and red visible, respectively [76].

Figure 2 describes the evolution of *NDVI* values during the summer season over one pepper field. *NDVI* values are varying between 0.16 and 0.38 corresponding to the development of pepper plant leaves and fruit ripening, respectively, starting from June until the middle of July. *NDVI* values decrease to 0.34 corresponding to the first fruit harvest date. Afterwards, *NDVI* values oscillate between 0.34 and 0.58 where minimum values mark harvest events as identified by red arrows in the figure accompanied with manual weeding.



**Figure 2.** Normalized difference vegetation index (*NDVI*) values evolution during the summer season of 2020 over a pepper reference field in the Kairouan Plain where red arrows indicate pepper harvest accompanied by hand weeding.

(b) SAR data


- Sentinel-1

Eight C-band SAR images were acquired by Sentinel-1 A (S-1 A) and B (S-1 B) constellation between June and August 2020 over the study area, as described in Table 1. Sentinel-1 data are produced as ground range-detected (GRD) data and generated in the interferometric wide-swath (IW) mode. Owing to the launch of Sentinel-1 A and B sensors, C-band data are available in vertical-vertical (VV) and vertical-horizontal (VH) polarizations at an incidence angle of approximately  $39^\circ$  for the Kairouan plain site, with a spatial resolution of  $10 \text{ m} \times 10 \text{ m}$  and a revisit time of up to 6 days. In regard to the S-1 products, several processing steps were carried out involving thermal noise removal, radiometric calibration, terrain correction based on a Shuttle Radar Topography Mission (SRTM) digital elevation model (DEM) with a 30 m resolution and speckle filtering with a Lee filter.

**Table 1.** Available synthetic aperture radar (SAR) image characteristics acquired in 2020 by Advanced Land Observing Satellite-2 (ALOS-2) in Horizontal-Horizontal (HH) and Horizontal-Vertical (HV) polarizations and Sentinel-1 A (S-1 A) and B (S-1 B) in Vertical-Vertical (VV) and Vertical- Horizontal (VH) polarizations.

Date	Incidence Angle	Sensor	Polarization Scheme	Ascending/Descending State
8 June 2020	32.5°	ALOS-2	HH + HV	Descending
17 June 2020	39°	S-1 A	VV + VH	Ascending
22 June 2020	32.5°	ALOS-2	HH + HV	Descending
24 June 2020	39°	S-1 B	VV + VH	Descending
5 July 2020	39°	S-1 B	VV + VH	Ascending
6 July 2020	39°	S-1 B	VV + VH	Descending
20 July 2020	32.5°	ALOS-2	HH + HV	Descending
23 July 2020	39°	S-1 A	VV + VH	Ascending
3 August 2020	32.5°	ALOS-2	HH + HV	Descending
4 August 2020	39°	S-1 A	VV + VH	Ascending
16 August 2020	39°	S-1 A	VV + VH	Ascending
17 August 2020	32.5°	ALOS-2	HH + HV	Descending
17 August 2020	39°	S-1 A	VV + VH	Descending

Figure 3 shows the temporal variation of Sentinel-1 data for one pepper field during acquisition dates as a function of precipitations recorded by the climatic station of Sidi Ali Ben Salem. According to Figure 3, one rainfall event of approximately 1.7 mm was recorded on 27 June 2020 along the acquisition chronology. Between 5 July 2020 and 4 August 2020, slight variations characterize the temporal evolution of C-VV and C-VH data. Starting from 4 August 2020 to 28 August 2020, C-VV decreased by 3.11 dB when rainfall was absent. From 4 August 2020 to 16 August 2020, C-VH evolution is rather stable, with small oscillations.




**Figure 3.** C-band Sentinel-1 backscattering coefficients (sigma) in dual-polarization VV and VH at an incidence angle of 39° and the precipitation quantity temporal evolutions during June, July, and August 2020.

- ALOS-2

Advanced Land Observing Satellite-2 (ALOS-2) images are acquired at the L-band frequency by the Phased Array Synthetic Aperture Radar (PALSAR). According to Table 1, five ALOS-2 SAR images were obtained in the stripmap mode between June and August 2020

over the study area. Radar images were available in dual polarizations, i.e., horizontal-horizontal (HH) and horizontal-vertical (HV), at an incidence angle of  $32.5^\circ$  for the study zone with a spatial resolution of  $6\text{ m} \times 6\text{ m}$  and a revisit cycle of 14 days. Radiometric calibration was performed based on the available data to transform digital values into backscattering coefficients on a linear scale. Georeferencing of ALOS-2 data was carried out through a control points method, as detected using *NDVI* images calculated from Sentinel-2 optical data with a root mean square (RMS) control point error smaller than 0.5 pixels [18,49].


Figure 4 shows the temporal behavior of the ALOS-2 signal as function of recorded precipitations. Three rainfall events marked the chronology on 8 June 2020, 9 June 2020 and 27 June 2020 with by low intensities of 3.41 mm, 0.4 mm, and 1.6 mm, respectively. Between 8 June 2020 and 22 June 2020, the L-HH signal decreased by 0.61 dB and L-HV increased by 1.46 dB. L-band sigma increased by 1.96 and 2.13 dB for L-HH and L-HV, respectively, from 22 June 2020 to 20 July 2020. During precipitation absence between 20 July 2020 and 17 August 2020, ALOS-2 signal increased by 1.90 dB in HH polarization and by 1.14 dB in HV polarization. Due to the limited number of ALOS-2 acquisitions, the interpretation of L-band signal temporal behavior remains complicated in the present case. According to Figures 3 and 4, we can notice the absence of correlations between SAR data evolutions and rainfalls because signals are lower in accordance with precipitations. In this case, the presence of irrigations probably affects the SAR signal more than rainfall.



**Figure 4.** L-band ALOS-2 backscattering coefficients (sigma) in dual-polarization HH and HV at an incidence angle of  $32.5^\circ$  and precipitation quantity temporal evolutions during June, July, and August 2020.

### 2.2.2. In Situ Measurements

During S-1 and ALOS-2 acquisitions (between June and August 2020), data gathering campaigns were conducted in seven irrigated reference pepper fields in the Sidi Ali Ben Salem area in the Kairouan Plain. Reference fields were considered to measure soil surface properties (roughness and soil moisture) and vegetation parameters (leaf area index, fraction cover and height of vegetation cover). The surface area of these fields varied between 1 and 2.6 ha. As shown in Figure 5, the pepper coverage is heterogeneous with a directional vegetation structure. Each pepper field comprised vegetation rows with local drip irrigation. An approximate distance of 0.35 m separated two pepper plants within one row. The inter-row spacing was 1 m and consisted of bare soil.



**Figure 5.** Pepper reference field architecture: delineation of the bare soil and vegetation parts, where the green spots represent pepper plants and the black lines represent the irrigation tape, based on ground truth scaling and illustrations.

(a) Soil moisture ( $Mv$ )

In the row crop case with drip irrigation, the soil moisture spatial pattern is heterogeneous: the water content in the soil below vegetation is different from that in the bare soil part. As a result, soil moisture measurements were performed at a depth of 5 cm and with a hand-held Theta probe in each test field at 10 points randomly chosen in the bare soil part and 10 points in the soil part below vegetation. The moisture measurements were completed within two hours separating the measurements and the satellite overpass time.

Within this context, we obtained soil moisture measurements collected over bare soils, namely, inter-row soil moisture  $Mv_{inter-row}$  varying between 4.9 vol.% and 31.4 vol.%, and soil moisture measurements collected over the underlying pepper plants soil, namely  $Mv_{veg-row}$  fluctuating between 5.6 vol.% and 32.1 vol.%, during all campaigns, as detailed by the minimum and the maximum values in Table 2. The inter-rows moisture is impacted exceptionally by water loss from irrigation systems which increase the soil moisture values.

**Table 2.** The minimum and maximum values of in situ measurements during the data gathering campaign in 2020. Root mean square surface height  $Hr_{ms}$ , correlation length  $L_c$ , soil moisture  $Mv$  (inter-row soil moisture  $Mv_{inter-row}$  and vegetation-influenced moisture  $Mv_{veg-row}$ ) and pepper parameters (height, Leaf Area Index (LAI), and cover fraction ( $F_c$ )).

Date	Measurements						
	$Hr_{ms}$ (cm)	$L_c$ (cm)	$Mv_{inter-row}$ (vol.%)	$Mv_{veg-row}$ (vol.%)	Height (m)	LAI ( $m^2/m^2$ )	$F_c$
8 June 2020	[1.84–2.54]	[2.98–7.40]	[4.90–6.10]	[12.50–17.50]	[0.19–0.40]	[0.15–0.18]	[0.20–0.33]
17 June 2020	[1.84–2.54]	[2.98–7.40]	[5.70–10.70]	[9.40–23.50]	-	-	-
22 June 2020	-	-	[5.50–21.10]	[5.60–27.60]	[0.17–0.41]	[0.07–0.56]	[0.08–0.43]
24 June 2020	-	-	[5.50–21.10]	[5.60–27.60]	[0.17–0.41]	[0.07–0.56]	[0.08–0.43]
5 July 2020	[1.50–2.54]	[2.98–7.40]	[5.80–27]	[6.80–28.50]	[0.22–0.42]	[0.20–0.45]	[0.20–0.50]
6 July 2020	-	-	[5.80–27]	[6.80–28.50]	[0.22–0.42]	[0.20–0.45]	[0.20–0.50]
20 July 2020	[1.50–2.54]	[2.98–7.40]	[6.40–31.40]	[8.90–30.90]	[0.27–0.55]	[0.30–0.71]	[0.21–0.38]
23 July 2020	[1.50–2.54]	[2.98–7.40]	-	-	[0.22–0.56]	[0.32–0.71]	[0.25–0.38]
3 August 2020	[1.50–2.54]	[2.98–7.40]	[6.80–24.10]	[9.80–31]	[0.35–0.63]	[0.38–0.90]	[0.33–0.46]
4 August 2020	-	-	[6.80–20.10]	[9.80–31]	-	-	-
16 August 2020	[1.50–2.54]	[2.98–7.40]	[5.30–29.50]	[10.80–32.10]	[0.39–0.64]	[0.50–1.75]	[0.17–0.46]
17 August 2020	-	-	[5.30–29.50]	[10.80–32.10]	[0.39–0.64]	[0.50–1.75]	[0.17–0.46]

For each reference field, we calculated an average soil moisture value based on the hypothesis that bare soil, characterized by  $Mv_{inter-row}$ , covered the proportion  $\alpha$  of the field area and  $1 - \alpha$  was covered by rows of pepper plants equipped by irrigation tapes,



characterized by  $Mv_{veg-row}$ . Consequently, the average soil moisture value at the field scale was calculated with the following expression:

$$Mv = \alpha \times Mv_{inter-row} + (1 - \alpha) \times Mv_{veg-row} \quad (2)$$

According to the ground truth observations, we estimated that 15% of the field area is covered by irrigation tapes and emitters. The rest of the area, which is equal to 85%, receives irrigation water through water transfers in the soil. As a result, the measured soil moisture is the result of the contribution of soil moisture next to the emitters and 85% of the soil moisture off the irrigation zone. Therefore, in the present study, we consider that  $\alpha$  is equal to 0.85.

(b) Soil roughness

The soil roughness was characterized with a 1 m pin profiler exhibiting a pin spacing of 2 cm using six roughness profiles (three perpendicular and three parallel to the inter-row tillage direction). These profiles were digitized to calculate statistical parameters of the soil roughness, namely, the root mean square of the height (Hrms) and correlation length (Lc), as mentioned in [44,49]. Hrms varied between 1.5 and 2.54 cm, and the Lc value varied between 2.98 and 7.40 cm.

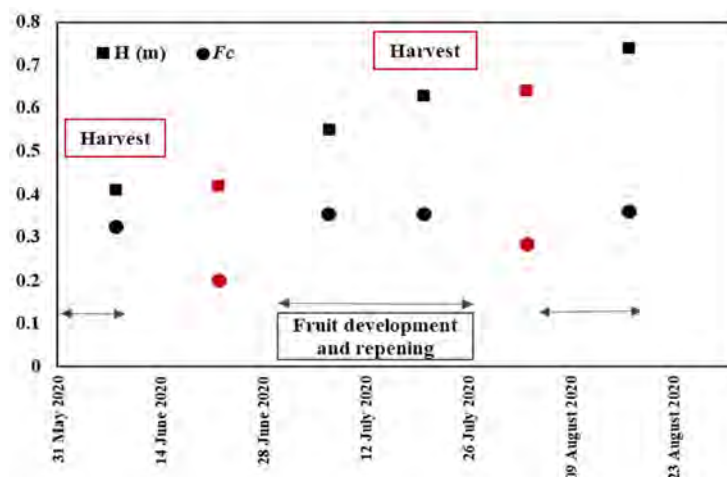
(c) Vegetation height (H)

During SAR data acquisition, as indicated in Table 2, 20 measurements of the pepper height (H) were obtained in each reference field on each date. The vegetation height could reach a maximum value of 0.64 m.

(d) Vegetation cover fraction ( $F_c$ ) and Leaf area index (LAI)

In various studies, the vegetation cover fraction has been calculated as a function of the NDVI derived from optical images with the dimidiate pixel model (DPM) [77]. In the present work, we estimated the LAI and vegetation cover fraction for each pepper field through 20 hemispherical digital images, as mentioned in [44,49,74].

The LAI value varied from 0.07 to 1.75. The pepper cover fraction ( $F_c$ ) value fluctuated across the various growth stages between 0.1 and 0.5, covering the four pepper phenological stages starting with vegetative growth at the end of June, followed by flowering, fruit setting and fruit formation. Figure 6 represents the evolution of  $F_c$  and H measured over a pepper reference field where harvest event dates were different to the chosen fields in Section 2.2.1 (a). According to Figure 6, the highest values were observed at the flowering and fruit setting stages when the pepper plants reached the maximum leaf growth level. The lowest values characterized fruit harvest events accompanied by hand weeding.



**Figure 6.** The temporal evolution of pepper biophysical parameters: Vegetation cover fraction ( $F_c$ ) and vegetation height (H) during the pepper growth cycle where red arrows indicate fruit harvest events.

### 2.3. Methodology

In the present section, we detail the adopted methodology to simulate the L-HH and C-VV SAR signal over covered vegetation fields. The reference fields are characterized by spatial heterogeneous vegetation coverage which lead to inter-pixel heterogeneous spatial repartition of the soil moisture. Therefore, we used a modified version of WCM to consider the different component of pepper fields. The modified WCM is coupled with IEM-B to simulate SAR signal over bare soil.

#### 2.3.1. Modified Water Cloud Model (WCM)

Attema and Ulaby in 1978 [39] proposed a semi-empirical model, the WCM, as a first-order approximation of the radiation transferred from vegetation canopies by considering that the vegetation response to radar signals consists of effects attributed to soil and the vegetation cover [31,78]. In regard to radar signals (in pq polarization), the total backscattering ( $\sigma^0_{\text{total}, pq}$ ) comprises the vegetation contribution ( $\sigma^0_{\text{veg}, pq}$ ), soil contribution attenuated by vegetation ( $\tau^2 \sigma^0_{\text{soil}, pq}$ ) and soil-vegetation term ( $\sigma^0_{\text{soil-veg}, pq}$ ), which has been mostly neglected. As a result, the WCM is expressed with the following equations (Equations (3)–(5)):

$$\sigma^0_{\text{total}, pq} = \sigma^0_{\text{veg}, pq} + \tau^2 \sigma^0_{\text{soil}, pq} \quad (3)$$

$$\tau^2 = \exp(-2 \times B \times V1 \times \sec \theta) \quad (4)$$

$$\sigma^0_{\text{veg}, pq} = A \times V2 \times \cos \theta \times (1 - \tau^2) \quad (5)$$

where  $A$  and  $B$  are parameters that depend on the characteristics of the vegetation canopy and SAR configurations and  $V1$  and  $V2$  are vegetation descriptors.

As mentioned above, parameters  $V1$  and  $V2$  have been determined based on vegetation parameters. Several works have particularly considered information retrieved from optical data to characterize these parameters, especially the  $NDVI$  [43,44,49].

The  $NDVI$  values were averaged for each pepper reference field characterized by vegetation rows separated by 1 m of bare soil. Consequently, the calculated  $NDVI$  values were affected by bare soil describing the total field and not only the vegetation such in homogeneous vegetation cover cases. Additionally, LAI measurements expressed the surface leaf of pepper seedlings per unit of soil area. In a spatial heterogeneous case, the soil area contribution is present and dominates the vegetation presence in the hemispherical photos. In this context, for the present study case, we propose to use the vegetation height as the parameter to describe the cover dynamics outside the bare soil zone. Thus, we consider  $V1 = V2 = H$  in this study as pepper descriptor without the bare soil part. In fields with vegetation crop rows, the above simplified version of the WCM, initially proposed for homogenous regions, is not applicable due to the heterogeneous spatial distribution of pepper plants. Hence, [21,47] introduced ancillary information on the vegetation fraction ( $Fc$ ). Consequently, the vegetation contribution in the WCM was delineated by the cover fraction.

In the study case involving the pepper field organization, we considered a combination of two contributions. The first contribution  $\sigma^0_{\text{veg-row}, pq}$  is that of the pepper row weighted by the cover fraction ( $Fc$ ), and the other contribution  $\sigma^0_{\text{inter-row}, pq}$  is that of inter-rows of the pepper part, weighted by  $(1 - Fc)$ :

$$\sigma^0_{\text{field}, pq} = Fc \times \sigma^0_{\text{veg-row}, pq} + (1 - Fc) \times \sigma^0_{\text{inter-row}, pq} \quad (6)$$

where  $\sigma^0_{\text{inter-row}, pq}$  is the bare soil backscattering term separating two pepper rows simulated with IEM-B and  $\sigma^0_{\text{veg-row}, pq}$  is the total contribution of the vegetation rows.

The total contribution of pepper rows  $\sigma^0_{\text{veg-row}, pq}$  is the sum of the first term  $\sigma^0_{\text{veg}, qp}$  representing the volume scattering contribution of the vegetation and the soil effect attenuated by the vegetation cover  $\sigma^0_{\text{bare-soil}, pq}$ . The bare soil scattering term is divided into two terms:

the first term  $\sigma_{under-veg}^0$  corresponds to the irrigated area (under peppers seedlings locally irrigated), and the second term  $\sigma_{inter-veg}^0$  corresponds to the non-irrigated area. This last one is around pepper plants and separating two successive peppers seedlings, relatively far from water emitters and consequently non-irrigated. These two contributions  $\sigma_{under-veg}^0$  and  $\sigma_{inter-veg}^0$  are weighted according to the corresponding fractions. As specified above, the locally irrigated area is approximately covering  $0.15 \text{ m}^2$  per one  $\text{m}^2$  ( $\frac{0.15}{Fc}$ ) of the row crop area. Therefore, the pepper row vegetation contribution is expressed as:

$$\sigma_{veg-row,qp}^0 = \sigma_{veg,qp}^0 + \tau^2 \sigma_{bare-soil,pq}^0 \quad (7)$$

$$\sigma_{veg-row,qp}^0 = \sigma_{veg,qp}^0 + \tau^2 \left( \frac{0.15}{Fc} \times \sigma_{under-veg}^0 + \frac{Fc - 0.15}{Fc} \times \sigma_{inter-veg}^0 \right) \quad (8)$$

where  $\sigma_{under-veg}^0$  and  $\sigma_{inter-veg}^0$  are simulated with the IEM-B model.

### 2.3.2. Integral Equation Model Modified by Baghdadi (IEM-B)

Several models have been employed to relate soil properties to the backscattering process, such as the physics-based integral equation model proposed by [79]. The IEM simulates electromagnetic wave scattering from a randomly rough surface using radar sensor characteristics as inputs (frequency, polarization, and incidence angle) and a height autocorrelation function (exponential or Gaussian). Despite the satisfactory accuracy of the IEM in SAR signal behavior simulation across bare soil regions over other empirical and semi-empirical models, the roughness description parameter Lc exhibits some measurement incertitude.

Therefore, references [80–83] proposed an updated version of IEM, namely IEM-B, by replacing the Lc parameter with the fitting parameter Lopt as a function of the Hrms value and radar parameters (polarization and incidence angle  $\theta$ ). In this paper, we adopted the IEM-B model to generate bare soil backscattering values employing calibrated correlation lengths in the C-band in VV polarization (C-VV) and the L-band in HH polarization (L-HH), as expressed in Equations (9) and (10), respectively:

$$\text{Lopt}(\text{Hrms}, \theta, \text{CVV}) = 1.281 + 0.134 \times (\sin(0.19 \times \theta))^{-1.59} \times \text{Hrms} \quad (9)$$

$$\text{Lopt}(\text{Hrms}, \theta, \text{LHH}) = 2.6590 \times \theta^{-1.4493} + 3.0484 \text{ Hrms} \times \theta^{-0.8044} \quad (10)$$

where  $\theta$  is the incidence angle in degrees in Equation (9) and  $\theta$  is the incidence angle in radian in Equation (10) and Lopt and Hrms are expressed in cm. The formulation of Lopt was obtained with the Gaussian correlation function.

### 2.3.3. Statistical Precision Parameters

Linear correlation coefficient  $R$  was adopted to evaluate the strength of the linear relationships between the radar signals and in situ measurements, as expressed in Equation (11). To assess the accuracy of model calibration and validation, we considered the root mean square error (RMSE) and bias, as expressed in Equations (12) and (13), respectively:

$$R = \sqrt{\frac{(\sum_i^N (x_i - \bar{x})(y_i - \bar{y}))^2}{\sum_i^N (x_i - \bar{x})^2 \sum_i^N (y_i - \bar{y})^2}} \quad (11)$$

$$\text{Bias} = \frac{1}{N} \sum_{i=0}^N (x_i - y_i) \quad (12)$$

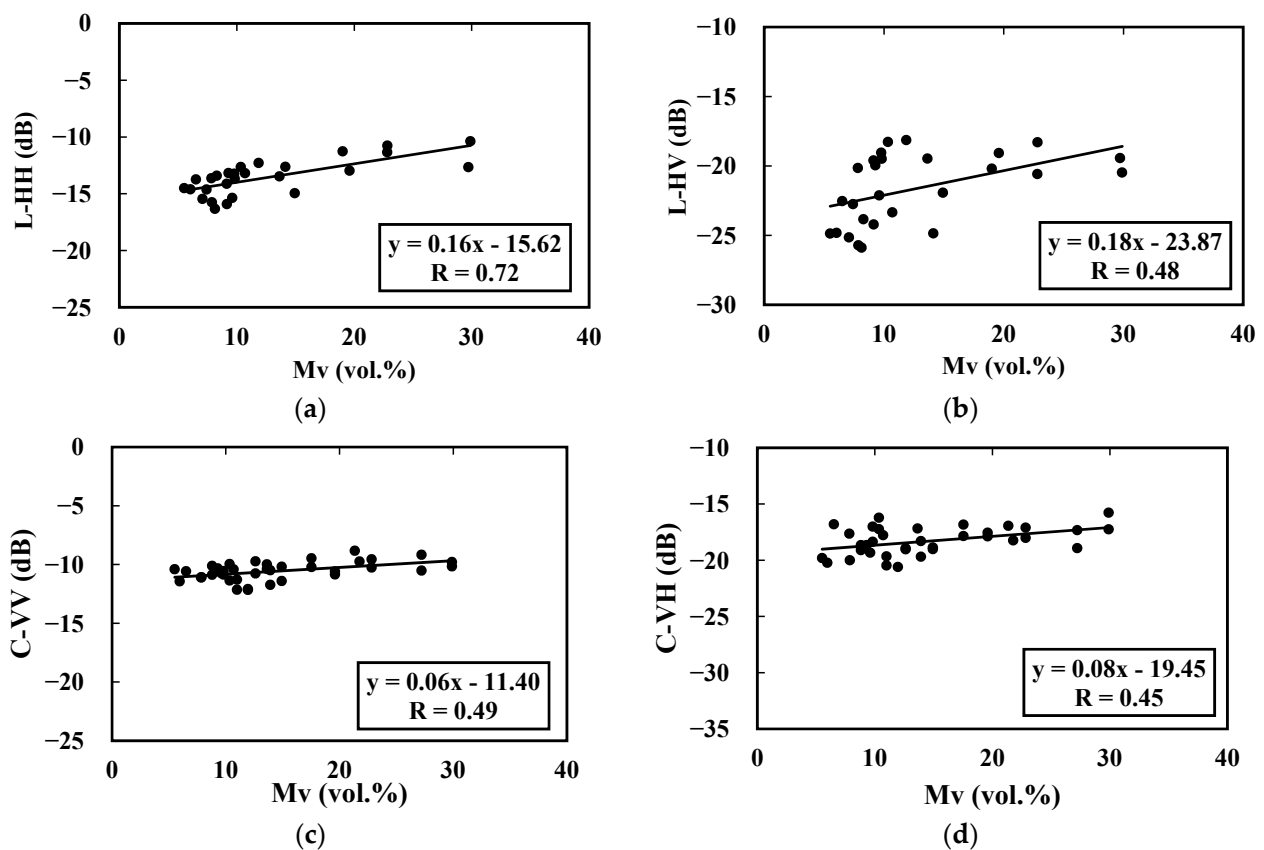
$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=0}^N (x_i - y_i)^2} \quad (13)$$

where  $x_i$  and  $y_i$  are the values of individual samples collected at points indexed with sample number  $i$  in Equation (11).  $x_i$  and  $y_i$  are the predicted and measured values, respectively, of sample  $i$  among  $N$  total data samples in Equations (12) and (13).

### 3. Results

#### 3.1. Radar (Advanced Land Observing Satellite-2 (ALOS-2) and Sentinel-1) Sensitivity to Soil Moisture

In this section, we evaluate the influence of soil moisture on the L- and C-band radar signals at the different pepper growth stages, where the pepper height value varies between 0.17 and 0.64 m, the LAI value fluctuates between 0.07 and 1.75 and  $F_c$  is less than 0.5. The objective is to conduct a preliminary analysis to detect possible soil moisture effects in high-heterogeneity context of soil moisture and vegetation cover. Figure 7 shows the linear relationships between the ALOS-2 and Sentinel-1 data and soil moisture values calculated as mentioned in the second section based on Equation (2). Regarding the C-band data, we observe a limited correlation between radar data and soil moisture. The correlation coefficient values throughout the pepper growth cycle are lower than 0.49, revealing the limited sensitivity of the C-band to soil moisture, with a slope value varying between 0.06 dB/vol.% and 0.08 dB/vol.% in VV and VH polarizations, respectively.

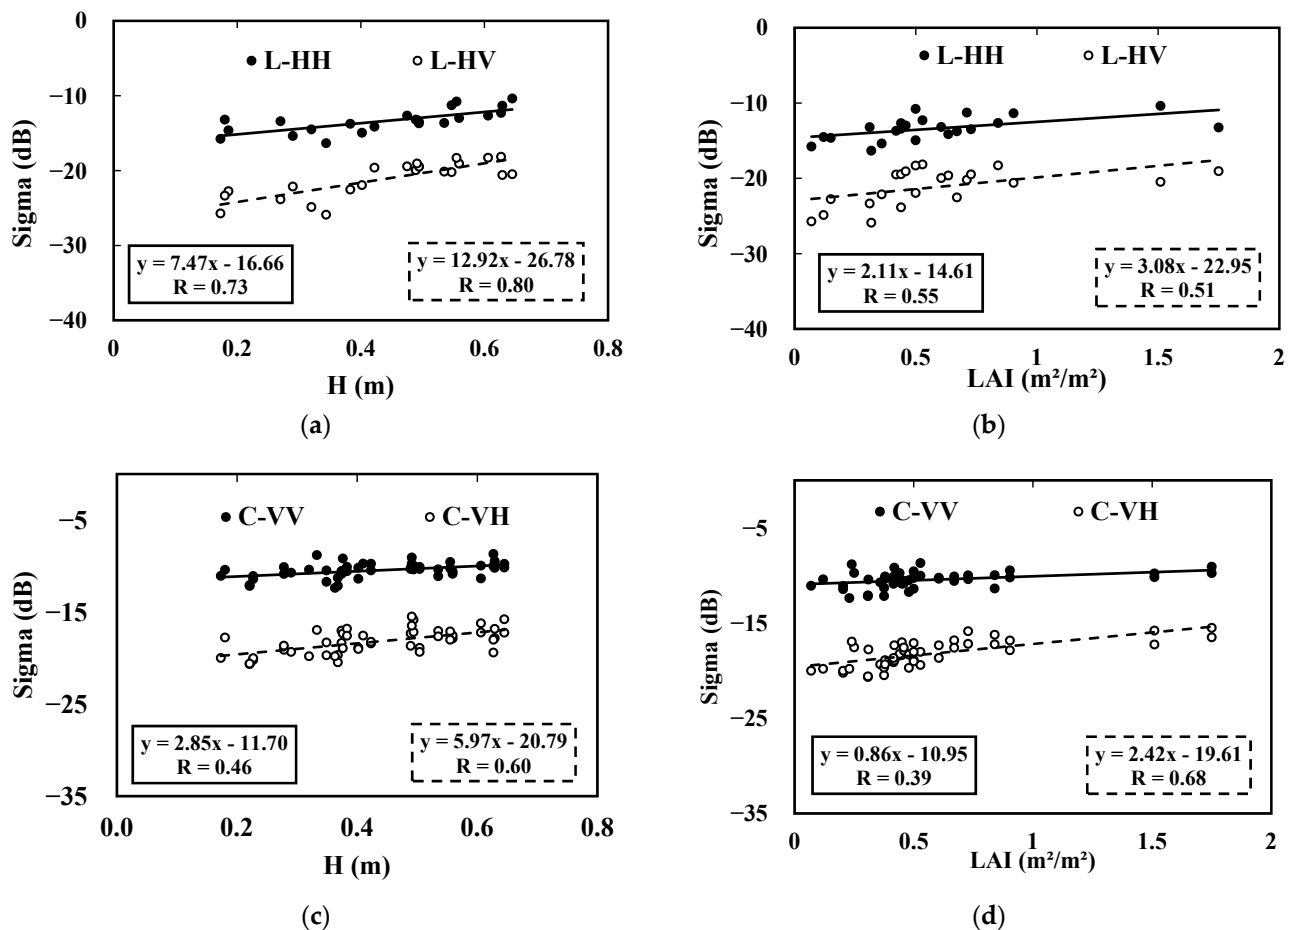


**Figure 7.** ALOS-2 and Sentinel-1 data as a function of soil moisture: L-band in (a) HH and (b) HV polarizations and C-band in dual-polarizations (c) VV and (d) VH.

The initial results confirm the sensitivity of the L-band data to the average soil moisture. The sensitivity of the radar signals to soil moisture is approximately identical between the HH and HV polarizations, at 0.16 dB/vol.% and 0.18 dB/vol.%, respectively. However, the correlation is much stronger in the case of HH data. This can be explained by the volume scattering effect of the vegetation cover, which is much greater in the case of cross-polarization.

### 3.2. Radar (ALOS-2 and Sentinel-1) Sensitivity to Vegetation

Figure 8 presents the linear relationships between the SAR signals and pepper biophysical parameters, i.e., vegetation height, and LAI. A high correlation characterizes the L-band data as a function of the vegetation height. The correlation coefficients range from 0.80 to 0.73 in the L-HV and L-HH configurations, respectively, with lower correlation coefficient values for the Sentinel-1 data varying between 0.6 and 0.46 in the C-VH and C-VV configurations, respectively.



**Figure 8.** SAR signals as a function of biophysical vegetation parameters: L-band data as function of (a) H and (b) LAI and C-band data as function of (c) H and (d) LAI.

Regarding the LAI parameter, radar sensitivity increases from 2.11  $dB \cdot m^2/m^2$  to 3.08  $dB \cdot m^2/m^2$  using L-HH and L-HV, respectively. C-band sensitivity increases from 0.86  $dB \cdot m^2/m^2$  in VV polarization to 2.42  $dB \cdot m^2/m^2$  in VH polarization. We also observe some sensitivity in the L-HH, L-HV, C-VV and C-VH configurations but with low R values of 0.55, 0.51, 0.39 and 0.68, respectively. This could be explained by the fact that LAI information is mainly related to the upper canopy layer and corresponds to a mean value comprehensively without reflecting the heterogenous spatial vegetation cover.

The vegetation height information reflects the canopy structure the most. Therefore, the L-band exhibits a higher sensitivity to this parameter (7.47  $dB/m$  and 12.92  $dB/m$  for HH and HV polarizations, respectively) thanks to its greater wave penetration.

The C-band sensitivities to vegetation height vary between 2.85  $dB/m$  and 5.97  $dB/m$  for VV and VH polarizations, respectively. Within all contexts, a higher sensitivity to vegetation of the cross-polarization signals in the L-band or C-band is observed. This is related to their notable response to vegetation volume scattering. The abovementioned results

emphasize the higher sensitivity of the SAR data in the cross-polarization configuration than that in the co-polarization configuration (L-HH and C-VV), as mentioned in [84].

The comparison between the L- and C-band behaviors reveals that the radar signals increase with increasing pepper development, as manifested by the increase of radar signal as function of H and LAI. Macelloni et al. [85] examined low-frequency radar behavior in covered fields as a function of the crop leaf nature, where L- and C-band SAR data increased as a function of the LAI for broad-leaf crops and decreased for narrow-leaf crops.

The same behavior was observed in previous studies using C-band [44,49,86] and X-band SAR data [63]. According to the results obtained, we investigated and analyzed the potential of co-polarized SAR data, namely, HH polarization data in the L-band and VV polarization data in the C-band, to limit the volume scattering effect on soil moisture retrieval in the following sections.


### 3.3. Calibration and Validation of the Modified WCM

In this section, we simulate the radar signal behavior in pepper fields through calibration and validation of the proposed model, as expressed in Equations (4) and (5). Based on the radar sensitivity results in Section 3.2, we adopt the vegetation height as a pepper descriptor in the following sections.

Modified WCM calibration and validation were carried out through the threefold cross-validation method due to the limited data samples (30 samples for L-band data and 32 samples for C-band data). This method consisted of a resampling procedure starting with random shuffling of the dataset followed by splitting into three partitions of equal size. With each partition, we calibrated the proposed model on 2/3 of the whole dataset, and we validated the model against 1/3 of the dataset. In each step, we evaluated the method performance by calculating the statistical parameters of the bias and RMSE.

Hence, A and B were calibrated three times. We only retained the most accurate calibration results in the subsequent steps. The A parameter values varied between 0.27 and 0.5 and B values fluctuated between 0.5 and 2.68, for L-HH and C-VV, respectively. The best WCM calibration performance was characterized by RMSE values ranging from 0.58 dB to 1.33 dB for the C-VV and L-HH data, respectively. The slightly higher RMSE in the L band could be explained by a greater roughness effect and surely a greater sensitivity to the entire canopy structure at this frequency band.

Figure 9 shows the validation results with an intercomparison of the SAR signals and backscattering coefficient model simulations. The RMSE value ranges from 1.26 dB to 1.54 dB, and the bias value fluctuates between  $-0.08$  dB and  $0.29$  dB for the C-VV and L-HH data, respectively.



**Figure 9.** Comparison of the radar data and simulated backscattering coefficients in the pepper fields: (a) C-VV configuration and (b) L-HH configuration.

### 3.4. Radar Backscattering Simulations with the Modified WCM

In this section, we analyze the behavior of the backscattering coefficient as function of soil moisture using the calibrated modified WCM in the case of pepper fields, considering a large range of vegetation and soil conditions: bare soil moisture ranging from 5 to 40 vol.%, underlying soil moisture ranging from 10 to 40 vol.%, pepper height ranging from 0.1 to 0.7 m, and vegetation cover fraction ranging from 0.1 to 0.6. Table 3 summarizes all these parameters values. In this case, the soil moisture variation is principally controlled by irrigation and rainfall events. For instance, the increase in bare soil moisture is induced by rainfall, which generally increases the field average soil moisture content in the bare soil and pepper-covered soil parts. Furthermore, irrigation events increase the vegetation-influenced soil moisture. Therefore, we assume that the bare soil moisture level is always equal to or lower than the pepper plant-influenced soil moisture level to ensure the representativeness of the proposed model simulations.


**Table 3.** The parameter values variation used in model simulation: soil moisture (vol.%) and pepper parameters (height and cover fraction  $F_c$ ).

Parameter		Values
Soil moisture	$Mv_{inter-row}$ (vol.%)	5, 10, 20, 30, 40
	$Mv_{veg-row}$ (vol.%)	10, 20, 30, 40
Biophysical parameters	Height (m)	0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7
	$F_c$	0.1, 0.2, 0.3, 0.4, 0.5, 0.6


In all simulations, we consider the hypothesis of constant roughness parameters ( $H_{rms} = 0.8$  cm and  $L_c = 5$  cm) as input into the IEM-B model to minimize the roughness effect. The principle of this analysis encompasses fixing a given condition and varying the other conditions to evaluate the slope of the linear relationships between soil moisture and modeled backscattering coefficients in the L-HH and C-VV configurations. We simulate the SAR backscattering coefficients with constant values of the cover fraction. At each value of the pepper coverage fraction, we varied the vegetation height level and recorded the slope (dB/vol.%).

To better investigate the model sensitivity with vegetation parameter variation, we generated 3D surface scatter plots of the modified WCM sensitivity to the different soil moisture values according to the above established linear relationships as a function of the cover fraction and vegetation height (Figure 10) under different soil moisture conditions. With the use of L-HH data (Figure 10a), a high sensitivity was found at a low vegetation cover fraction and small height despite the smaller slope values starting at a height of 0.5 m and an  $F_c$  value of 0.4. Regarding C-VV data (Figure 10b), the model sensitivity decreased from 0.2 dB/vol.% at low  $F_c$  and H values to 0 dB/vol.% at an  $F_c$  value of 0.3 and a pepper height of 0.3 m.

To further investigate the evolution of model sensitivities as function of vegetation height and cover fraction, we have chosen to present 2D profiles extracted from Figure 10 where  $F_c$  values are equal to 0.1, 0.3 and 0.6. At each constant value of  $F_c$ , we scatterplot, the proposed model sensitivity to soil moisture as function of pepper height using the SAR data (L-HH and C-VV) under inter-row soil moisture values equal to 5 vol.%, 20 vol.% and 40 vol.% (Figure 11).



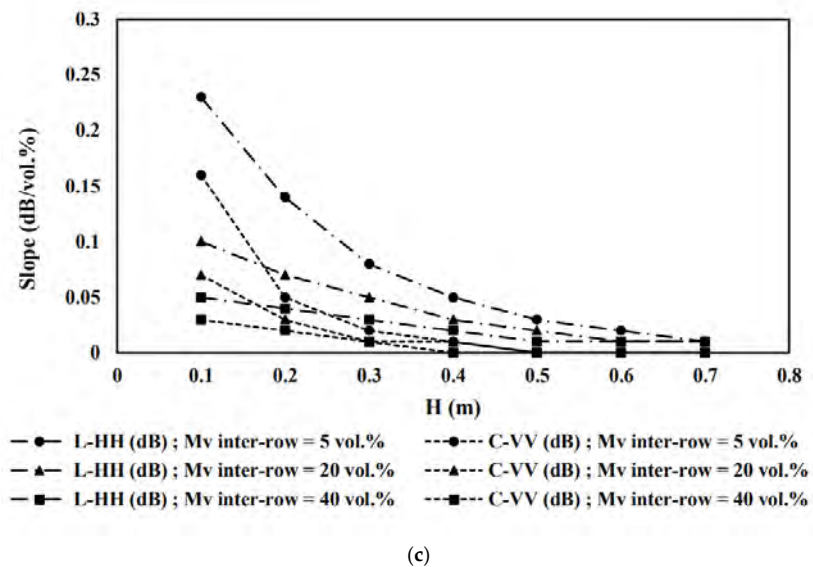


(a)



(b)

**Figure 10.** Three-dimensional surface scatter plot of the modified WCM sensitivities to soil moisture as a function of the pepper vegetation height and cover fraction using (a) L-HH and (b) C-VV data.





**Figure 11.** Scatterplots of the modified WCM sensitivities to soil moisture as a function of the pepper vegetation height ( $H$ ) using L-HH and C-VV data in three different contexts of inter-rows soil moisture (5 vol.%, 20 vol.% and 40 vol.%) with constant values of cover fraction (a)  $F_c = 0.1$ , (b)  $F_c = 0.3$  and (c)  $F_c = 0.6$ .

Figure 11a represents simulation results when cover fraction is equal to 0.1 in different soil moisture contexts. Globally, the model sensitivities decrease as function of pepper height increase. Using L-HH data, the model sensitivities vary from 0.25 to 0.10 dB/vol.%.

Using C-VV data, the simulation slope fluctuates between 0.17 dB/vol.% and 0 dB/vol.%. For a vegetation height equal to 0.1 m, L-HH sensitivities vary from 0.25 to 0.05 dB/vol.% regarding a slope between 0.17 and 0.03 dB/vol.% using C-VV for  $Mv_{inter-row}$  values equal to 5 and 40 vol.%, respectively. When the vegetation height increases to 0.4 m, L-HH sensitivity still higher than 0.1 dB/vol.% for inter-row soil moisture equal to 5 vol.%, regarding slopes lower than of 0.03 dB/vol.% for C-VV case under the different  $Mv_{inter-row}$  contexts.

Pepper height reaches its maximum at 0.7 m. For this case, L-HH signal slopes vary from 0.05 dB/vol.% to 0.01 dB/vol.% regarding zero values for C-VV simulations. With the increase of pepper's height, the dynamic of model sensitivities, using L-HH data, decreases from 0.20 dB/vol.% to 0.04 dB/vol.% for H values equal to 0.1 m and 0.7 m, respectively. We notice low sensibility characterizing C-VV simulations where sensitivity decrease from 0.14 dB/vol.% to be null, for vegetation heights equal to 0.1 m and 0.7 m, respectively. Under low vegetation cover fraction ( $F_c = 0.1$ ), the comparison between L-HH and C-VV simulation results reveals that the modified WCM, using L-HH data, remains sensitive to soil moisture as function of the increase pepper height and the inter-rows soil water content. However, the proposed model using C-VV becomes insensitive to soil moisture with the vertical development of pepper plants. This C-band behavior is induced from a strong attenuation of the signal over peppers.

According to the Figure 11b, the same trends were noticed for L-HH and sensitivities as shown in the Figure 11a but with a lower sensitivity dynamic for a  $F_c$  value equal to 0.3. Using L-HH data, the slope variation is between 0.19 dB/vol.%, 0.05 dB/vol.% and 0.01 dB/vol.% when H values are equal to 0.1 m, 0.4 m, and 0.7 m, respectively, under three contexts of the inter-row soil moisture. Using C-VV data, sensitivity dynamic starts from 0.13 dB/vol.% to be 0.01 dB/vol. % and then null for three H values equal to 0.1 m, 0.4 m, and 0.7 m, respectively. Figure 11c shows the scatterplot of the model sensitivities as function of pepper height where cover fraction is equal to 0.6 under the different context of inter-row soil moisture. The sensitivity to soil moisture fluctuates between 0.23 dB/vol.% and 0.01 dB/vol.% for L-HH data and between 0.16 dB/vol.% and 0.03 dB/vol.% for C-VV data, for a vegetation height value equal to 0.1 m and  $Mv_{inter-row}$  values varying between 5 and 40 vol.%. With the increase of pepper height, sensitivity variation, using C-VV, decreases to be null where H values reach 0.4 m.

The examination of the three profiles reveals the following conclusions. The modified WCM sensitivity decreases as function of the increase of pepper biophysical parameters: vertically (pepper height) and horizontally (cover fraction) and inter-row soil moisture values. For constant values of cover fraction values, the dynamics of the sensitivity to soil moisture decreases as function of the increase of pepper height. This decrease may indicate the domination of bare soil the total backscattering mechanism until the pepper height reaches the value of 0.3 m for the C-VV signal and 0.5 m for the L-HH signal. Subsequently, vegetation backscattering contribution increases with the pepper growth regarding the decrease of bare soil impact.

The comparison of simulation results underlines that model sensitivity based on C-VV data decreases more rapidly than does that based on L-HH data as a function of the pepper cover fraction and height and the soil water content. The L-HH data sensitivity declines and remains relatively higher than the C-VV data sensitivity given the same values of  $F_c$  and H. The aforementioned results also highlight the potential of the modified WCM to simulate SAR signals in the pepper reference fields. Conversely, the proposed model potential should be further explored considering other heterogeneous plants under drip irrigation via a comparison to the present study.

#### 4. Conclusions

This study proposes an analysis of the potential of SAR data for soil moisture retrieval in drip-irrigated pepper fields in semiarid areas at the center of Tunisia, i.e., the Kairouan Plain, using L- and C-band SAR data. By considering that 15% of the field area is influenced by drip irrigation and that the remaining area is dominated by non-irrigated bare soil, we analyzed the sensitivity of radar signal to the weighted soil moisture content (Mv). According to the initial sensitivity analysis to detect possible soil moisture effects under a high soil moisture heterogeneity where the pepper height varied between 0.17 and 0.64 m, the LAI value fluctuated between 0.07 and 1.75 and Fc was lower than 0.5, the results revealed that the L-HH data were more sensitive than were the C-VV data to the soil water content. The sensitivity decreased from 0.16 dB/vol.% in L-HH case to 0.06 dB/vol.% using C-VV. Regarding cross-polarized data, volume scattering generated noise, which impacted the sensitivity of SAR signal where R values were lower than 0.48 for both the L-HV and C-VH data. The radar signal sensitivity was investigated as a function of two pepper biophysical properties: vegetation height and LAI.

Radar signal sensitivity analysis of these pepper biophysical parameters revealed a high correlation of the linear relationships between the SAR data and vegetation height compared to the LAI parameter. Based on the results, we proposed a modified version of the WCM. In this model, we considered the vegetation height as a vegetation descriptor and we used the cover fraction to separate the backscattering mechanisms of the bare soil and vegetation row parts. To simulate SAR signals, the suggested model parameters required calibration and validation via the three-fold cross-validation method. The best calibration RMSE values ranged from 0.58 dB for the C-VV data to 1.33 dB for the L-HH data. The validation accuracy parameters, namely, the bias and RMSE, varied between 0.29 dB and 1.54 dB for the L-HH data and between  $-0.08$  dB and 1.26 dB for the C-VV data.

We evaluated the sensitivity of the suggested model to soil moisture. The results highlighted the potential of the modified version of the WCM to simulate ALOS-2 and Sentinel-1 signals over inter-pixel heterogeneous soil moisture context. This potential is impacted by the inter-vegetation rows moisture content and the variation of vegetation biophysical parameters (pepper height and vegetation cover fraction). Using L-HH data, the proposed model remained sensitive to soil moisture where sensitivity values vary between 0.25 dB/vol.% and 0.08 dB/vol.% at a vegetation height and a cover fraction values less than 0.5 m and 0.4, respectively, where inter-row soil moisture value is equal to 5 vol.%. Under the same soil moisture context, the model sensitivity, using C-VV data, decreased from 0.17 dB/vol.% to 0.08 dB/vol.% at a vegetation height less than 0.3 m and a cover fraction value lower than 0.3. The aforementioned vegetation biophysical parameters thresholds vary as function of the inter-row vegetation soil moisture contexts.

One of the limitations of the proposed semi-empirical approach is its dependence on the database used and the study objectives. Hence, the suggested approach should be tested at other sites. The inversion process of the modified WCM coupled with the IEM-B model for soil moisture retrieval purposes is complex to realize. Therefore, machine-learning algorithms, such as artificial neural networks (ANNs), will be applied in future work to estimate the soil water content.

**Author Contributions:** E.A., M.Z., Z.K. and Z.L.-C. conceived and designed the experiments; E.A. performed the experiments; E.A. and M.Z. analyzed the data; E.A., M.Z., Z.K., Z.L.-C. and N.B. contributed to the materials/analysis tools; E.A. and M.Z. wrote the paper. All authors have read and agreed to the published version of the manuscript.

**Funding:** This study was funded by the Viana (ERA-Net ARIMNet) Project; the PHC Utique IPASS Project; the Chaams (ERANET3-602 CHAAMS) Project; the Irrigation+ ((ESA n°4000129870/20/I-NB) Project; and the TAPAS TOSCA/CNES project.

**Data Availability Statement:** Data are available in Theia Land site <https://www.theia-land.fr/> (accessed on 8 January 2022).

**Acknowledgments:** We extend our warm thanks to the technical teams at the IRD and INAT (Institut National Agronomique de Tunisie) who participated in the ground truth measurement campaigns and data processing.

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

## References

- Cai, X.; Rosegrant, M.W. Global Water Demand and Supply Projections: Part 1. A Modeling Approach. *Water Int.* **2002**, *27*, 159–169. [[CrossRef](#)]
- FAO; FIDA; OMS; PAM et UNICEF. *L'État de la Sécurité Alimentaire et de la Nutrition dans le Monde 2021. Transformer les Systèmes Alimentaires Pour que la Sécurité Alimentaire, une Meilleure Nutrition et une Alimentation Saine et Abordable Soient une Réalité Pour Tous*; FAO: Rome, Italy, 2021; ISBN 9789251316016.
- Abioye, E.A.; Abidin, M.S.Z.; Mahmud, M.S.A.; Buyamin, S.; AbdRahman, M.K.I.; Otuoze, A.O.; Ramli, M.S.A.; Ijike, O.D. IoT-based monitoring and data-driven modelling of drip irrigation system for mustard leaf cultivation experiment. *Inf. Process. Agric.* **2020**, *8*, 270–283. [[CrossRef](#)]
- Tramblay, Y.; Koutroulis, A.; Samaniego, L.; Vicente-Serrano, S.M.; Volaire, F.; Boone, A.; Le Page, M.; Llasat, M.C.; Albergel, C.; Burak, S.; et al. Challenges for drought assessment in the Mediterranean region under future climate scenarios. *Earth-Sci. Rev.* **2020**, *210*, 103348. [[CrossRef](#)]
- Pereira, L.S.; Oweis, T.; Zairi, A. Irrigation management under water scarcity. *Agric. Water Manag.* **2002**, *57*, 175–206. [[CrossRef](#)]
- Rosa, L.; Chiarelli, D.D.; Rulli, M.C.; Angelo, J.D.; Odorico, P.D. Global agricultural economic water scarcity. *Sci. Adv.* **2020**, *6*, eaaz6031. [[CrossRef](#)]
- Amiri, Z.; Gheysari, M.; Mosaddeghi, M.R.; Amiri, S.; Tabatabaei, M.S.; Ozdogan, M.; Yang, Y.; Allez, G.; Cervantes, C.; Wolff, P.; et al. Remote sensing of irrigated agriculture: Opportunities and challenges. *Remote Sens.* **2010**, *2*, 2274–2304. [[CrossRef](#)]
- Massari, C.; Modanesi, S.; Dari, J.; Gruber, A.; De Lannoy, G.J.M.; Girotto, M.; Quintana-Seguí, P.; Le Page, M.; Jarlan, L.; Zribi, M.; et al. A review of irrigation information retrievals from space and their utility for users. *Remote Sens.* **2021**, *13*, 4112. [[CrossRef](#)]
- Motte, E.; Zribi, M.; Fanise, P.; Egido, A.; Darrozes, J.; Al-Yaari, A.; Baghdadi, N.; Baup, F.; Dayau, S.; Fieuzal, R.; et al. GLORI: A GNSS-R Dual Polarization Airborne Instrument for Land Surface Monitoring. *Sensors* **2016**, *16*, 732. [[CrossRef](#)]
- El Hajj, M.; Baghdadi, N.; Zribi, M.; Bazzi, H. Synergic use of Sentinel-1 and Sentinel-2 images for operational soil moisture mapping at high spatial resolution over agricultural areas. *Remote Sens.* **2017**, *9*, 1292. [[CrossRef](#)]
- Zribi, M.; André, C.; Decharme, B. A method for soil moisture estimation in Western Africa based on the ERS scatterometer. *IEEE Trans. Geosci. Remote Sens.* **2008**, *46*, 438–448. [[CrossRef](#)]
- Sekertekin, A.; Marangoz, A.M.; Abdikan, S.; Esetlili, M.T. Preliminary results of estimating soil moisture over bare soil using full-polarimetric ALOS-2 data. In Proceedings of the International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences—ISPRS Archives, Istanbul, Turkey, 16–17 October 2016.
- Wang, C.; Qi, J.; Moran, S.; Marsset, R. Soil moisture estimation in a semiarid rangeland using ERS-2 and TM imagery. *Remote Sens. Environ.* **2004**, *90*, 178–189. [[CrossRef](#)]
- Gherboudj, I.; Magagi, R.; Berg, A.A.; Toth, B. Soil moisture retrieval over agricultural fields from multi-polarized and multi-angular RADARSAT-2 SAR data. *Remote Sens. Environ.* **2011**, *115*, 33–43. [[CrossRef](#)]
- Attarzadeh, R.; Amini, J.; Notarnicola, C.; Greifeneder, F. Synergetic use of Sentinel-1 and Sentinel-2 data for soil moisture mapping at plot scale. *Remote Sens.* **2018**, *10*, 1285. [[CrossRef](#)]
- Bao, Y.; Lin, L.; Wu, S.; Abdalla, K.; Deng, K.; Petropoulos, G.P. Surface soil moisture retrievals over partially vegetated areas from the synergy of Sentinel-1 and Landsat 8 data using a modified water-cloud model. *Int. J. Appl. Earth Obs. Geoinf.* **2018**, *72*, 76–85. [[CrossRef](#)]
- Hosseini, M.; McNairn, H.; Mitchell, S.; Dingle Robertson, L.; Davidson, A.; Homayouni, S. Synthetic aperture radar and optical satellite data for estimating the biomass of corn. *Int. J. Appl. Earth Obs. Geoinf.* **2019**, *83*, 101933. [[CrossRef](#)]
- Zribi, M.; Muddu, S.; Bousbih, S.; Al Bitar, A.; Tomer, S.K.; Baghdadi, N.; Bandyopadhyay, S. Analysis of L-band SAR data for soil moisture estimations over agricultural areas in the tropics. *Remote Sens.* **2019**, *11*, 1122. [[CrossRef](#)]
- Bazzi, H.; Baghdadi, N.; Fayad, I.; Zribi, M.; Belhouchette, H.; Demarez, V. Near real-time irrigation detection at plot scale using sentinel-1 data. *Remote Sens.* **2020**, *12*, 1456. [[CrossRef](#)]
- Ezzahar, J.; Ouadi, N.; Zribi, M.; Elfarkh, J.; Aouade, G.; Khabba, S.; Er-Raki, S.; Chehbouni, A.; Jarlan, L. Evaluation of backscattering models and support vector machine for the retrieval of bare soil moisture from sentinel-1 data. *Remote Sens.* **2020**, *12*, 72. [[CrossRef](#)]
- Zhang, L.; Lv, X.; Chen, Q.; Sun, G.; Yao, J. Estimation of surface soil moisture during corn growth stage from SAR and optical data using a combined scattering model. *Remote Sens.* **2020**, *12*, 1844. [[CrossRef](#)]
- Zribi, M.; Foucras, M.; Baghdadi, N.; Demarty, J.; Muddu, S. A New Reflectivity Index for the Retrieval of Surface Soil Moisture from Radar Data. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2021**, *14*, 818–826. [[CrossRef](#)]
- Baghdadi, N.; Cresson, R.; El Hajj, M.; Ludwig, R.; La Jeunesse, I. Estimation of soil parameters over bare agriculture areas from C-band polarimetric SAR data using neural networks. *Hydrol. Earth Syst. Sci.* **2012**, *16*, 1607–1621. [[CrossRef](#)]

24. Baghdadi, N.; Cresson, R.; Pottier, E.; Aubert, M.; Zribi, M.; Jacome, A.; Benabdallah, S. A potential use for the C-band polarimetric SAR parameters to characterize the soil surface over bare agriculture fields. *IEEE Trans. Geosci. Remote Sens.* **2012**, *50*, 3844–3858. [[CrossRef](#)]
25. Aubert, M.; Baghdadi, N.N.; Zribi, M.; Ose, K.; El Hajj, M.; Vaudour, E.; Gonzalez-Sosa, E. Toward an operational bare soil moisture mapping using terrasar-x data acquired over agricultural areas. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2013**, *6*, 900–916. [[CrossRef](#)]
26. Baghdadi, N.N.; El Hajj, M.; Zribi, M.; Fayad, I. Coupling SAR C-Band and Optical Data for Soil Moisture and Leaf Area Index Retrieval over Irrigated Grasslands. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2016**, *9*, 1229–1243. [[CrossRef](#)]
27. El Hajj, M.; Baghdadi, N.; Cheviron, B.; Belaud, G.; Zribi, M. Integration of remote sensing derived parameters in crop models: Application to the PILOTE model for hay production. *Agric. Water Manag.* **2016**, *176*, 67–79. [[CrossRef](#)]
28. Bai, X.; He, B.; Li, X.; Zeng, J.; Wang, X.; Wang, Z.; Zeng, Y.; Su, Z. First assessment of Sentinel-1A data for surface soil moisture estimations using a coupled water cloud model and advanced integral equation model over the Tibetan Plateau. *Remote Sens.* **2017**, *9*, 714. [[CrossRef](#)]
29. Gao, Q.; Zribi, M.; Escorihuela, M.J.; Baghdadi, N. Synergetic use of sentinel-1 and sentinel-2 data for soil moisture mapping at 100 m resolution. *Sensors* **2017**, *17*, 1966. [[CrossRef](#)] [[PubMed](#)]
30. Zribi, M.; Ciarletti, V.; Taconet, O. Validation of a Rough Surface Model Based on Fractional Brownian Geometry with SIRC and ERASME Radar Data over Orgeval. *Remote Sens. Environ.* **2000**, *73*, 65–72. [[CrossRef](#)]
31. Whitt, M.W.; Ulaby, F.T. Radar Response of Periodic Vegetation Canopies. *Int. J. Remote Sens.* **1994**, *15*, 1813–1848. [[CrossRef](#)]
32. Steele-Dunne, S.C.; McNairn, H.; Monsivais-Huertero, A.; Judge, J.; Liu, P.W.; Papathanassiou, K. Radar Remote Sensing of Agricultural Canopies: A Review. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2017**, *10*, 2249–2273. [[CrossRef](#)]
33. Karam, M.A.; Fung, A.K.; Antar, Y.M.M. Electromagnetic Wave Scattering from Some Vegetation Samples. *IEEE Trans. Geosci. Remote Sens.* **1988**, *26*, 799–808. [[CrossRef](#)]
34. Karam, M.A.; Amar, F.; Fung, A.K.; Mougine, E.; Lopes, A.; Le Vine, D.M.; Beaudoin, A. A microwave polarimetric scattering model for forest canopies based on vector radiative transfer theory. *Remote Sens. Environ.* **1995**, *53*, 16–30. [[CrossRef](#)]
35. Ulaby, F.T.; Sarabandi, K.; McDonald, K.; Whitt, M.; Dobson, M.C. Michigan microwave canopy scattering model. *Int. J. Remote Sens.* **1990**, *11*, 1223–1253. [[CrossRef](#)]
36. De Roo, R.D.; Du, Y.; Ulaby, F.T.; Craig Dobson, M. A semi-empirical backscattering model at L-band and C-band for a soybean canopy with soil moisture inversion. *IEEE Trans. Geosci. Remote Sens.* **2001**, *39*, 864–872. [[CrossRef](#)]
37. Du, J.; Shi, J.; Sun, R. The development of HJ SAR soil moisture retrieval algorithm. *Int. J. Remote Sens.* **2010**, *31*, 3691–3705. [[CrossRef](#)]
38. Weiß, T.; Ramsauer, T.; Löw, A.; Marzahn, P. Evaluation of Different Radiative Transfer Models for Microwave Backscatter Estimation of Wheat Fields. *Remote Sens.* **2020**, *12*, 3037. [[CrossRef](#)]
39. Attema, E.P.W.; Ulaby, F.T. Vegetation modeled as a water cloud. *Radio Sci.* **1978**, *13*, 357–364. [[CrossRef](#)]
40. Ulaby, F.T.; Allen, C.T.; Eger, G.; Kanemasu, E. Relating the microwave backscattering coefficient to leaf area index. *Remote Sens. Environ.* **1984**, *14*, 113–133. [[CrossRef](#)]
41. Dabrowska-Zielinska, K.; Inoue, Y.; Kowalik, W.; Gruszczynska, M. Inferring the effect of plant and soil variables on C- and L-band SAR backscatter over agricultural fields, based on model analysis. *Adv. Space Res.* **2007**, *39*, 139–148. [[CrossRef](#)]
42. Kumar, K.; Prasad, K.S.H.; Arora, M.K. Estimation of water cloud model vegetation parameters using a genetic algorithm. *Hydrol. Sci. J.* **2012**, *57*, 776–789. [[CrossRef](#)]
43. Baghdadi, N. Calibration of the Water Cloud Model at C-Band for Winter Crop Fields and Grasslands. *Remote Sens.* **2017**, *9*, 969. [[CrossRef](#)]
44. Bousbih, S.; Zribi, M.; Lili-Chabaane, Z.; Baghdadi, N.; El Hajj, M.; Gao, Q.; Mougine, B. Potential of sentinel-1 radar data for the assessment of soil and cereal cover parameters. *Sensors* **2017**, *17*, 2617. [[CrossRef](#)]
45. Li, J.; Wang, S. Using SAR-derived vegetation descriptors in a water cloud model to improve soil moisture retrieval. *Remote Sens.* **2018**, *10*, 1370. [[CrossRef](#)]
46. Ouadi, N.; Jarlan, L.; Ezzahar, J.; Khabba, S.; Le Dantec, V.; Rafi, Z.; Zribi, M.; Frison, P.L. Water Stress Detection over Irrigated Wheat Crops in Semi-Arid Areas Using the Diurnal Differences of Sentinel-1 Backscatter. In Proceedings of the 2020 Mediterranean and Middle-East Geoscience and Remote Sensing Symposium (M2GARSS), Tunis, Tunisia, 9–11 March 2020; pp. 306–309. [[CrossRef](#)]
47. He, B.; Xing, M.; Bai, X. A synergistic methodology for soil moisture estimation in an alpine prairie using radar and optical satellite data. *Remote Sens.* **2014**, *6*, 10966–10985. [[CrossRef](#)]
48. Qiu, J.; Crow, W.T.; Wagner, W.; Zhao, T. Effect of vegetation index choice on soil moisture retrievals via the synergistic use of synthetic aperture radar and optical remote sensing. *Int. J. Appl. Earth Obs. Geoinf.* **2019**, *80*, 47–57. [[CrossRef](#)]
49. Ayari, E.; Kassouk, Z.; Lili-Chabaane, Z.; Baghdadi, N.; Bousbih, S.; Zribi, M. Cereal crops soil parameters retrieval using L-band ALOS-2 and C-band sentinel-1 sensors. *Remote Sens.* **2021**, *13*, 1393. [[CrossRef](#)]
50. Paloscia, S.; Pettinato, S.; Santi, E.; Notarnicola, C.; Pasolli, L.; Reppucci, A. Soil moisture mapping using Sentinel-1 images: Algorithm and preliminary validation. *Remote Sens. Environ.* **2013**, *134*, 234–248. [[CrossRef](#)]

51. Ouadi, N.; Jarlan, L.; Ezzahar, J.; Zribi, M.; Khabba, S.; Bouras, E.; Frison, P.L. Surface Soil Moisture Retrieval over Irrigated Wheat Crops in Semi-Arid Areas Using Sentinel-1 Data. In Proceedings of the 2020 Mediterranean and Middle-East Geoscience and Remote Sensing Symposium (M2GARSS), Tunis, Tunisia, 9–11 March 2020; pp. 212–215. [[CrossRef](#)]
52. Wang, Z.; Zhao, T.; Qiu, J.; Zhao, X.; Li, R.; Wang, S. Microwave-based vegetation descriptors in the parameterization of water cloud model at L-band for soil moisture retrieval over croplands. *GISci. Remote Sens.* **2021**, *58*, 48–67. [[CrossRef](#)]
53. 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](#)]
54. Graham, A.J.; Harris, R. Extracting biophysical parameters from remotely sensed radar data: A review of the water cloud model. *Prog. Phys. Geogr.* **2003**, *27*, 217–229. [[CrossRef](#)]
55. Gao, S.; Niu, Z.; Huang, N.; Hou, X. Estimating the Leaf Area Index, height and biomass of maize using HJ-1 and RADARSAT-2. *Int. J. Appl. Earth Obs. Geoinf.* **2013**, *24*, 1–8. [[CrossRef](#)]
56. Veloso, A.; Mermoz, S.; Bouvet, A.; Le Toan, T.; Planells, M.; Dejoux, J.F.; Ceschia, E. Understanding the temporal behavior of crops using Sentinel-1 and Sentinel-2-like data for agricultural applications. *Remote Sens. Environ.* **2017**, *199*, 415–426. [[CrossRef](#)]
57. Vreugdenhil, M.; Wagner, W.; Bauer-Marschallinger, B.; Pfeil, I.; Teubner, I.; Rüdiger, C.; Strauss, P. Sensitivity of Sentinel-1 backscatter to vegetation dynamics: An Austrian case study. *Remote Sens.* **2018**, *10*, 1396. [[CrossRef](#)]
58. Gorraeb, A.; Ameline, M.; Albergel, C.; Baup, F. Use of sentinel-1 multi-configuration and multi-temporal series for monitoring parameters of winter wheat. *Remote Sens.* **2021**, *13*, 553. [[CrossRef](#)]
59. Bousbih, S.; Zribi, M.; El Hajj, M.; Baghdadi, N. Soil Moisture and Irrigation Mapping in A Semi-Arid Region, Based on the Synergetic Use of Sentinel-1. *Remote Sens.* **2018**, *22*, 1953. [[CrossRef](#)]
60. Tomer, S.K.; Al Bitar, A.; Sekhar, M.; Zribi, M.; Bandyopadhyay, S.; Sreelash, K.; Sharma, A.K.; Corgne, S.; Kerr, Y. Retrieval and multi-scale validation of Soil Moisture from multi-temporal SAR Data in a semi-arid tropical region. *Remote Sens.* **2015**, *7*, 8128–8153. [[CrossRef](#)]
61. Zhu, L.; Walker, J.P.; Ye, N.; Rüdiger, C. Roughness and vegetation change detection: A pre-processing for soil moisture retrieval from multi-temporal SAR imagery. *Remote Sens. Environ.* **2019**, *225*, 93–106. [[CrossRef](#)]
62. Pierdicca, N.; Pulvirenti, L.; Pace, G. A prototype software package to retrieve soil moisture from sentinel-1 data by using a bayesian multitemporal algorithm. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2014**, *7*, 153–166. [[CrossRef](#)]
63. El Hajj, M.; Baghdadi, N.; Belaud, G.; Zribi, M.; Cheviron, B.; Courault, D.; Hagolle, O.; Charron, F. Irrigated grassland monitoring using a time series of TerraSAR-X and COSMO-SkyMed X-Band SAR data. *Remote Sens.* **2014**, *6*, 10002–10032. [[CrossRef](#)]
64. Fieuzal, R.; Marais Sicre, C.; Baup, F. Estimation of corn yield using multi-temporal optical and radar satellite data and artificial neural networks. *Int. J. Appl. Earth Obs. Geoinf.* **2017**, *57*, 14–23. [[CrossRef](#)]
65. El Hajj, M.; Baghdadi, N.; Bazzi, H.; Zribi, M. Penetration analysis of SAR signals in the C and L bands for wheat, maize, and grasslands. *Remote Sens.* **2019**, *11*, 31. [[CrossRef](#)]
66. Mirsoleimani, H.R.; Sahebi, M.R.; Baghdadi, N.; El Hajj, M. Bare soil surface moisture retrieval from sentinel-1 SAR data based on the calibrated IEM and dubois models using neural networks. *Sensors* **2019**, *19*, 3209. [[CrossRef](#)] [[PubMed](#)]
67. Hamze, M.; Baghdadi, N.; El Hajj, M.M.; Zribi, M.; Bazzi, H.; Cheviron, B.; Faour, G. Integration of L-Band Derived Soil Roughness into a Bare Soil Moisture Retrieval Approach from C-Band SAR Data. *Remote Sens.* **2021**, *13*, 2102. [[CrossRef](#)]
68. Svoray, T.; Shoshany, M. SAR-based estimation of areal aboveground biomass (AAB) of herbaceous vegetation in the semi-arid zone: A modification of the water-cloud model. *Int. J. Remote Sens.* **2002**, *23*, 4089–4100. [[CrossRef](#)]
69. Xing, M.; He, B.; Ni, X.; Wang, J.; An, G.; Shang, J.; Huang, X. Retrieving Surface Soil Moisture over Wheat and Soybean Fields during Growing Season Using Modified Water Cloud Model from Radarsat-2 SAR Data. *Remote Sens.* **2019**, *11*, 1956. [[CrossRef](#)]
70. Davidson, M.; Chini, M.; Dierking, W.; Djavidnia, S.; Haarpaintner, J.; Hajduch, G.; Laurin, G.V.; Laval, M.; López-Martínez, C.; Nagler, T.; et al. *Copernicus L-band SAR Mission Requirements Document*; ESA-EOPSM-CLIS-MRD-3371; ESA: Paris, France, 2019.
71. Amiri, Z.; Gheysari, M.; Mosaddeghi, M.R.; Amiri, S.; Tabatabaei, M.S. An Attempt to Find a Suitable Place for Soil Moisture Sensor in a Drip Irrigation System. *Inf. Process. Agric.* **2021**; in press. [[CrossRef](#)]
72. Amri, R. Estimation Régionale de L'évapotranspiration sur la Plaine de Kairouan (Tunisie) à Partir de Données Satellites Multi-capteurs École. Ph.D. Thesis, Université Paul Sabatier, Toulouse, France, 2013; p. 176.
73. Leduc, C.; Ammar, S.B.E.N.; Favreau, G.; Beji, R.; Virrion, R. Impacts of hydrological changes in the Mediterranean zone: Environmental modifications and rural development in the Merguellil catchment, central Tunisia. *Hydrol. Sci. J./J. Des Sci. Hydrol.* **2007**, *52*, 1162–1178. [[CrossRef](#)]
74. Zribi, M.; Chahbi, A.; Shabou, M.; Lili-Chabaane, Z.; Duchemin, B.; Baghdadi, N.; Amri, R.; Chehbouni, A. Soil surface moisture estimation over a semi-arid region using ENVISAT ASAR radar data for soil evaporation evaluation. *Hydrol. Earth Syst. Sci.* **2011**, *15*, 345–358. [[CrossRef](#)]
75. Bousbih, S.; Zribi, M.; Pelletier, C.; Gorraeb, A.; Lili-Chabaane, Z.; Baghdadi, N.; Aissa, N.B.; Mougénot, B. Soil texture estimation using radar and optical data from Sentinel-1 and Sentinel-2. *Remote Sens.* **2019**, *11*, 1520. [[CrossRef](#)]
76. Rouse, J.W.; Haas, R.H.; Schell, J.A.; Deering, D.W. *Monitoring the Vernal Advancement and Retrogradation (Green Wave Effect) of Natural Vegetation*; Progress Report RSC 1978-1; Texas A & M University, Remote Sensing Center: College Station, TX, USA, 1973; p. 112.
77. Gutman, G.; Ignatov, A. The derivation of the green vegetation fraction from NOAA/AVHRR data for use in numerical weather prediction models. *Int. J. Remote Sens.* **1998**, *19*, 1533–1543. [[CrossRef](#)]
78. Ulaby, F.T. Radar Response to Vegetation. *IEEE Trans. Antennas Propag.* **1975**, *23*, 36–45. [[CrossRef](#)]

79. Fung, A.K.; Li, Z.; Chen, K.S. Backscattering from a Randomly Rough Dielectric Surface. *IEEE Trans. Geosci. Remote Sens.* **1992**, *30*, 356–369. [[CrossRef](#)]
80. Baghdadi, N.; Gherboudj, I.; Zribi, M.; Sahebi, M.; King, C.; Bonn, F. Semi-empirical calibration of the IEM backscattering model using radar images and moisture and roughness field measurements. *Int. J. Remote Sens.* **2004**, *25*, 3593–3623. [[CrossRef](#)]
81. Baghdadi, N.; Holah, N.; Zribi, M. Soil moisture estimation using multi-incidence and multi-polarization ASAR data. *Int. J. Remote Sens.* **2006**, *27*, 1907–1920. [[CrossRef](#)]
82. Baghdadi, N.; Abou Chaaya, J.; Zribi, M. Semiempirical calibration of the integral equation model for SAR data in C-Band and cross polarization using radar images and field measurements. *IEEE Geosci. Remote Sens. Lett.* **2011**, *8*, 14–18. [[CrossRef](#)]
83. Baghdadi, N.; Zribi, M.; Paloscia, S.; Verhoest, N.E.C.; Lievens, H.; Baup, F.; Mattia, F. Semi-empirical calibration of the integral equation model for co-polarized L-band backscattering. *Remote Sens.* **2015**, *7*, 13626–13640. [[CrossRef](#)]
84. Inoue, Y.; Kurosu, T.; Maeno, H.; Uratsuka, S.; Kozu, T.; Dabrowska-Zielinska, K.; Qi, J. Season-long daily measurements of multifrequency (Ka, Ku, X, C, and L) and full-polarization backscatter signatures over paddy rice field and their relationship with biological variables. *Remote Sens. Environ.* **2002**, *81*, 194–204. [[CrossRef](#)]
85. Macelloni, G.; Paloscia, S.; Pampaloni, P.; Marliani, F.; Gai, M. The relationship between the backscattering coefficient and the biomass of narrow and broad leaf crops. *IEEE Trans. Geosci. Remote Sens.* **2001**, *39*, 873–884. [[CrossRef](#)]
86. Fieuzal, R.; Baup, F.; Marais-Sicre, C. Monitoring Wheat and Rapeseed by Using Synchronous Optical and Radar Satellite Data—from Temporal Signatures to Crop Parameters Estimation. *Adv. Remote Sens.* **2013**, *2*, 162–180. [[CrossRef](#)]

### III.4. Conclusions

Dans cette étude, nous avons comparé le potentiel des données en bande C et en bande L pour estimer l'humidité du sol dans deux contextes agricoles différents. Les humidités de surface sur des parcelles des céréales sont estimées en inversant deux options du WCM. Les résultats ont confirmé la pertinence du couplage du IEM-B avec les deux options du WCM avec des RMSE variables entre 3.35 vol.% et 4.65 vol.% en utilisant les données C-VV et des RMSE inférieures à 5 vol.% en utilisant les données L-HH. L'inversion de la deuxième option du WCM a induit une précision relativement stable par rapport à l'inversion de la première option en utilisant L-HH. En contrepartie, l'intégration du terme des interactions sol-végétation, a amélioré la performance de l'estimation d'humidité en utilisant les données L-HV où la valeur RMSE a passé de 13.68 vol.% à 6.81 vol.%. Cette amélioration était limitée en utilisant les données C-VH avec une diminution relative du RMSE égale à 5 %. Ces résultats sont promoteurs pour approfondir l'examen du potentiel de la bande L et les modèles utilisées pour estimer l'humidité du sol. Dans le cas des cultures arrangées en lignes séparées par du sol nu et localement irriguées, nous nous sommes intéressés à adapter le WCM à cette répartition hétérogène de l'humidité du sol. La sensibilité de cette version modifiée du WCM a été évalué en utilisant les données bi-fréquence. Les simulations à plusieurs combinaisons de conditions maîtrisées ont souligné le potentiel du modèle proposé à simuler le comportement du signal radar dans ce contexte. L'utilisation des données en co-polarisation de la bande L reste plus sensible à l'humidité par rapport à un potentiel plus limité des données C-VV.

Les résultats présentés dans ses deux parties ont montré clairement le potentiel du signal radar en bande L à estimer l'humidité du sol en deux contextes de culture homogène et une culture en rangs. Ce potentiel mérite d'être plus exploré avec les nouvelles missions en bande L. Dans les deux parties, nous avons utilisé le WCM pour la simulation du signal radar. Ce modèle requiert l'utilisation des descripteurs de la végétation. Nous avons utilisé dans les deux parties soit des mesures in-situ de la hauteur des piments. Ce descripteur est un super consommateur de temps et d'efforts pour le collecter sur terrain et ne couvre pas la variabilité spatiotemporelle de la végétation à une échelle régionale. Le NDVI, calculé à partir des images optiques, peut-être une alternative fiable aux mesures in-situ. Malheureusement, les données optiques sont fréquemment impactées par les nuages qui contamine le contenu des pixels. Dans ce contexte, dans le chapitre suivant, nous avons examiné la faisabilité et la fiabilité des descripteurs de la végétation estimés à partir des données radar dans le processus d'estimation de l'humidité de surface.



## Chapitre IV

---

# Apport des données SAR pour décrire la végétation dans le processus d'estimation de l'humidité de surface du sol

---

Ayari, E., Zribi, M., Kassouk, Z., Lili-Chabaane, Z., Ouaadi, N. & Baghdadi, N., (2023). NDVI time-series reconstruction using Sentinel-1 data over wheat fields in a semiarid Mediterranean region. **En révision (GIScience & Remote Sensing)**.

Ayari, E., Zribi, M., Kassouk, Z., Lili-Chabaane, Z., Jarlan, L., Rodriguez-Fernandez, N., & Baghdadi, N., (2023). Sensitivity of surface soil moisture retrieval to satellite-derived vegetation descriptors over wheat fields in the Kairouan Plain. *European Journal of Remote Sensing*, 56(1), 2260555, <https://doi.org/10.1080/22797254.2023.2260555>

# Chapitre IV

## Apport des données SAR pour décrire la végétation dans le processus d'estimation l'humidité de surface du sol

---

### IV.1. Introduction

Les propriétés de la végétation sont variables dans le temps et dans l'espace. Sa structure constituée de la tige, des feuilles, des fleurs et des fruits, est changeante au cours de son cycle de croissance. En outre, l'état hydrique de la végétation dépend de la quantité d'eau disponible dans le sol et de sa capacité à absorber l'eau par sa partie racinaire. Ces facteurs évoqués rendent la description de la dynamique de végétation un véritable défi. Bien que les mesures in-situ des variables biophysiques réussissent à prendre en filature la croissance des plantes, elles ne peuvent pas considérer la variabilité spatiotemporelle de cette évolution de la végétation. Pour remédier cette anomalie, la télédétection a prouvé son apport pour décrire les propriétés de la végétation et suivre sa croissance. Le Normalized Difference Vegetation Index (NDVI) est l'un des indices spectraux les plus utilisés pour caractériser le couvert végétal. Cet indice, calculé à partir des données dans le domaine optique, est fortement impacté par les conditions météorologiques. Particulièrement, il est limité par la présence des nuages.

Dans le chapitre précédent, nous avons utilisé les mesures de la hauteur des piments et le NDVI pour les céréales comme étant des descripteurs de la végétation dans le processus d'estimation de l'humidité du sol sur les parcelles couvertes. Cette description constitue un pilier primordial dans le modèle WCM qui intervient à la fois dans la rétrodiffusion de la végétation et l'atténuation de la végétation de la rétrodiffusion du sol nu. Dans ce chapitre, nous nous sommes intéressés à tester des alternatives au NDVI estimés à partir des données radar. Ces dernières ne sont pas impactées par les conditions météorologiques. En considérant que le NDVI est efficace pour estimer les humidités du sol, nous avons essayé dans la deuxième partie du chapitre, de reconstruire les cycles du NDVI du blé à partir des données radar Sentinel-1.

L'approche développée et les résultats sont décrits dans l'article en cours de révision dans le journal **GIScience & Remote Sensing** : « Ayari, E., Zribi, M., Kassouk, Z., Lili-Chabaane, Z., Ouaadi, N. & Baghdadi, N., (2023). *NDVI time-series reconstruction using Sentinel-1 data over wheat fields in a semiarid Mediterranean region.* »

Dans la deuxième partie du chapitre, nous avons testé la pertinence des variables estimées à partir des données SAR en bande C acquises par Sentinel-1 dans le processus d'estimation d'humidité du sol. Ces variables sont utilisées comme étant des descripteurs du blé dans le WCM pour estimer l'humidité de surface du sol sur des parcelles de références sur la plaine de Kairouan. Les tests et les résultats sont détaillé dans l'article publié dans **European Journal of Remote Sensing** : « Ayari, E., Zribi, M., Kassouk, Z., Lili-Chabaane, Z., Jarlan, L., Rodriguez-Fernandez, N., & Baghdadi, N., (2023). *Sensitivity of surface soil moisture retrieval to satellite-derived vegetation descriptors over wheat fields in the Kairouan Plain.* »

## IV.2. Reconstruction du cycle NDVI en utilisant des données SAR

### IV.2.1. Résumé

L'indice NDVI a prouvé son utilité dans des différentes applications dans le domaine agricole comme l'estimation et le suivi du rendement de la végétation, l'identification des géotypes des plantes, classification des occupations du sol... Cet indice est calculé à partir des données optiques et il est fortement impacté par les nuages qui contamine le contenu des pixels. Cette disponibilité limitée, dans les zones tempérées et tropicales, nous a incités à poser les questions suivantes : Est-ce qu'on peut estimer le NDVI à partir des données radar ? Est-ce qu'on peut restituer le cycle NDVI des séries temporelles des données radar ? Pour répondre à ces questions, nous avons essayé dans cette partie à reconstruire le cycle NDVI des blés à une échelle parcellaire. Dans le présent travail, nous avons utilisé des données SAR en bande C acquises par Sentinel-1 pour calculer deux variables principalement : la cohérence interférométrique et l'indice normalisé du rapport de cross-polarisation. Sur des parcelles de blé sélectionnées sur la plaine de Kairouan durant deux années agricoles (2018-2019 et 2019-2020), nous avons utilisé les deux variables SAR pour estimer les valeurs NDVI. En première étape, les parcelles ont été divisées en trois lots : apprentissage (70 %), validation (20%) et test (10%). La représentation de la relation NDVI en fonction des variables radar se caractérise par une évolution en hystérésis avec une partie linéaire au début du cycle de blé. Après la première quinzaine du Mars, les valeurs NDVI se saturent puis décroient vers la fin du cycle.

En fonction des stades phénologiques, le cycle NDVI du blé est divisé en deux périodes. La première période commence par le semis jusqu'à l'épiaison en mi-mars décrivant le développement de la végétation. La deuxième période englobe deux sous-périodes : la première sous-période confère à la phase de maturation ( $NDVI \geq 0.4$ ) et la deuxième période couvre la phase de senescence ( $NDVI < 0.4$ ). A partir de ces constatations, nous avons estimé le NDVI à chaque période du cycle pour chaque parcelle en utilisant soit des équations d'ajustement, soit des algorithmes d'apprentissage supervisé, de régression dans notre cas, tels que la régression Random Forest (RF) ou bien la régression Support Vector Machine (SVR).

Pour la première période, afin d'estimer NDVI, nous avons utilisé une fonction linéaire en fonction de IN ou de la cohérence. Également, nous avons testé les algorithmes Random Forest ou Support Vector Regressor en fonction des deux variables. Les estimations de NDVI, durant la première période, sont validées par des RMSE qui varient entre 0.07 et 0.1 et un minimum des coefficients de détermination  $R^2$  égale à 0.8. Durant la deuxième période à des valeurs  $NDVI < 0.4$ , les NDVI sont estimés avec RMSE inférieurs à 0.05. En contrepartie,  $NDVI \geq 0.4$ , les valeurs RMSE peuvent atteindre des valeurs de l'ordre de 0.28 avec un biais de -0.13 en utilisant les équations empiriques en fonction de IN. Cette complexité est induite de l'effet de volume de la végétation qui impacte le signal radar. En contrepartie, l'impact de la présence du volume de végétation n'est pas détecté par les mesures du signal dans le domaine optique. Par conséquent, cet effet n'est pas impliqué dans les valeurs NDVI et complique, par la suite, l'estimation de cet indice à partir des données radar. Pour chaque période, on utilise le modèle correspondant, qui est calibré et validé, pour estimer les valeurs NDVI. Ensuite, nous avons rassemblé les estimations sur toutes les périodes pour reconstruire un cycle complet. Cette démarche a été appliquée sur le lot des parcelles test qui n'étaient pas incluses dans les étapes d'apprentissage et validation. Globalement, les cycles NDVI sont reconstruit avec des RMSE variables entre 0.12 et 0.19. La performance la plus faible confère l'utilisation des équations en fonction de l'indice normalisé IN. La comparaison entre les deux cycles du NDVI Sentinel-2 interpolé et NDVI estimé a souligné la pertinence du signal radar pour retrouver la dynamique du NDVI, notamment la dynamique de la végétation. La présence du volume durant la phase de maturation complique les estimations. En contrepartie, cette prise en compte du volume peut être pertinente dans d'autres applications dans le but de corriger l'effet de la canopée de la végétation. Tous les détails du travail sont expliqués et discutés dans l'article suivant.

#### IV.2.2. Article

# NDVI time-series reconstruction using Sentinel-1 data over wheat fields in a semiarid Mediterranean region

## Abstract

Annual crop monitoring is a key parameter for managing agricultural strategies. Several studies have relied on remote sensing products such as the normalized difference vegetation index (NDVI) as a vegetation dynamic metric. However, the dependence of optical data on weather conditions limits its availability. In this study, we reconstruct the NDVI time series of wheat fields using the moving averages of the Sentinel-1 normalized VH/VV cross-polarization ratio (IN) and the interferometric coherence in VV polarization over wheat selected fields in a semiarid site in Tunisia during two seasons, from 2018 to 2020. The crop cycle is divided into two periods: before and after the heading phase, which occurs in approximately the middle of March. Due to the volume-scattering impact, the second phase is divided into the ripening and maturation phase ( $\text{NDVI} \geq 0.4$ ) and senescence phase ( $\text{NDVI} < 0.4$ ). To estimate the NDVI values, different methods are used: curve-fitting equations and machine learning regressors such as the random forest (RF) and the support vector regressor (SVR). Low root mean square error (RMSE) values characterize NDVI estimation during the first period. In the second period, the RMSE values reach 0.05 when the NDVI is lower than 0.4. When the NDVI values exceed 0.4 in the second period, lower accuracy marks the NDVI estimation using the curve-fitting equations as a function of IN or coherence. Low accuracy characterizes the regression algorithms' estimations when  $\text{NDVI} \geq 0.4$  compared to their performance during the aforementioned periods. The proposed approach was tested on different wheat fields. The NDVI estimations are characterized by RMSE values varying between 0.12 and 0.19. The use of RF and SVR outperformed the curve-fitting methods with an RMSE equal to 0.12.

**Keywords:** Synthetic aperture radar; Normalized difference vegetation index; Sentinel-1; vegetation; wheat; VH/VV cross-polarization ratio; Interferometric coherence; semiarid

## 1. Introduction

Under actual climate irregularities and the threat of food insecurity, the need for optimized agricultural systems are increasingly essential to managing available soil and water resources (IPCC, 2022). Hence, agricultural systems are an effective tool for adopting precision-farming practices such as irrigation, fertilization, and pesticide application according to the vegetation phenological stages and morphological changes and to forecast vegetation yield (Ali, Tedone, and De Mastro 2015; Zingale et al. 2022). Therefore, annual crop monitoring is needed to

optimize agricultural strategies from a field scale to the regional scale. The in situ measurements of biophysical variables of vegetation are insufficient to cover the vegetation dynamic variability in space and time. Consequently, the use of remote sensing products is a method that resolves the aforementioned inabilities with high spatial and temporal resolutions. By transforming the optical remote sensing bands mathematically to indices, the difference vegetation index (NDVI) provides valuable and reliable information for annual crop monitoring under dryland and irrigated conditions (Huang et al. 2021). The NDVI has proven its relevance in different agricultural applications, such as the identifying crop genotypes (Naser et al. 2020; Pinto et al. 2016), estimating nitrogen content, yield forecasting (Chahbi et al., 2014; Duan et al., 2017; Goodwin et al., 2018; Labus et al., 2002; Marti et al., 2007.) and classifying land use c (Minallah et al. 2020; Song and Wang 2019; Belgiu and Csillik 2018). NDVI information is derived from optical images. Their availability is limited by the presence of clouds and their shadows, atmospheric disturbance and sensor capacity, which contaminate surface reflectance pixels (Li et al., 2021; Huang et al., 2021). Consequently, these polluted pixels should be removed, and the NDVI time series will be discontinued. To fill the missing pixel values and reconstruct reliable NDVI image time series, several approaches have been applied, such as data fusion (Liao et al., 2016 ; Chen et al., 2021; Zhang et al., 2016), filtering functions such as the Fourier filter (Wagenseil and Samimi 2006) and Savitzky–Golay filter (Chen et al. 2004, Liu et al., 2022), harmonic analysis of time series (HANTS) (Zhong et al. 2010), threshold method (You et al. 2013) and moving averages (Jönsson and Eklundh 2004).

As an alternative to the NDVI, several studies have used synthetic aperture radar (SAR) data owing to its independence from weather conditions, acquisition time, and ability to penetrate vegetation canopies even in dense cover contexts. Annual crop monitoring has utilized SAR products in the X-band (Phan et al. 2018; Yuzugullu et al. 2017; Koppe et al. 2013), C-band (Barbouchi et al. 2022; Gorrab et al. 2021; Vavlas et al. 2020; Nasirzadehdizaji et al. 2019; Homayouni et al. 2019; Bhogapurapu et al. 2021), and L-band (H. Li et al. 2019), the synergy of multifrequency data (Yihyun Kim et al. 2013; Kraatz et al. 2021), and multisensor data using SAR and optical data (David, Giordano, and Mallet 2021; Stendardi et al. 2019; Denize et al. 2019; Mercier et al. 2019). In this context, several approaches have been developed to explore radar measurements to monitor vegetation dynamics, especially with the increasing availability of C-band SAR data with high resolution and repetitiveness after the launch of Sentinel-1A/B in 2014 and 2016, respectively (Kussul et al. 2017; Bell et al. 2020; Rembold et al. 2015; Allies et al. 2021). Various studies have relied on radiometric information by calculating the VH/VV

cross-polarization ratio (Chakhar et al., 2021; Kim and Van Zyl, 2009; Planque et al., 2021; Veloso et al., 2017; Vreugdenhil et al., 2018), the radar vegetation index (RVI) (Kim and Van Zyl, 2009) and its truncated RVI (Mandal et al., 2020; Haldar et al., 2022). Bhogapurapu et al. (2021) proposed three polarimetric variables calculated using Sentinel-1 data, such as the pseudo scattering type, entropy and co-pol purity parameters.

Several studies have explored interferometric SAR (InSAR) information to detect vegetation cover changes between two successively acquired scenes. These changes are deduced from the temporal coherence loss between two acquisitions (Tamm et al. 2016; Mestre-Quereda et al. 2020; Ouaadi et al. 2020; Jacob et al. 2020; Jacquemart and Tiampo 2021; Palmisano et al. 2018; Kellndorfer et al. 2022; Villarroya-Carpio, Lopez-Sanchez, and Engdahl 2022). Tamm et al. (2016) initiated studies on coherence time series using the available Sentinel-1 A images to detect mowing events in grasslands. The use of a coherence time series by Jacob et al., 2020; Mestre-Quereda et al. 2020, enhanced the overall accuracy classification of the land owing to the coherence ability to identify the annual crop calendars. The potential of a 6-day temporal baseline interferometric coherence as a vegetation descriptor was recently discussed by (Villarroya-Carpio, Lopez-Sanchez, and Engdahl 2022), for different crop types and compared to the NDVI and the VH/VV cross-polarization ratio. They noted that interferometric coherence estimations and backscattering intensity are complementary to monitoring crop dynamics. In semiarid regions, Ouaadi et al. (2020) investigated the link between vegetation descriptors (interferometric coherence and VH/VV cross-polarization cross-polarization ratio) and the in situ dry aboveground biomass (AGB) of wheat. This relationship has consequently been used to retrieve AGB and estimate soil moisture using the water cloud model coupled with the Oh model.

Based on the potential of NDVI and SAR data to describe vegetation dynamics, we can obviously ask the same question as Bai et al., (2020): Can vegetation index such as NDVI be retrieved from SAR? Tested over villages and farm-lands, Bai et al. (2020) revealed the potential of interferometry as an important supplementary data to the NDVI in cloud presence to represent the changes in scene features. In this context, an SAR-calibrated NDVI was introduced by Jiao et al. (2021) as a solution to fill the NDVI value gaps and reconstruct the NDVI time series. To simulate the relationship between the SAR data and NDVI values, several methods can be used, such as empirical relationships as assumed by Mercier et al. 2019; Bai et al. 2020; Jiao, McNairn, and Dingle Robertson, 2021, or by establishing supervised trained models using machine learning algorithms such as random forest (RF) (Segal 2004; Shi and

Horvath 2006; Belgiu and Drăgu 2016; Pelletier et al. 2016; Wang et al. 2016; Liang et al. 2018; Izquierdo-Verdiguier and Zurita-Milla 2020; Schonlau and Zou 2020), support vector machine (Mountrakis, Im, and Ogole 2011; Pasolli, Notarnicola, and Bruzzone 2011; Ezzahar et al. 2020) or artificial neural networks (Ahmad, Kalra, and Stephen 2010; Kumar et al. 2019).

According to Li et al. (2021), the NDVI time-series reconstruction is based on filling the pixel gaps in optical images. Additionally, a smoothing process is needed to obtain a reliable NDVI time series. The present paper proposes an approach to retrieve the NDVI time series at wheat field scale without passing with optical image pixel filling. For each field, the mean NDVI value is estimated using the link between SAR data and the optical index during each vegetation-growth period and its physiological states. The NDVI time series was divided into three parts: the first part from the sowing stage to the maximum vegetation development stage, the second period is specific for the maturation phase, and the third part includes the senescence and harvest phases. For each part, we established a trained model to estimate the NDVI using curve-fitting equations and RF and SVR algorithms. This work focuses on the use of interferometric coherence and the normalized VH/VV cross-polarization ratio (IN), as proposed by Rolle et al., 2022, using the Sentinel-1 data time series during two wheat cycles to retrieve the NDVI values over wheat fields on the plain of Kairouan under a semiarid climate.

This paper is divided into five sections, starting with the introduction in the first section. The study area description, datasets and methodology are detailed in the second section. In the third section, we illustrate and describe the findings, which are discussed in the following section. The conclusions are detailed in the final section.


## **2. Materials and Methods**

### ***2.1. Study area description***

The study area extends over the Kairouan Plain in the center of Tunisia ( $9^{\circ}23'-10^{\circ}17'E$ ,  $35^{\circ}1'-35^{\circ}55'N$ ). It is characterized by a vast alluvial flat landscape covering 3,000 km<sup>2</sup>. Located in the semiarid climate zone, the Kairouan Plain receives 300 mm of total annual rainfall. Two major oueds (wadi, valley) feed the Kairouan: Merguellil and Zeroud, where the El Haouareb and Sidi Saad dams were constructed, respectively. The land is occupied by cereals, olive trees, garden crops and orchards (Zribi et al. 2011; Amri et al. 2011). In recent years, irrigated areas have been developed extensively, generating an increase in water demand and the extension of pumping either from dams or wells. These pumping practices have impacted hydrological dynamics, resulting in overexploitation of the Kairouan Plain aquifer with a piezometric drop



between 0.25 m and 1 m per year over the last two decades (Leduc et al. 2007; Massuel and Riaux 2017).



**Figure 1.** The reference wheat field delineation in the study zone area on the Kairouan Plain in the center of Tunisia during two vegetation cycles (64 fields during 2018/2019 and 66 fields during 2019/2020).

Wheat cultivation is an agricultural practice that consumes the most irrigation water due to its importance in regional and national agricultural production. Therefore, optimizing the irrigation needs of wheat depending on vegetation-growth stages is a key component of water resource management. The present study monitored the wheat cycle for two years (2018-2019 and 2019-2020), including the different phenological phases: vegetation development, heading, ripening and senescence. The cycle starts with sowing events which occur in approximately December of each year. By the end of May to June, the wheat is harvested. The observations included 64 reference fields for the first year and 66 fields in the second year. To ensure the spatial representativity of the Kairouan Plain's agriculture scene, the area of the selected wheat fields is mostly higher than 1 hectare and can reach 13 hectares, which affords a sufficient number of pixels for calculating the average of SAR and optical data. Different surveys were held with agriculture about farming practices. The comparison between the practices revealed that each field is different in terms of wheat variety, irrigation doses and soil tillage, which decreases the

interfieldspatial autocorrelation. The wheat fields are irrigated by sprinklers. Unfortunately, at the field scale, the quantification of the irrigation amount remains challenging. The study area is characterized by highly diversified small family farms that manage their practices according to their own logic (Ameur, Amichi, and Leauthaud 2020). Due to these informal arrangements, the installed irrigation systems and strategy are different from one agriculture to another which complicates quantifying the total amount of irrigation per field.

## **2.2. Datasets**

### *2.2.1. Sentinel-1*

To monitor and map land surfaces, the Sentinel-1 mission offers a long time series of high-spatial-resolution, SAR images operating at a center frequency of 5.405 GHz over 175 orbits. With the launch of Sentinel-1 A and B in 2014 and 2016, respectively, C-band images are available every six days acquired in different modes: interferometric wide-swath mode (IW), wave mode (WV), strip-map mode (SM) and extra wide-swath mode (EW). Various Sentinel-1 data products have been distributed, including raw Level-0 data, single look complex (SLC) imagery, ground range-detected (GRD) Level-1 data and Level-2 ocean (OCN) data (Torres et al. 2012).

In the present study, we used GRD and SLC Sentinel-1 images covering two wheat cycles, 2018-2019 (60 acquisitions) and 2019-2020 (56 acquisitions), over the reference fields on the Kairouan Plain, as described in Table 1. To maximize the use of the available C-band time series information as recommended by (Defourny et al. 2019), we merged the ascending and descending orbit data. In this work, the SAR data were acquired at incidence angles varying between approximately  $39^\circ$  and  $40^\circ$  for the two orbits over a flat landscape. Based on the vegetation isotropy within the wheat fields, we can assume that the difference of  $1^\circ$  and the limited slope variation in the study area minimize the azimuthal anisotropy, especially because the aforementioned problem is caused by the orientation of the topography's slope (Schaufler et al., 2018). We used the already processed GRD images to calculate the IN, and we processed the SLC images to compute the interferometric coherence  $\rho_{pq}$ . All the processing steps and the calculations are detailed in the supplemental material.

**Table 1.** Characteristics of the satellite images used: optical images acquired by Sentinel-2A/B and C-band SAR images acquired by Sentinel-1A/B.

	Number of fields	Sentinel-2A/B			Sentinel-1A/B				
		Number of acquisitions	Relative orbit	Revisit time	Product type	Pixel spacing Range × azimuth (m)	Number of acquisitions	Relative orbit	Revisit time
2018-2019	64	35	22 and 122	5 days	SLC	2.3 × 13.9	60	88 and 95	6 days
					GRD	10 × 10	60		
2019-2020	66	39			SLC	2.3 × 13.9	56		
					GRD	10 × 10	56		

### 2.2.2. Sentinel-2

After the launch of two polar-orbiting satellites, Copernicus Sentinel-2A/B, on 23 June 2015 and 7 March 2017, respectively, high-resolution multispectral optical images with a revisit frequency of 5 days were available with a swath-width band of 290 km and spatial resolutions of 10, 20 and 60 meters (Drusch et al. 2012). Sentinel-2 bands of 10 and 20 meters, depending on the spectral bands, were automatically processed by the MAJA processor of the THEIA land data center to correct the data for atmospheric effects and detect clouds (<https://theia.cnes.fr/atdistrib/rocket/#/search?collection=SENTINEL2>). The NDVI calculation is detailed in the supplemental section.


### 2.3. Methodology

As mentioned in the previous section, we attempted to investigate the coherence potential and IN to estimate the NDVI values over the wheat-growth stages. In this section, we detail the steps to retrieve the NDVI cycle over wheat fields using various empirical models. Thus, for each wheat field, we calculated a moving average of the extracted variables (coherence and normalized VH/VV cross-polarization ratio) with a temporal window of 6 observations. During the remainder of the study, we used IN,  $\rho_{VV}$  and  $\rho_{VH}$  abbreviations to indicate the moving averages of the normalized VH/VV cross-polarization ratio, the coherence in VV and the coherence in VH, respectively. Since optical sensor acquisition is dependent on weather and is

impaired especially by cloud cover, the availability of Sentinel-2 data was challenging throughout the wheat cycle and created a serious data gap in the cycle. Therefore, in the case of the absence of optical data, we calculated NDVI values using linear interpolation for each S-1 acquisition date. To consider the climatic variability of the two agricultural years and to vary the study cases for training, we mixed data from the two years for NDVI estimation. The NDVI retrieval strategy is based on the phenological growth stages of wheat, as we identified in the supplemental section: the first period was from December to the middle of March, and the second period extended the senescence stage to June. The second period was subdivided according to NDVI values: less than 0.4 and higher than or equal to 0.4.

To gauge the NDVI values for each period, several methods were tested utilizing curve-fitting equations and machine learning regressors, such as random forest (RF) and support vector machine (SVR). According to the literature, random forest regression (RF), support vector regression (SVR) and artificial neural networks (ANNs) are the most commonly used machine learning regression algorithms to estimate vegetation biophysical variables. When the number of samples is limited, using the ANN does not accurately estimate the objective variable. Therefore, the RF and SVR algorithms are more privileged (Balabin & Lomakina, 2011; Salcedo-Sanz et al., 2020; Shataee et al., 2012). The aforementioned algorithms proved their pertinence in addressing complex relationships to estimate crop biovariables such as biomass (Mutanga et al., 2012; Wang et al., 2016), fractional vegetation cover (Liu et al., 2021), and leaf nitrogen content (Liang et al., 2018). In the present paper, we investigate the potential of these two algorithms to estimate the NDVI using radar data.

We randomly divided the reference field cycles and their corresponding satellite datasets into three sets: training (70% of the fields), validation (20% of the fields) and testing (10% of the fields). Each wheat cycle per set is subdivided according to the aforementioned periods (Figure A.1). For each period, we train the model as a first step (Figure 2). The performance of the trained models is evaluated using unseen data and not included in the training process to avoid overfitting or underfitting of the constructed models. Considering of the validation dataset in the training process can induce an untrustworthy prediction model performance and its capability to be tested on different datasets (Jabbar and Khan, 2015; Langley and Simon, 1995; Li et al., 2017). Due to the saturation problem and to enlarge the dataset especially for the curve-fitting equation training, for the second period when the NDVI values are higher than 0.4, we train the model with the entire dataset of the second period.



**Figure 2.** Flowchart of the methodology to estimate NDVI values.

### 2.3.1. Curve-fitting equations

To retrieve the NDVI during the first period, the linear relationship parameters (a and b) and the SAR parameter values were used to estimate the optical index. The constructed trained models were used to estimate the NDVI values. For the second period of the cycle describing the reproductive phase until the harvest of the wheat between the middle of March and June, we proposed two subperiods depending on the maturity phase start highlighted by the NDVI value threshold. When the NDVI values were under 0.4, we used an exponential function for data fitting, in which we had two parameters (a and b) to calibrate and validate using the IN and the interferometric coherence separately as vegetation descriptors. For NDVI values higher than or equal to 0.4, the curve fitting equations' approach was dependent on the type of variable, whether the VH/VV cross-polarization ratio or the coherence at the VV channel, due to the different behaviors of SAR parameters in this period. Therefore, the NDVI was retrieved using one of the following equations, where a, b, k, and k' are parameters to calibrate and validate:

$$\text{NDVI} = \begin{cases} a \times \exp(b \times x), & \text{NDVI} < 0.4, x = \text{IN or } \rho_{VV} \\ k \times \left(\frac{1}{\log(x)}\right) + 0.15, & \text{NDVI} \geq 0.4, x = \text{IN} \\ k' \times (-\log(x)) - 0.15, & \text{NDVI} \geq 0.4, x = \rho_{VV} \end{cases} \quad (1)$$

### 2.3.2. Random forest regressor

The random forest algorithm is known as an efficient method for building nonlinear regression models. It is based on a random selection of trees thanks to the bootstrap aggregating method. At each tree node, the data are split as a function of the used feature values. To find the cutoff

point and the best splitting point, a split criterion is measured by the residual sum squared (Breiman 2001). When the sample values are higher than the cutoff point, they are directed to the right or left node. This process is carried out until the sample moves from the root node to the terminal leaves of the selected tree, where we obtain the predicted value of the samples (Izquierdo-Verdiguier and Zurita-Milla 2020). The overall prediction is the average of the terminal leaf predictions of each tree in the forest.

In the present study, the moving averages of the coherence and cross-polarization IN were the aforementioned candidates. Therefore, we attempted to examine the contribution of each feature in the regression model. While the machine algorithm builds the model, various parameters control the structure of individual trees in the forest to retrieve the NDVI values with high prediction performance. To find the optimal hyperparameters, the RF algorithm needs to be tuned. We attempted to optimize the RF hyperparameters, such as the number of generated decision trees (10,50,100,200,300,400,500,1000) and the maximum depth of the trees (1,2,5,10,20,30,40,50,100) (Ghosh et al. 2014; Izquierdo-Verdiguier and Zurita-Milla 2020) and the maximum number of features for each node of the tree. Hence, we used a grid search strategy in which we evaluated the performance of each combination of maximum depth, and the number of trees in the present case using a 3-fold cross-validation method (Gleason and Im 2012; Pelletier et al. 2016).

### *2.3.3. Support vector regressor*

As noted in previous studies, the SVM algorithm can be used for regression analyses as a supervised-learning approach. SVM builds a model function by drawing a hyperplane that separates the observations into partitions situated at equal and maximum distances from them due to its abilities to analyze data and recognize patterns (Mountrakis et al., 2011; Smola and Scholkopf, 2004; Zhang and Zhang, 2002). The nearest points to the aforementioned plane constitute the support vectors separated by the maximum margin.

The predicted NDVI values are calculated based on the hyperplane side where the new observations are classified. The model bases its training on a loss function that equally penalizes high and low misretrieved values. To find the best model function, especially in nonlinear cases, kernels are used to transform the data to a higher-dimensional space to be linear and facilitate the separation between them. In this study, we involved three kernel functions: linear kernel, polynomial function, and Gaussian radial basis function (RBF), which depend on the data specifications used with the lowest regression error (Pasolli et al., 2011; Rains et al., 2022). Using the grid search strategy, we attempted to optimize the algorithm by varying the kernels

(RBF, polynomial or linear functions), the kernel coefficients (gamma = 1, 0.1, 0.01, 0.001, 0.0001) and the regularization parameters (C= 1e0, 1e1, 1e2, 1e3). The same hyperparameter tuning strategy was applied for - SVR using the 3-fold cross-validation method to identify the best parameters.

#### 2.3.4. Statistical metrics

To assess the performance of the proposed approach, we used three statistical metrics: Pearson's correlation for linear relationships  $R^2$ ,  $Bias$ , and root mean square  $RMSE$  calculated using Equations (2) – (4):

$$R^2 = \frac{\sum_{i=1}^N (x_{estimated,i} - \bar{x})^2}{\sum_{i=1}^N (x_i - \bar{x})^2} \quad (2)$$

$$Bias = \frac{1}{N} \sum_{i=1}^N (x_{estimated,i} - x_{observed,i}) \quad (3)$$


$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_{estimated,i} - x_{observed,i})^2} \quad (4)$$

where  $x_{estimated,i}$  and  $x_{observed,i}$  are the estimated and observed values, respectively, of sample  $i$  of the total samples  $N$  and  $\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i$ .


### 3. Results

#### 3.1. NDVI and radar variable dynamics during the wheat cycle

Figures 3a. and 3b. display the boxplots of the moving averages of the interferometric coherence in VV and VH polarizations and the VH/VV cross-polarization ratio and the interpolated NDVI dynamics during the wheat-growth cycle. Throughout the two years, the NDVI values increased continuously until a saturation phase, which was characterized by small value fluctuations. The plateau was reached, recording the highest NDVI values, which characterize the combined effect of the maximum chlorophyll content consequently highly photosynthetic vegetation and vegetation density. The boxplots show high variation in the NDVI values at the start of the cycle, and these differences may have been induced by the different agricultural practices in the study zone, especially the sowing dates, which vary between November and January. After the saturation phase, the NDVI values decreased with wheat maturation, describing the chromatic changes until the harvest event at the end of the cycle, in which the NDVI values were stable at approximately 0.2, indicating the absence of vegetation.



(a)



(b)



**Figure 3.** Subplots of the moving average of IN,  $\rho_{VV}$ ,  $\rho_{VH}$  and the interpolated NDVI during the wheat-growth cycles: (a) 2018/2019 and (b) 2019/2020 marked by the growth stages: heading (blue dashed line) and senescence start (orange dashed line).


Regarding the VH/VV cross-polarization ratio index, its curve has the same trends as the NDVI curve, especially from the start of the NDVI cycle until saturation. Despite the decrease in NDVI values, the IN values remained high due to the volume-scattering effect and the water content of vegetation during the wheat maturation phases. The interferometric coherence values varied between 0.15 and 0.77 for copolarization and between 0.15 and 0.52 for VH polarization and inversely affected the NDVI evolutionary curve. The coherence trends were marked by the relative discrepancies marking the start of the vegetation cycle and the harvesting event at the end of the cycle. This behavior may be due to the differences between sowing and harvest timing between the fields. The lowest values of approximately 0.15 marked vegetation peak. With a dynamic range of 0.62, the coherence in VV polarization had a larger variation than the cross-polarized coherence, which varied over a dynamic range of 0.4.

### ***3.2. NDVI and radar variable dynamics according to SAR acquisition dates***


To examine the variation in the proposed SAR variables as an NDVI function, we made a scatterplot of the relationships between the moving averages of the coherence in VV ( $\rho_{VV}$ ) and VH ( $\rho_{VH}$ ) polarizations, the IN and the NDVI values colored by the SAR data acquisitions during two wheat cycles (2018/2019 and 2019/2020) on the Kairouan Plain. According to Figure 4, the NDVI values vary between 0.2 and 1, in which a high density of values is recorded for the 0.8 and 0.9 intervals. The IN values range between 0.1 and 0.9 in Figures 4a and 4b. The coherence values fluctuate between 0.15 and 0.8 and between 0.15 and 0.5 in VV and VH polarizations, respectively. We distinguish a relative noise related using the coherence in the cross-polarization ( $\rho_{VH}$ ). The normalized ratio values increase with the increase linearly in the NDVI in a linear way. After reaching the maximum NDVI values, the normalized ratio decreases with a hysteresis curve (Figure 4).

The relationships between the NDVI and the coherence are characterized by a linear part and a saturated part in which the coherence values are low, similar to the hysteresis curve. According to the kernel density estimation plot of the copolarized coherence, the saturation phase is highlighted for values between 0.2 and 0.3. By comparing the two coherence scatterplots as an NDVI function, the differentiation between the two parts of the composite curve using the coherence in VV polarization is more obvious than in the VH polarization. Therefore, in later analysis, we kept only the copolarized coherence and the IN to emphasize the relationships between the NDVI and the parameters with the minimum noise. According to the scatterplots,

we observed a linear relationship characterizing the first period of the cycles starting from December until the middle of March of each cycle, in which the NDVI values increased from 0.2 to 1, indicating an increase in the chlorophyll content in vegetation and the wheat heading phase. During this period, the coherence values fluctuated between 0.2 and 0.7 and between 0.2 and 0.8 for 2018/2019 and 2019/2020, respectively. The normalized ratio index values varied between 0.1 and 0.9 during the two cycles. For the maximum NDVI values, a high density of coherence low values and IN high values characterized the scatters during March, which may indicate a saturation phase at the end of the first period. Starting from the heading event, which overlaps the middle of March, the NDVI values decreased, facing erratic variations in coherence and IN values.



(a)



**Figure 4.** Scatterplots of the interpolated NDVI values during each S-1 acquisition as a function of the moving average of IN and the coherence in VV ( $\rho_{VV}$ ) and VH polarization ( $\rho_{VH}$ ) during the wheat-growth cycles for all the reference fields (each point is a moving average variable colored by S-1 acquisition date): (a) 2018/2019 and (b) 2019/2020.

The dynamics of SAR variables restarted when the vegetation organs (kernels, head and stems) turned yellow and dough. At this stage, the NDVI values were approximately less than 0.4. Therefore, we could divide the second period between mid-March and June into two subperiods depending on the start of physiological maturity; otherwise, the NDVI threshold was equal to 0.4.


### 3.3. NDVI estimation during the wheat cycle

In this section, we estimate the NDVI values using the aforementioned variables per period and subperiod using curve-fitting equations using either IN or the coherence and tuned machine learning algorithms such as RF and SVR using both the IN and VV coherence as features.

#### 3.3.1. First period of the wheat cycle

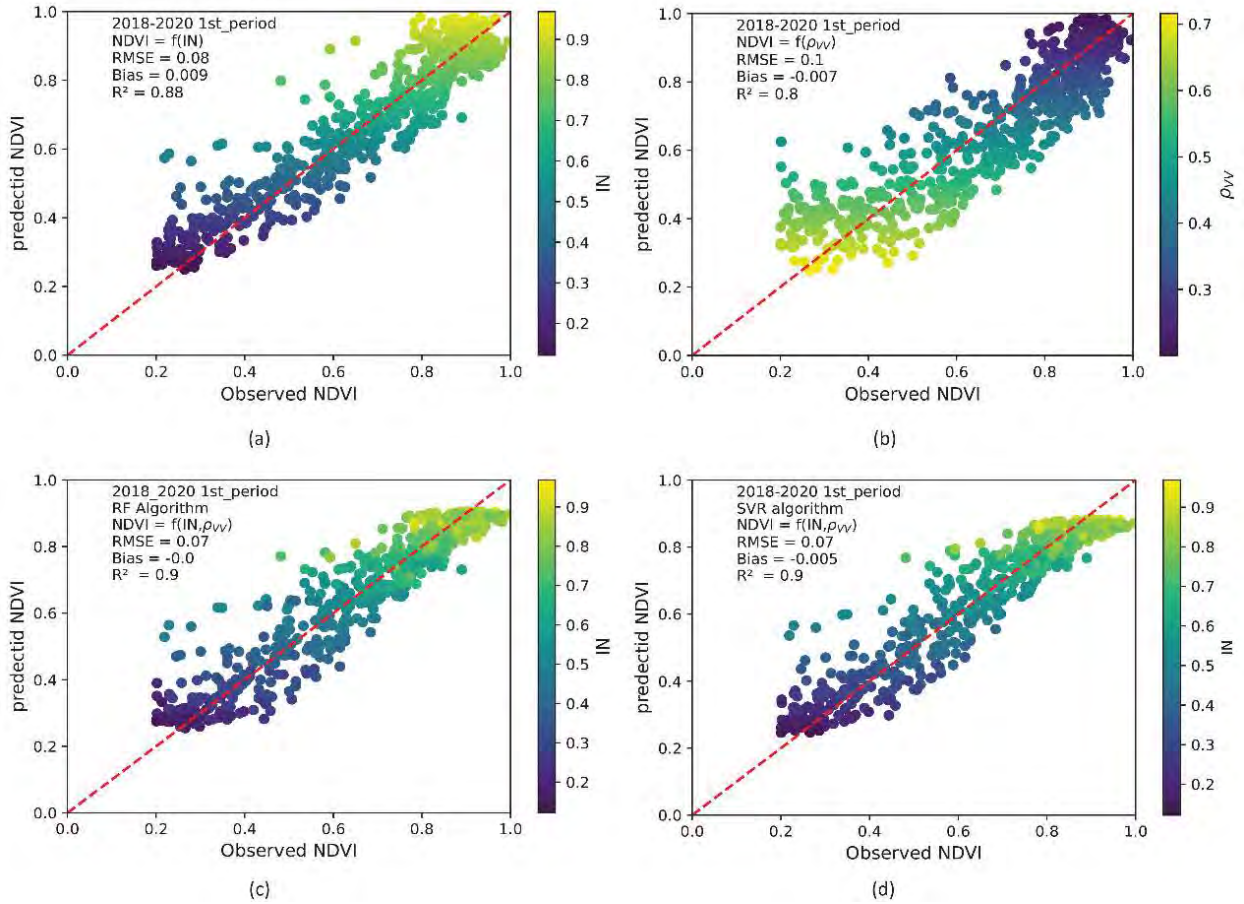
To estimate the NDVI values during the first period corresponding to vegetation growth (between sowing and the heading event), an empirical linear regression was used as a function of the VH/VV cross-polarization ratio index and the copolarized coherence with determination coefficients of 0.86 and 0.76, respectively, as displayed in Figure (5). The slope values vary between 0.9 and -1.44 for IN and  $\rho_{VV}$ , respectively. The order of origin values is equal to 0.14

and 1.28 for the aforementioned parameters. These coefficients were used to estimate the NDVI values using the validation dataset during the first period.



**Figure 5.** Scatterplots of established linear relationships during the first period between the interpolated NDVI values during each S-1 acquisition and (a) IN and (b)  $\rho_{VV}$

According to Figure 6a and 6b, high determination coefficients varying between 0.8 and 0.88 characterize the linear relationships linking the estimated and observed NDVI values using the coherence and IN (as shown in Figure 5), respectively, with a maximum RMSE value of 0.1. To improve the NDVI retrieval accuracy, we performed the model training of the first period using machine learning algorithms (SVR and RF), in which the coherence and VH/VV cross-polarization ratio index were the model features. Figures 6c and 6d display the validation of the RF with a maximum depth and number of estimators equal to 5 and 100, respectively, and the SVR with an RBF kernel. The RMSE values are approximately 0.07, and the determination coefficient values ( $R^2$ ) reach a maximum of 0.9. . Before reaching the maximum wheat growth, the NDVI estimation during the first period was characterized by high accuracy using the linear empirical approach as a function of the normalized index or the coherence or the machine learning regressors using both SAR variables as features. The machine learning algorithms' estimations are validated by close accuracy. This performance is due to the obvious linearity of the relation between the SAR variables and the optical index during the first vegetation development period.



**Figure 6.** Scatterplots of the observed NDVI (the interpolated NDVI values during each S-1 acquisition) and predicted NDVI using an empirical linear relationship between NDVI and IN (a), between NDVI and  $\rho_{VV}$  (b), RF regressor algorithm with IN and  $\rho_{VV}$  in input (c), and (d) SVR algorithm with IN and  $\rho_{VV}$  in input.

### 3.3.2. Second period of the cycle

Using interferometric information, when the NDVI is lower than 0.4, the calibrated a and b values are equal to 0.49 and -1.95, respectively. Using the VH/VV cross-polarization ratio index, the aforementioned parameters are equal to 0.15 and 0.93, respectively. For  $\text{NDVI} \geq 0.4$ , the k and k' values are equal to -0.08 and 0.53, respectively. For the RF and SVR algorithms, both SAR variables (IN and  $\rho_{VV}$ ) were used to estimate the NDVI for each subperiod. When the NDVI values were under 0.4, we could retrieve the NDVI values with RMSE values varying approximately 0.04 and 0.03 using the curve-fitting equations and RF regressor, respectively, except for the SVR algorithm case in which the RMSE reached 0.05, as illustrated in Table 2. The bias values fluctuate between -0.004 and 0.03. When the NDVI values reach 0.4, the proposed approaches underestimate the NDVI values with biases varying between -0.04 and -0.13. In this case, the SVR algorithm with an RBF kernel RF regressor with a maximum depth of 5 and number estimator of 400 relatively outperforms the curve-fitting

equations with an RMSE value equal to 0.17 compared to 0.19 using the curve-fitting equation as a function of the coherence and 0.28 using the curve-fitting equation as a function of cross-polarization IN. The RF model in this part of the second period built the regression model using 67% of the information from the IN and 33% from the coherence variation. This complementarity was also noted when the NDVI values were under 0.4, and the importance of IN and the coherence were equal to 45% and 55%, respectively.

**Table 2.** Statistical metrics of validation step using the three approaches: the empirical approach as a function of moving averages of IN and coherence, the RF algorithm and the SVR algorithm during the two parts of the second period of the wheat cycle ( $NDVI < 0.4$  and  $NDVI \geq 0.4$ ).

	Curve-fitting equations		RF algorithm	SVR algorithm	
		IN			$\rho_{VV}$
NDVI < 0.4	RMSE	0.04	0.04	0.03	0.05
	Bias	-0.004	0.002	0.001	0.03
NDVI $\geq$ 0.4	RMSE	0.28	0.19	0.17	0.17
	Bias	-0.13	-0.09	-0.06	-0.04

### 3.4. NDVI cycle retrieval

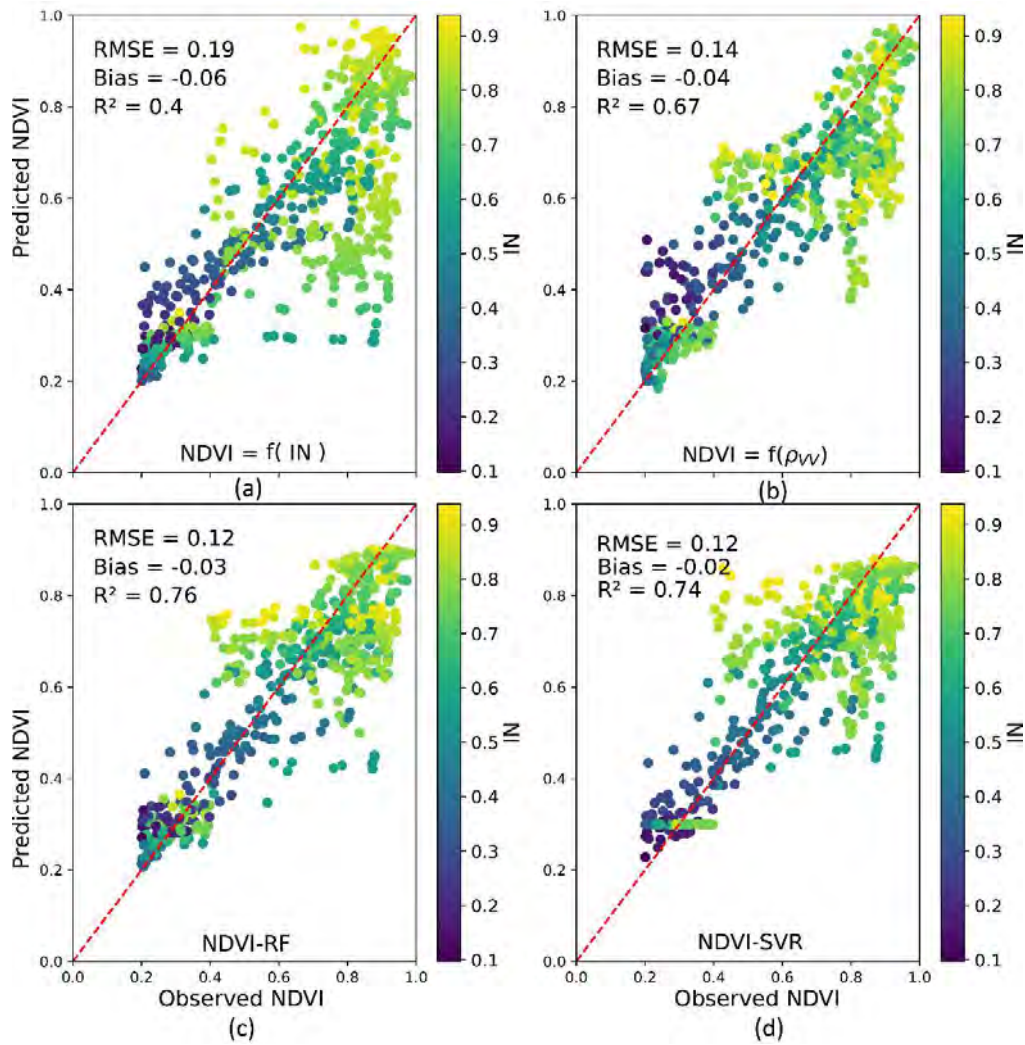
To assess the performance of the proposed approaches, we applied the approaches to retrieve the NDVI and reconstruct the NDVI cycles of the 10% of fields already selected and not included in the calibration and validation steps (13 fields). Figure 7 displays the scatterplots of the calculated NDVI as a function of the retrieved NDVI using different approaches. The highest RMSE value is equal to 0.19 with a bias of -0.06 and the lowest determination coefficient of 0.4 characterizes the NDVI retrieval using the curve-fitting equation as a function of the IN variable. The use of coherence improved the NDVI estimation with an RMSE value equal to 0.14 and  $R^2$  equal to 0.67. During the wheat cycle, the machine learning algorithms relatively outperform the curve-fitting equations in which the SVR and RF show the lowest RMSE value equal to 0.12 with slight differences in the bias and the determination coefficients.

By comparing the retrieval results, we noticed that NDVI estimation using SVR is saturated, especially at the low observed NDVI values regarding high values of IN, even though the determination coefficient was equal to 0.74. This trend may be induced by the difficulty of estimating the NDVI in the second period, in which NDVI values were equal to or greater than 0.4. The difficulties of the second period are also notable in the NDVI-RF scatterplot marked

by a relative noise for a range of high NDVI values. This noise is more pronounced with the scatterplot of the empirical approach using the cross-polarization IN. To examine the robustness of the developed approaches, we represented the temporal NDVI dynamics of the Sentinel-2 NDVI and the estimated values. Figures 8a to 8d illustrate the measured NDVI cycle and the retrieved index with the different proposed methods of two of the tested fields.

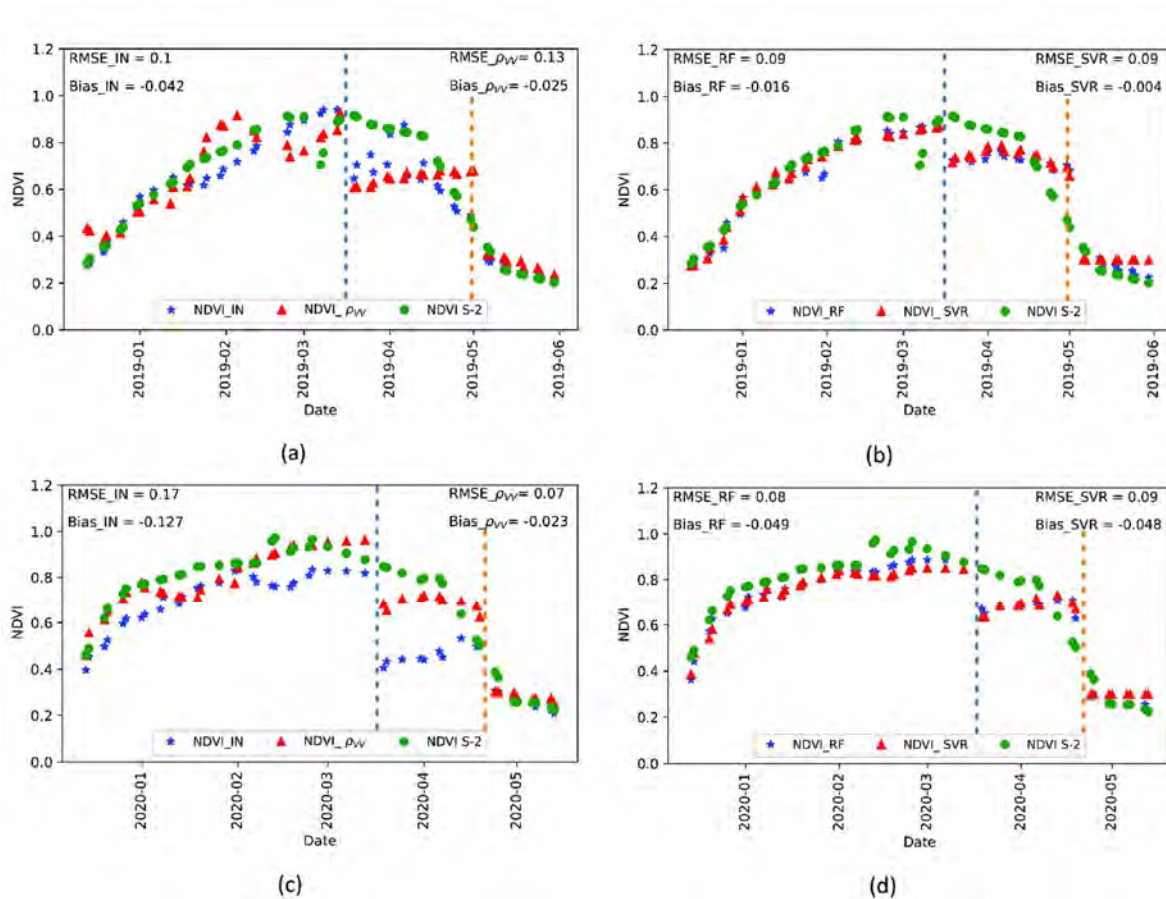
According to Figure 8.a, the RMSE values are equal to 0.1 and 0.13 using the curve-fitting equations as a function of IN and  $\rho_{VV}$ , respectively. The reconstructed NDVI cycle using calibrated equations reveals the potential of the approach to estimating the NDVI values during the first and second periods, in which the NDVI values were less than 0.4. When the NDVI values exceeded 0.4, the curve-fitting approach was unable to retrieve the same trends of Sentinel-2 NDVI dynamics. The use of IN slightly outperformed the use of interferometric information in this case. The same difficulty was observed using the RF regressor and SVR to establish the nonlinear models in the second period and for high NDVI values.

Despite the low RMSE value equal to 0.09, the saturation problem of the SVR algorithm at the end of the wheat cycle is illustrated in Figure 8b. As displayed in Figure 8c and 8d, the machine learning statistical metrics were better than the curve-fitting approach as a function of the IN, in which the RMSE value was approximately 0.17. Using the coherence in VV polarization, the RMSE value was equal to 0.07 with a bias value of -0.02.



**Figure 7.** Scatterplots of the predicted NDVI values as a function of the observed NDVI (calculated using Sentinel-2 images) using the empirical approaches (a)  $NDVI=f(IN)$ , (b)  $NDVI=f(\rho_{VV})$ , (c) RF regressor (NDVI\_RF) and (d) SVR (NDVI\_SVR) using the two SAR variables (IN and  $\rho_{VV}$ ) to retrieve the NDVI wheat cycle of thirteen test fields on the plain of Kairouan.





**Figure 8.** The temporal dynamics of the observed and estimated NDVI values during the wheat cycle for two selected test fields using the empirical approach (a,c) and machine learning algorithms (RF and SVR (b,d)) marked by the growth stages : heading (blue dashed line) and senescence start (orange dashed line).

#### 4. Discussion

In the present paper, we analyzed the potential of SAR variables to reconstruct the NDVI cycle of wheat fields as a continuous crop dynamic metric independent of weather conditions. By illustrating the time series of the normalized polarimetric index (IN), the coherence in two channels, VV and VH, and the NDVI, we noticed that IN and the coherence in VV polarization were consistent with the NDVI curve during the two wheat cycles. The IN curve, cross-polarization as already demonstrated in previous studies, was linked linearly to the NDVI for the first period of the wheat cycle until saturation when the vegetation reached its maximum green organ reflection, which overlapped with the stem elongation of wheat and the increase in the number and length of stems. In this case, as demonstrated by Veloso et al., 2017; Ouadi et al., 2021; Palmisano et al., 2018, the backscattering coefficients in the VH channel increased with the accretion of the volume scattering. In addition, in the copolarized channel VV, the direct contribution of the bare soil and the canopy decreased due to signal attenuation with

vertical structure vegetation, such as wheat, and the increase in vegetation cover fraction. As reported by Erdle et al. (2011), the NDVI values increased until the maximum wheat growth occurred in approximately the middle of March. With the start of the wheat grain filling period phase, the chromatic changes over the wheat fields anticipated the drying of the vegetation; therefore, the NDVI curve forecasted a drop before the IN curve, which remained high owing to the crop volume presence and its water content (Allies et al. 2021). The volume-scattering presence and the changes occurring in vegetation scattering were noticeable in the coherence time series in the VV channel more in the VH channel, which was less affected by the morphological wheat changes. The stability of the interferometric information at the start and end of the time series was interfered with by coherence loss, indicating the maximum development of the crop, which reduced the bare-soil response. The harvest event was identified by the fast increase in coherence (Mestre-Quereda et al. 2020; Villarroya-Carpio, Lopez-Sanchez, and Engdahl 2022). The potential of interferometric coherence in VV polarization was relevant compared to that in VH polarization in vegetation monitoring (Barbouchi et al., 2021), crop calendar identification (Villarroya-Carpio et al., 2022), land use classification (Mestre-Quereda et al. 2020) and biophysical vegetation variable estimations, such as the case in Ouadi et al., 2020. In the aforementioned study, the AGB of vegetation was estimated as a VV coherence function over wheat fields in semiarid areas in Morocco.

To our knowledge, the aforementioned studies examined the entire wheat cycle using the NDVI and SAR parameter time series without considering the different SAR-derived variables during the phenological stages of the wheat before and after the heading and the interception of the volume-scattering and vegetation water content impact. The established empirical relations are in concordance with the already established relationships between SAR and optical data tested in semiarid regions. In the plain of Kairouan (the same study site), the relations between SAR and optical data are characterized by close accuracy and stability during different cereal growth seasons: two seasons from 2015 to 2017 in Bousbih et al., 2017 and Bousbih et al. 2018 and the 2019-2020 season in Ayari et al., 2021. In Tunisia and under the semiarid context, these relations were studied by Barbouchi et al., 2022, where the phenological stages of wheat that matched the same periods of the studied varieties with the same trends of NDVI and radar signal were identified. In another southern Mediterranean region under semiarid climate (Morocco), Ouadi et al., 2020 and Ouadi et al., 2021 examined these relations. By comparing the stability of NDVI and Sentinel-1 signals over wheat fields, we observed the same trends and the same period of the phenological growth stages.

The wheat cycle was divided into two parts using an empirical limit of mid-March, as detailed in the above sections. For the first period of the cycle, in which a linear relationship related the optical index to SAR parameters, RMSE values reached a maximum of 0.1, and  $R^2$  values fluctuated between 0.8 and 0.9. With the increase in the vegetation cover fraction, the number of scatters increased, which impacted the link between the coherence, IN and the NDVI due to the SAR sensitivity to the fresh biomass and not just the chromatic changes. To mitigate the effect of the high density of vegetation and the complexity of the nonlinear relationships, the second period was divided according to an NDVI threshold equal to 0.4. The retrieved optical index was characterized by low RMSE values under 0.06, in which the NDVI was under 0.4 during the senescence phase. If the NDVI values exceeded 0.4, the use of the IN or the coherence in the VV channel moving averages separately was limited, and the RMSE value increased beyond 0.19. The use of coherence to estimate the NDVI was more relevant than that in the IN. This may be induced due to the low sensitivity of the interferometric coherence to the soil moisture variation. According to (Ouaadi et al., 2021, 2023), during the presence of vegetation in semiarid regions, the C-band coherence is impacted by the scatter dynamics and the winds regarding a low sensitivity to precipitation and surface soil moisture. Moreover, the IN is sensitive to soil moisture and soil roughness. As discussed by Zribi et al. (2005), this aspect certainly generates noise in the signals, especially with the temporal evolution of roughness. Therefore, the use of machine learning algorithms such as RF and SVR reproduced the NDVI using the two SAR variables as complementary features. The low performance of synergy between the two SAR parameters in high vegetation density may be induced due to the saturation of the C-band signal. The developed approach was tested on thirteen wheat fields in which the entire NDVI cycle was reconstructed with an RMSE under 0.12 and an  $R^2$  value approximately 0.74 using the machine learning regressors and the Sentinel-1 variables as features. Despite the potential of the RF and SVR algorithms to retrieve the NDVI values, a saturation problem was highlighted in optical index time-series reconstruction using the SVR algorithm per field and for the entire test dataset. Additionally, between mid-March and mid-April during the period of wheat grain filling, the NDVI estimations were saturated. This behavior confirms the complexity of optical index estimation in this period using the C-band SAR signal due to its high sensitivity to the vegetation volume and the vegetation water content. Combining Sentinel-1 descriptors, such as interferometric coherence and the normalized VH/VV cross-polarization ratio, with the reconstructed NDVI time series for wheat fields may be a solution for temperate and tropical regions suffering from a lack of optical data availability

due to cloud presence and artifacts induced by sensor acquisition quality (Frantz et al., 2019; Huang et al., 2021).

Despite the merits of the present approach, the developed empirical models require data acquisition during the entire wheat cycle. Otherwise, we need to attend to the minimum and maximum of the cross-polarization ratio to calculate the IN. Therefore, we cannot consider it a real-time application. Regarding coherence, the impact of the temporal baseline was discussed by Ouaadi et al., 2021, Villarroya-Carpio, Lopez-Sanchez, and Engdahl, 2022, which highlighted the importance of a short temporal baseline for coherence use. After the technical problems of Sentinel-1 B on the 23rd of December 2021, C-band images were available every 12 days. The use of 12 days leads to a less accurate temporal baseline, which escapes some structural vegetation changes. To resolve this anomaly, Sentinel-1C will be launched to replace Sentinel-1B and provide 6-day repetitiveness.

Additionally, in the present study, we considered approximate dates of sowing, harvest events and phenological stages for all the fields. According to these wheat phenophases, we divided the NDVI cycle into periods and subperiods to retrieve the optical index values. This dependency on the phenological phases complicates the transferability of the methods. In fact, the proposed approach is linked to study site characteristics such as climate and farming practices. Hence, the transferability of the NDVI estimation models to another site with different climate and farming contexts requires the recalibration of the empirical models (Weiss et al., 2020; Ouaadi et al., 2023). Otherwise, we need to identify the dates of each growth stage per field. This temporal variable may be used with radar data as features to train the model using the machine learning algorithms for the entire dataset to retrieve the NDVI cycle.

In further steps, this approach needs to be used in applications, such as vegetation biophysical variable mapping and land use classification, with high spatial and temporal resolution using the available Sentinel-1 acquisitions every six days. Hence, this estimated index comparable to the NDVI, may correct the vegetation volume effect in many agricultural applications, such the soil moisture estimation which is based on vegetation's dynamic description ((Ayari et al., 2021; Baghdadi et al., 2017; Bousbih et al., 2017; El Hajj et al., 2017) or FAO-56 crop coefficient monitoring (Ouaadi et al., 2023). Moreover, the optical index reconstruction methodology using C-band radar data may be tested on other vegetation indices (Pôças et al., 2020; Xue & Su, 2017) such as the enhanced vegetation index (EVI), ratio vegetation index (RVI) and perpendicular vegetation index (PVI). Among the perspectives, the artificial neural network may be used to estimate the NDVI and minimize the bias, especially during maturation

and ripening periods when the NDVI values are higher than 0.4, where the relation between the NDVI and SAR descriptors is complex. The proposed approach can be applied in a forest context based on the approved potential of C-band Sentinel-1 data to monitor vegetation phenology in a temperate mixed forest context (Frison et al., 2018).

## 5. Conclusions

The present study introduces an approach to reconstructing the NDVI time series over wheat fields in a semiarid area on the Kairouan Plain in the center of Tunisia. The NDVI wheat dynamics suffered gaps due to cloud presence, atmospheric disturbance and sensor capacity. By considering the independence of the SAR data from weather conditions, we tested two Sentinel-1 derived descriptors to estimate the missing NDVI values: the moving averages of the normalized VH/VV cross-polarization ratio and the coherence in VV polarization. Due to the dependency of SAR data on fresh crop biomass dynamics, NDVI retrieval was performed according to vegetation development periods: two periods by the mid-March date corresponding to the maximum growth. The complexity in the second period was marked by the synergetic effect of presence of vegetation volume, the wheat water content and the attenuation of soil backscatter. Therefore, we subdivided this period according to NDVI thresholds equal to 0.4 which separated between the maturation and senescence phases. To retrieve the NDVI values, curve-fitting equations and RF and SVR algorithms were used. For the first growth period, using linear regression, the NDVI was estimated with RMSE values varying between 0.07 and 0.1 using the IN and coherence in VV polarization, respectively. Similar low RMSE values were observed using the regression algorithms and both SAR parameters as features. For the second period, at a low level of NDVI values ( $NDVI < 0.4$ ), SAR variables successfully contributed to estimating the NDVI with RMSE values equal to 0.05 using SVR and 0.03 RF regressor and 0.04 using the curve-fitting equations. The use of one single SAR descriptor, IN or coherence, was insufficient to retrieve the NDVI in a dense wheat context ( $NDVI \geq 0.4$ ), in which the RMSE value varied between 0.19 and 0.28 with the outperformance of the coherence use. Despite the use of machine learning algorithms, the RMSE value was approximately 0.17. However, the proposed approach was applied to several test fields to retrieve the NDVI values and reconstruct the optical index time series. Overall, the RMSE values varied between 0.12 and 0.19, and the determination coefficient ranged from 0.4 using the empirical model to 0.76 using the machine learning algorithms with the IN and coherence as features. The results confirmed the potential of Sentinel-1 derived variables to derive the NDVI values during the wheat cycle with the low performance observed during the

maturation phase when the vegetation volume and water content govern the signal scattering. cross-polarization This approach can be applied to other vegetation types and under different climate contexts to retrieve crop dynamics at a regional scale. In further steps, we can establish an entire mathematical approach to reconstruct the wheat NDVI cycle over a large regional spatial area where the ancillary data of phenological growth stages are available.

### Acknowledgments

This study was funded by the Viana (ERA-Net ARIMNet) Project; the PHC Utique IPASS Project; the Chaams (ERANET3-602 CHAAMS) Project; the Irrigation+ ((ESA n°4000129870/20/I-NB) Project; and the TAPAS TOSCA/CNES project. We would like to thank the ARTS program/IRD for awarding a PhD scholarship to Emna Ayari. We extend our warm thanks to the technical teams at the IRD and INAT (Institut National Agronomique de Tunisie) who participated in the ground truth measurement campaigns and data processing.

**Data availability** The data that support the findings of this study are available from the coauthor, Mehrez Zribi, upon reasonable request.

### Appendices

#### A.1. Sentinel-1

##### A.1.1. Single look complex Sentinel-1 data

The SLC products include complex samples preserving the amplitude and phase information in vertical–vertical (VV) and vertical–horizontal (VH) polarization channels acquired in IW mode. The C-band product contains one image per subswath with a total number of 3 subswaths. Each subswath contains various bursts in azimuth-time-order separated by black-fill demarcations. The SLC images used were downloaded from the CNES's Sentinel Product Exploitation Platform (PEPS), which redistributes the Sentinel products generated by the European Union program for the observation and monitoring of the Earth Copernicus (<https://peps.cnes.fr/rocket/#/home>). The Level-1 images were processed using the SNAP Sentinel-1 toolbox to calculate the interferometric coherence following five basic steps (Ouaadi et al. 2020, 2021). After the image split and the subswath selection, the precise orbit file was applied to determine the orbit positions with an accuracy rate of less than 5 cm, at a sub-pixel level. The coregistration of two Sentinel-1 acquisitions for the same orbit (ascending or descending) is performed into a stack of master and slave images assisted by a digital elevation model SRTM DEM downloaded automatically. In the following step, the coherence  $\rho_{pq}$  was computed between consecutive acquisitions to highlight the similarities between the two image pixels using a window size of 15(Range)  $\times$  3 (azimuth) to obtain a square pixel. The coherence magnitude is computed as the following Equation (A.1):

$$\rho_{pq} = \frac{|\sum_{i=1}^N z_i^* z_i'|}{\sqrt{\sum_{i=1}^N |z_i|^2 \sum_{i=1}^N |z_i'|^2}} \quad (\text{A.1})$$

where  $z_i$  and  $z_i^*$  are the complex number and the conjugate of two acquisitions, respectively, and pq is the SAR sensor polarization (VV or VH).

The coherence values vary between 0 for an incoherent pixel and 1 for perfect coherent pixels. To obtain a single image without demarcations, the TOPS deburst operator was applied followed by terrain correction to project the results in WGS 84/UTM zone 32 N based on the SRTM DEM. For each wheat field, the coherence values are averaged to obtain a mean value per field.

#### A.1.2. Ground Range-Detected Sentinel-1 data

GRD Sentinel-1 already processed images were downloaded from the Google Earth Engine Copernicus collection (<https://developers.google.com/earth-engine/guide/sentinel1>). The Earth Engine platform derived the backscattering coefficients  $\sigma^0$  per pixel in decibel (dB) in copolarization (VV) and cross-polarization (VH) after various steps of preprocessing, including orbit file application, GRD border-noise removal, thermal noise removal, radiometric calibration, and terrain correction. To avoid the disadvantages of nonadaptive or adaptive filters, we used the spatial average. Therefore, the derived  $\sigma^0$  raster was converted to a linear scale. The VH/VV cross-polarization ratio,  $\frac{\sigma_{VH}^0}{\sigma_{VV}^0}$ , was calculated. For each reference field, the ratio was averaged and converted to dB. As proposed by Rolle et al., (2022), the ratio values were normalized by considering the minimum and maximum ratios for each field during the wheat growth season, as detailed in Equation (A.2):

$$IN = \frac{\frac{\sigma_{VH}^0}{\sigma_{VV}^0} - \frac{\sigma_{VH}^0}{\sigma_{VV}^0} min}{\frac{\sigma_{VH}^0}{\sigma_{VV}^0} max - \frac{\sigma_{VH}^0}{\sigma_{VV}^0} min} \quad (A.2)$$


where  $\frac{\sigma_{VH}^0}{\sigma_{VV}^0}$  is the VH/VV cross-polarization ratio per field in dB and  $\frac{\sigma_{VH}^0}{\sigma_{VV}^0} max$  and  $\frac{\sigma_{VH}^0}{\sigma_{VV}^0} min$  are the maximum and minimum VH/VV cross-polarization ratio values in dB, respectively, during the wheat cycle per field in dB. The IN values range between 0 and 1, in which the VH/VV cross-polarization ratio is equal to  $\frac{\sigma_{VH}^0}{\sigma_{VV}^0} min$  and  $\frac{\sigma_{VH}^0}{\sigma_{VV}^0} max$ , respectively.

#### A.2. Sentinel-2

To monitor the wheat dynamic changes, we calculated the mean of the NDVI per wheat field using cloud free Sentinel-2 red ( $R_{red}$ ) and near-infrared ( $R_{NIR}$ ) bands at central wavelengths of 665 nm and 842 nm, respectively, and 10 m spatial resolution using Equation (3) established by Rouse et al., (1973):

$$NDVI = \frac{R_{NIR} - R_{red}}{R_{NIR} + R_{red}} \quad (A.3)$$

For illustration purposes, we present a scatterplot in Figure 2 of the NDVI cycle of a wheat field with the corresponding phenological stages. The wheat cycle started with a vegetative development period marked by an increase in fresh biomass. The heading event occurred in approximately mid-March according to ground truth observations and previous works in semiarid regions (Bouras et al. 2020; Ouaadi et al. 2020; Barbouchi et al. 2022). The heading phase was followed by ripening and maturation periods when the functioning of the plant was fully oriented toward filling the grains from the produced biomass. After the grain maturation, the plant is ready to be harvest by the end of May. To identify the limit between the maturation and senescence events, we used an NDVI threshold equal to  $(NDVI_{max} - NDVI_{min}) * 50\%$  (Chu et al. 2014; Bouras et al. 2020). In the present case, the NDVI threshold is equal to 0.4.



**Figure A.1.** The NDVI profile of a selected reference wheat field in the Kairouan Plain with the corresponding phenological phases: vegetation development period, heading event, ripening and maturation period and the senescence period. The NDVI plotted data correspond to Sentinel-2 acquisition dates.



## References

- Ahmad, Sajjad, Ajay Kalra, and Haroon Stephen. 2010. "Estimating Soil Moisture Using Remote Sensing Data: A Machine Learning Approach." *Advances in Water Resources* 33 (1): 69–80. <https://doi.org/10.1016/j.advwatres.2009.10.008>.
- Ali, Salem Alhajj, Luigi Tedone, and Giuseppe De Mastro. 2015. "Optimization of the Environmental Performance of Rainfed Durum Wheat by Adjusting the Management Practices." *Journal of Cleaner Production* 87 (1): 105–18. <https://doi.org/10.1016/j.jclepro.2014.09.029>.
- Allies, Aubin, Antoine Roumiguie, Jean Francois Dejoux, Remy Fieuzal, Anne Jacquin, Amanda Veloso, Luc Champolivier, and Frederic Baup. 2021. "Evaluation of Multiorbital SAR and Multisensor Optical Data for Empirical Estimation of Rapeseed Biophysical Parameters." *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 14: 7268–83. <https://doi.org/10.1109/JSTARS.2021.3095537>.
- Ameur, Fatah, Hichem Amichi, and CrysteLe Leauthaud. 2020. "Agroecology in North African Irrigated Plains? Mapping Promising Practices and Characterizing Farmers' Underlying Logics." *Regional Environmental Change*. <https://doi.org/10.1007/s10113-020-01719-1/Published>.
- Amri, Rim, Mehrez Zribi, Zohra Lili-Chabaane, Benoit Duchemin, Claire Gruhier, and Abdelghani Chehbouni. 2011. "Analysis of Vegetation Behavior in a North African Semi-Arid Region, Using SPOT-VEGETATION NDVI Data." *Remote Sensing* 3 (12): 2568–90. <https://doi.org/10.3390/rs3122568>.
- Ayari, E., Kassouk, Z., Lili-Chabaane, Z., Baghdadi, N., Bousbih, S., & Zribi, M. (2021). Cereal crops soil parameters retrieval using L-band ALOS-2 and C-band sentinel-1 sensors. *Remote Sensing*, 13(7). <https://doi.org/10.3390/rs13071393>
- Baghdadi, N., El Hajj, M., Zribi, M., & Bousbih, S. (2017). *Calibration of the Water Cloud Model at C-Band for Winter Crop Fields and Grasslands*. 1–13. <https://doi.org/10.3390/rs9090969>
- Bai, Zechao, Shibo Fang, Jian Gao, Yuan Zhang, Guowang Jin, Shuqing Wang, Yongchao Zhu, and Jiaxin Xu. 2020. "Could Vegetation Index Be Derive from Synthetic Aperture Radar? – The Linear Relationship between Interferometric Coherence and NDVI." *Scientific Reports* 10 (1): 1–9. <https://doi.org/10.1038/s41598-020-63560-0>.
- Balabin, R. M., & Lomakina, E. I. (2011). Support vector machine regression (SVR/LS-SVM) - An alternative to neural networks (ANN) for analytical chemistry? Comparison of nonlinear methods on near infrared (NIR) spectroscopy data. *Analyst*, 136(8), 1703–1712. <https://doi.org/10.1039/c0an00387e>
- Barbouchi, Meriem, Chayma Chaabani, Hatem Cheikh M'Hamed, Riadh Abdelfattah, Rachid Lhissou, Karem Chokmani, Nadhira Ben Aissa, Mohamed Annabi, and Haithem Bahri. 2022. "Wheat Water Deficit Monitoring Using Synthetic Aperture Radar Backscattering Coefficient and Interferometric Coherence." *Agriculture* 12 (7): 1032. <https://doi.org/10.3390/agriculture12071032>.
- Belgiu, Mariana, and Ovidiu Csillik. 2018. "Sentinel-2 Cropland Mapping Using Pixel-Based and Object-Based Time-Weighted Dynamic Time Warping Analysis." *Remote Sensing of Environment* 204 (January): 509–23. <https://doi.org/10.1016/j.rse.2017.10.005>.
- Belgiu, Mariana, and Lucian Drăgu. 2016. "Random Forest in Remote Sensing: A Review of Applications and Future Directions." *ISPRS Journal of Photogrammetry and Remote Sensing* 114: 24–31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>.
- Bell, Jordan R., Esayas Gebremichael, Andrew L. Molthan, Lori A. Schultz, Franz J. Meyer, Christopher R. Hain, Suravi Shrestha, and K. Cole Payne. 2020. "Complementing Optical Remote Sensing with

- Synthetic Aperture Radar Observations of Hail Damage Swaths to Agricultural Crops in the Central United States.” *Journal of Applied Meteorology and Climatology* 59 (4): 665–85. <https://doi.org/10.1175/JAMC-D-19-0124.1>.
- Bhogapurapu, Narayanarao, Subhadip Dey, Avik Bhattacharya, Dipankar Mandal, Juan M. Lopez-Sanchez, Heather McNairn, Carlos López-Martínez, and Y. S. Rao. 2021. “Dual-Polarimetric Descriptors from Sentinel-1 GRD SAR Data for Crop Growth Assessment.” *ISPRS Journal of Photogrammetry and Remote Sensing* 178 (August): 20–35. <https://doi.org/10.1016/J.ISPRSJPRS.2021.05.013>.
- Bousbih, S., Zribi, M., Hajj, M. El, Baghdadi, N., Lili-Chabaane, Z., Gao, Q., & Fanise, P. (2018). Soil Moisture and Irrigation Mapping in A Semi-Arid Region , Based on the Synergetic Use of Sentinel-1. *Remote Sensing*, 22. <https://doi.org/10.3390/rs10121953>
- Bousbih, S., Zribi, M., Lili-Chabaane, Z., Baghdadi, N., El Hajj, M., Gao, Q., & Mougenot, B. (2017). Potential of sentinel-1 radar data for the assessment of soil and cereal cover parameters. *Sensors (Switzerland)*, 17(11). <https://doi.org/10.3390/s17112617>
- Bouras, El Houssaine, Lionel Jarlan, Salah Er-Raki, Clément Albergel, Bastien Richard, Riad Balaghi, and Saïd Khabba. 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* 12 (24): 1–35. <https://doi.org/10.3390/rs12244018>.
- Breiman, Leo. 2001. “Random Forests.” Vol. 45. Machine learning 45. <https://doi.org/https://doi.org/10.1023/A:1010933404324>.
- Chahbi, Aicha, Mehrez Zribi, Zohra Lili-Chabaane, Benoit Duchemin, Marouen Shabou, Bernard Mougenot, and Gilles Boulet. 2014. “Estimation of the Dynamics and Yields of Cereals in a Semi-Arid Area Using Remote Sensing and the SAFY Growth Model.” *International Journal of Remote Sensing* 35 (3): 1004–28. <https://doi.org/10.1080/01431161.2013.875629>.
- Chakhar, Amal, David Hernández-López, Rocío Ballesteros, and Miguel A. Moreno. 2021. “Improving the Accuracy of Multiple Algorithms for Crop Classification by Integrating Sentinel-1 Observations with Sentinel-2 Data.” *Remote Sensing* 13 (2): 1–21. <https://doi.org/10.3390/rs13020243>.
- Chen, Jin, Per Jönsson, Masayuki Tamura, Zhihui Gu, Bunkei Matsushita, and Lars Eklundh. 2004. “A Simple Method for Reconstructing a High-Quality NDVI Time-Series Data Set Based on the Savitzky-Golay Filter.” *Remote Sensing of Environment* 91 (3–4): 332–44. <https://doi.org/10.1016/j.rse.2004.03.014>.
- Chu, Lin, Gao-Huan Liu, Chong Huang, and Qing-Sheng Liu. 2014. “Phenology Detection of Winter Wheat in the Yellow River Delta Using MODIS NDVI Time-Series Data.” <https://doi.org/10.1109/Agro-Geoinformatics.2014.6910664>.
- David, Nicolas, Sébastien Giordano, and Clément Mallet. 2021. “Investigating Operational Country-Level Crop Monitoring with Sentinel~1 And~2 Imagery.” *Remote Sensing Letters* 12 (10): 970–82. <https://doi.org/10.1080/2150704X.2021.1950940>.
- Defourny, Pierre, Sophie Bontemps, Nicolas Bellemans, Cosmin Cara, Gérard Dedieu, Eric Guzzonato, Olivier Hagolle, et al. 2019. “Near Real-Time Agriculture Monitoring at National Scale at Parcel Resolution: Performance Assessment of the Sen2-Agri Automated System in Various Cropping Systems around the World.” *Remote Sensing of Environment* 221 (February): 551–68. <https://doi.org/10.1016/j.rse.2018.11.007>.
- Denize, Julien, Laurence Hubert-Moy, Julie Betbeder, Samuel Corgne, Jacques Baudry, and Eric Pottier. 2019. “Evaluation of Using Sentinel-1 and -2 Time-Series to Identify winter Land Use in Agricultural Landscapes.” *Remote Sensing* 11 (1). <https://doi.org/10.3390/rs11010037>.

- Drusch, M., U. Del Bello, S. Carlier, O. Colin, V. Fernandez, F. Gascon, B. Hoersch, et al. 2012. "Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services." *Remote Sensing of Environment* 120 (May): 25–36. <https://doi.org/10.1016/j.rse.2011.11.026>.
- Duan, T., S. C. Chapman, Y. Guo, and B. Zheng. 2017. "Dynamic Monitoring of NDVI in Wheat Agronomy and Breeding Trials Using an Unmanned Aerial Vehicle." *Field Crops Research* 210 (June): 71–80. <https://doi.org/10.1016/j.fcr.2017.05.025>.
- El Hajj, M., Baghdadi, N., Zribi, M., & Bazzi, H. (2017). Synergic use of Sentinel-1 and Sentinel-2 images for operational soil moisture mapping at high spatial resolution over agricultural areas. *Remote Sensing*, 9(12), 1–28. <https://doi.org/10.3390/rs9121292>
- Erdle, Klaus, Bodo Mistele, and Urs Schmidhalter. 2011. "Comparison of Active and Passive Spectral Sensors in Discriminating Biomass Parameters and Nitrogen Status in Wheat Cultivars." *Field Crops Research* 124 (1): 74–84. <https://doi.org/10.1016/j.fcr.2011.06.007>.
- Ezzahar, Jamal, Nadia Ouadi, Mehrez Zribi, Jamal Elfarkh, Ghizlane Aouade, Said Khabba, Salah Er-Raki, Abdelghani Chehbouni, and Lionel Jarlan. 2020. "Evaluation of Backscattering Models and Support Vector Machine for the Retrieval of Bare Soil Moisture from Sentinel-1 Data." *Remote Sensing* 12 (1): 1–20. <https://doi.org/10.3390/RS12010072>.
- FAO, FIDA, OMS, PAM et UNICEF. 2021. *L'État de La Sécurité Alimentaire et de La Nutrition Dans Le Monde 2021*. Rome: FAO. <https://doi.org/10.4060/cb4474fr>.
- Frison, P. L., Fruneau, B., Kmiha, S., Soudani, K., Dufrière, E., Le Toan, T., Koleck, T., Villard, L., Mougin, E., & Rudant, J. P. (2018). Potential of Sentinel-1 data for monitoring temperate mixed forest phenology. In *Remote Sensing* (Vol. 10, Issue 12). MDPI AG. <https://doi.org/10.3390/rs10122049>
- Ghosh, Aniruddha, Fabian Ewald Fassnacht, P. K. Joshi, and Barbara Kochb. 2014. "A Framework for Mapping Tree Species Combining Hyperspectral and LiDAR Data: Role of Selected Classifiers and Sensor across Three Spatial Scales." *International Journal of Applied Earth Observation and Geoinformation* 26 (1): 49–63. <https://doi.org/10.1016/j.jag.2013.05.017>.
- Gleason, Colin J., and Jungho Im. 2012. "Forest Biomass Estimation from Airborne LiDAR Data Using Machine Learning Approaches." *Remote Sensing of Environment* 125: 80–91. <https://doi.org/10.1016/j.rse.2012.07.006>.
- Goodwin, A W, L E Lindsey, S K Harrison, Allen W Goodwin, Laura E Lindsey, Steven K Harrison, and Pierce A Paul. 2018. "Crop Management Estimating Wheat Yield with Normalized Difference Vegetation Index and Fractional Green Canopy Cover." <https://doi.org/10.2134/cftm2018.04.0026>.
- Gorab, Azza, Maël Ameline, Clément Albergel, and Frédéric Baup. 2021. "Use of Sentinel-1 Multi-Configuration and Multi-Temporal Series for Monitoring Parameters of Winter Wheat." *Remote Sensing* 13 (4): 1–19. <https://doi.org/10.3390/rs13040553>.
- Haldar, Dipanwita, Abhinav Verma, Suresh Kumar, and Prakash Chauhan. 2022. "Estimation of Mustard and Wheat Phenology Using Multi-Date Shannon Entropy and Radar Vegetation Index from Polarimetric Sentinel-1." *Geocarto International* 37 (20): 5935–62. <https://doi.org/10.1080/10106049.2021.1926554>.
- Homayouni, S., H. McNairn, M. Hosseini, X. Jiao, and J. Powers. 2019. "Quad and Compact Multitemporal C-Band PolSAR Observations for Crop Characterization and Monitoring." *International Journal of Applied Earth Observation and Geoinformation* 74 (February): 78–87. <https://doi.org/10.1016/J.JAG.2018.09.009>.

- Huang, Sha, Lina Tang, Joseph P Hupy, Yang Wang, and Guofan Shao. 2021. "A Commentary Review on the Use of Normalized Difference Vegetation Index (NDVI) in the Era of Popular Remote Sensing." *J. For. Res* 32 (1): 1–6. <https://doi.org/10.1007/s11676-020-01155-1>.
- IPCC. 2022. "Climate Change 2022: Impacts, Adaptation, and Vulnerability. Contribution of Working Group II to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [H.-O. Pörtner, D.C. Roberts, M. Tignor, E.S. Poloczanska, K. Mintenbeck, A. Alegría, M. Craig, S. Langsdorf, S. Löschke, V. Möller, A. Okem, B. Rama (Eds.)]. Cambridge University Press. Cambridge University Press." <https://doi.org/10.5281/zenodo.4768833>.
- Izquierdo-Verdiguier, Emma, and Raúl Zurita-Milla. 2020. "An Evaluation of Guided Regularized Random Forest for Classification and Regression Tasks in Remote Sensing." *International Journal of Applied Earth Observation and Geoinformation* 88 (January). <https://doi.org/10.1016/j.jag.2020.102051>.
- Jacob, Alexander W., Claudia Notarnicola, Gopika Suresh, Oleg Antropov, Shaojia Ge, Jaan Praks, Yifang Ban, et al. 2020. "Sentinel-1 InSAR Coherence for Land Cover Mapping: A Comparison of Multiple Feature-Based Classifiers." *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 13: 535–52. <https://doi.org/10.1109/JSTARS.2019.2958847>.
- Jacquemart, Mylènemylene, and Kristy Tiampo. 2021. "Leveraging Time Series Analysis of Radar Coherence and Normalized Difference Vegetation Index Ratios to Characterize Pre-Failure Activity of the Mud Creek Landslide, California." *Natural Hazards and Earth System Sciences* 21 (2): 629–42. <https://doi.org/10.5194/nhess-21-629-2021>.
- Jia, Kun, Shunlin Liang, Xiangqin Wei, Yunjun Yao, Yingru Su, Bo Jiang, and Xiaoxia Wang. 2014. "Land Cover Classification of Landsat Data with Phenological Features Extracted from Time Series MODIS NDVI Data." *Remote Sensing* 6 (11): 11518–32. <https://doi.org/10.3390/rs6111518>.
- Jiao, Xianfeng, Heather McNairn, and Laura Dingle Robertson. 2021. "Monitoring Crop Growth Using a Canopy Structure Dynamic Model and Time Series of Synthetic Aperture Radar (SAR) Data." *International Journal of Remote Sensing* 42 (17): 6437–64. <https://doi.org/10.1080/01431161.2021.1938739>.
- Jönsson, Per, and Lars Eklundh. 2004. "TIMESAT - A Program for Analyzing Time-Series of Satellite Sensor Data." *Computers and Geosciences* 30 (8): 833–45. <https://doi.org/10.1016/j.cageo.2004.05.006>.
- Kellndorfer, Josef, Oliver Cartus, Marco Lavallo, Christophe Magnard, Pietro Milillo, Shadi Oveisgharan, Batu Osmanoglu, Paul A. Rosen, and Urs Wegmüller. 2022. "Global Seasonal Sentinel-1 Interferometric Coherence and Backscatter Data Set." *Scientific Data* 9 (1): 1–16. <https://doi.org/10.1038/s41597-022-01189-6>.
- Khalaf Jabbar Rafiqul Zaman Khan, Haider DR. 2015. *METHODS TO AVOID OVER-FITTING AND UNDER-FITTING IN SUPERVISED MACHINE LEARNING (COMPARATIVE STUDY)*.
- Kim, Yihyun, Thomas Jackson, Rajat Bindlish, Hoonyol Lee, and Sukyoung Hong. 2013. "Monitoring Soybean Growth Using L-, C-, and X-Band Scatterometer Data." *International Journal of Remote Sensing* 34 (11): 4069–82. <https://doi.org/10.1080/01431161.2013.772309>.
- Kim, Yunjin, and Jakob J. Van Zyl. 2009. "A Time-Series Approach to Estimate Soil Moisture Using Polarimetric Radar Data." *IEEE Transactions on Geoscience and Remote Sensing* 47 (8): 2519–27. <https://doi.org/10.1109/TGRS.2009.2014944>.
- Koppe, Wolfgang, Martin L. Gny, Christoph Hütt, Yinkun Yao, Yuxin Miao, Xinpeng Chen, and Georg Bareth. 2013. "Rice Monitoring with Multi-Temporal and Dual-Polarimetric Terrasar-X Data." *International Journal of Applied Earth Observation and Geoinformation* 21 (1): 568–76. <https://doi.org/10.1016/j.jag.2012.07.016>.

- Kraatz, Simon, Nathan Torbick, Xianfeng Jiao, Xiaodong Huang, Laura Dingle Robertson, Andrew Davidson, Heather McNairn, Michael H. Cosh, and Paul Siqueira. 2021. "Comparison between Dense L-Band and c-Band Synthetic Aperture Radar (Sar) Time Series for Crop Area Mapping over a Nisar Calibration-Validation Site." *Agronomy* 11 (2). <https://doi.org/10.3390/agronomy11020273>.
- Kumar, P., R. Prasad, A. Choudhary, D. K. Gupta, V. N. Mishra, A. K. Vishwakarma, A. K. Singh, and P. K. Srivastava. 2019. "Comprehensive Evaluation of Soil Moisture Retrieval Models under Different Crop Cover Types Using C-Band Synthetic Aperture Radar Data." *Geocarto International* 34 (9): 1022–41. <https://doi.org/10.1080/10106049.2018.1464601>.
- Kussul, Nataliia, Mykola Lavreniuk, Sergii Skakun, and Andrii Shelestov. 2017. "Deep Learning Classification of Land Cover and Crop Types Using Remote Sensing Data." *IEEE Geoscience and Remote Sensing Letters* 14 (5): 778–82. <https://doi.org/10.1109/LGRS.2017.2681128>.
- Labus, M. P., G. A. Nielsen, R. L. Lawrence, R. Engel, and D. S. Long. 2002. "Wheat Yield Estimates Using Multi-Temporal NDVI Satellite Imagery." *International Journal of Remote Sensing* 23 (20): 4169–80. <https://doi.org/10.1080/01431160110107653>.
- Langley, Pat, and Herbert A Simon. 1995. "Applications of Machine Learning and Rule Induction." Vol. 38. <http://robotics.stanford.edu/peo->.
- Leduc, C, S B E N Ammar, G Favreau, R Beji, and R Virrion. 2007. "Impacts of Hydrological Changes in the Mediterranean Zone: Environmental Modifications and Rural Development in the Merguellil Catchment, Central Tunisia" 52 (June 2008): 1162–78.
- Liang, Liang, Liping Di, Ting Huang, Jiahui Wang, Li Lin, Lijuan Wang, and Minhua Yang. 2018. "Estimation of Leaf Nitrogen Content in Wheat Using New Hyperspectral Indices and a Random Forest Regression Algorithm." *Remote Sensing* 10 (12). <https://doi.org/10.3390/rs10121940>.
- Liu, D., Jia, K., Jiang, H., Xia, M., Tao, G., Wang, B., & Chen, Z. (2021). *Fractional Vegetation Cover Estimation Algorithm for FY-3B Reflectance Data Based on Random Forest Regression Method*. 1–17.
- Li, Huapeng, Ce Zhang, Shuqing Zhang, and Peter M. Atkinson. 2019. "Full Year Crop Monitoring and Separability Assessment with Fully-Polarimetric L-Band UAVSAR: A Case Study in the Sacramento Valley, California." *International Journal of Applied Earth Observation and Geoinformation* 74 (September 2018): 45–56. <https://doi.org/10.1016/j.jag.2018.08.024>.
- Li, Jundong, Kewei Cheng, Suhang Wang, Fred Morstatter, Robert P. Trevino, Jiliang Tang, and Huan Liu. 2017. "Feature Selection: A Data Perspective." *ACM Computing Surveys*. Association for Computing Machinery. <https://doi.org/10.1145/3136625>.
- Li, Shuang, Liang Xu, Yinghong Jing, Hang Yin, Xinghua Li, and Xiaobin Guan. 2021. "High-Quality Vegetation Index Product Generation: A Review of NDVI Time Series Reconstruction Techniques." *International Journal of Applied Earth Observation and Geoinformation*. Elsevier B.V. <https://doi.org/10.1016/j.jag.2021.102640>.
- Mandal, Dipankar, Vineet Kumar, Debanshu Ratha, Subhadip Dey, Avik Bhattacharya, Juan M. Lopez-Sanchez, Heather McNairn, and Yalamanchili S. Rao. 2020. "Dual Polarimetric Radar Vegetation Index for Crop Growth Monitoring Using Sentinel-1 SAR Data." *Remote Sensing of Environment* 247 (September). <https://doi.org/10.1016/j.rse.2020.111954>.
- Marti, J, J Bort, G A Slafer, J L Araus, and Correspondence J Bort. n.d. "Can Wheat Yield Be Assessed by Early Measurements of Normalized Difference Vegetation Index?" <https://doi.org/10.1111/j.1744-7348.2007.00126.x>.

- Massuel, Sylvain, and Jeanne Riaux. 2017. "Surexploitation de l'eau Souterraine: Pourquoi Agite-t-On le Drapeau Rouge? Etude de Cas Dans l'aquifère de La Plaine de Kairouan (Tunisie Centrale)." *Hydrogeology Journal* 25 (6): 1607–20. <https://doi.org/10.1007/s10040-017-1568-2>.
- Mercier, Audrey, Julie Betbeder, Jacques Baudry, Julien Denize, Vincent Leroux, Jean-Luc Roger, Fabien Spicher, and Laurence Hubert-Moy. 2019. "Evaluation of Sentinel-1 and -2 Time Series to Derive Crop Phenology and Biomass of Wheat and Rapeseed: Northern France and Brittany Case Studies" 1114903 (October): 2. <https://doi.org/10.1117/12.2533132>.
- Mestre-Quereda, Alejandro, Juan M. Lopez-Sanchez, Fernando Vicente-Guijalba, Alexander W. Jacob, and Marcus E. Engdahl. 2020. "Time-Series of Sentinel-1 Interferometric Coherence and Backscatter for Crop-Type Mapping." *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 13: 4070–84. <https://doi.org/10.1109/JSTARS.2020.3008096>.
- Minallah, Nasru, Mohsin Tariq, Najam Aziz, Waleed Khan, Atiq Ur Rehman, and Samir Brahim Belhaouari. 2020. "On the Performance of Fusion Based Planet-Scope and Sentinel-2 Data for Crop Classification Using Inception Inspired Deep Convolutional Neural Network." *PloS One* 15 (9): e0239746. <https://doi.org/10.1371/journal.pone.0239746>.
- Mountrakis, Giorgos, Jungho Im, and Caesar Ogole. 2011. "Support Vector Machines in Remote Sensing: A Review." *ISPRS Journal of Photogrammetry and Remote Sensing* 66 (3): 247–59. <https://doi.org/10.1016/j.isprsjprs.2010.11.001>.
- Mutanga, O., Adam, E., & Cho, M. A. (2012). High density biomass estimation for wetland vegetation using worldview-2 imagery and random forest regression algorithm. *International Journal of Applied Earth Observation and Geoinformation*, 18(1), 399–406. <https://doi.org/10.1016/j.jag.2012.03.012>
- Naser, Mohammed A., Raj Khosla, Louis Longchamps, and Subash Dahal. 2020. "Using NDVI to Differentiate Wheat Genotypes Productivity under Dryland and Irrigated Conditions." *Remote Sensing* 12 (5). <https://doi.org/10.3390/rs12050824>.
- Nasirzadehdizaji, Rouhollah, Fusun Balik Sanli, Saygin Abdikan, Ziyadin Cakir, Alihsan Sekertekin, and Mustafa Ustuner. 2019. "Sensitivity Analysis of Multi-Temporal Sentinel-1 SAR Parameters to Crop Height and Canopy Coverage." *Applied Sciences (Switzerland)* 9 (4). <https://doi.org/10.3390/app9040655>.
- Ouaadi, Nadia, Lionel Jarlan, Jamal Ezzahar, Mehrez Zribi, Saïd Khabba, Elhoussaine Bouras, Safa Bousbih, and Pierre-Louis Frison. 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* 251 (August): 112050. <https://doi.org/10.1016/j.rse.2020.112050>.
- Ouaadi, Nadia, Lionel Jarlan, Saïd Khabba, Jamal Ezzahar, Michel Le Page, and Olivier Merlin. 2021. "Irrigation Amounts and Timing Retrieval through Data Assimilation of Surface Soil Moisture into the FAO-56 Approach in the South Mediterranean Region," 1–26.
- Ouaadi, N., Jarlan, L., Khabba, S., Le Page, M., Chakir, A., Er-Raki, S., & Frison, P. L. (2023). Are the C-band backscattering coefficient and interferometric coherence suitable substitutes of NDVI for the monitoring of the FAO-56 crop coefficient? *Agricultural Water Management*, 282. <https://doi.org/10.1016/j.agwat.2023.108276>
- Palmisano, Davide, Anna Balenzano, Giuseppe Satalino, Francesco Mattia, Nazzareno Pierdicca, and Andrea Monti-Guarnieri. 2018. "Sentinel-1 Sensitivity to Soil Moisture at High Incidence Angle and Its Impact on Retrieval." *International Geoscience and Remote Sensing Symposium (IGARSS)* 2018-July (9): 1430–33. <https://doi.org/10.1109/IGARSS.2018.8518613>.

- Pasolli, Luca, Claudia Notarnicola, and Lorenzo Bruzzone. 2011. "Estimating Soil Moisture with the Support Vector Regression Technique." *IEEE Geoscience and Remote Sensing Letters* 8 (6): 1080–84. <https://doi.org/10.1109/LGRS.2011.2156759>.
- Pelletier, Charlotte, Silvia Valero, Jordi Inglada, Nicolas Champion, and Gérard Dedieu. 2016. "Assessing the Robustness of Random Forests to Map Land Cover with High Resolution Satellite Image Time Series over Large Areas." *Remote Sensing of Environment* 187: 156–68. <https://doi.org/10.1016/j.rse.2016.10.010>.
- Phan, Hoa, Thuy Le Toan, Alexandre Bouvet, Lam Dao Nguyen, Tien Pham Duy, and Mehrez Zribi. 2018. "Mapping of Rice Varieties and Sowing Date Using X-Band SAR Data." *Sensors (Switzerland)* 18 (1). <https://doi.org/10.3390/s18010316>.
- Pinto, R. Suzuki, Marta S. Lopes, Nicholas C. Collins, and Matthew P. Reynolds. 2016. "Modelling and Genetic Dissection of Staygreen under Heat Stress." *Theoretical and Applied Genetics* 129 (11): 2055–74. <https://doi.org/10.1007/s00122-016-2757-4>.
- Planque, Carole, Richard Lucas, Suvarna Punalekar, Sebastien Chognard, Clive Hurford, Christopher Owers, Claire Horton, et al. 2021. "National Crop Mapping Using Sentinel-1 Time Series: A Knowledge-Based Descriptive Algorithm." *Remote Sensing* 13 (5): 1–30. <https://doi.org/10.3390/rs13050846>.
- Pôças, I., Calera, A., Campos, I., & Cunha, M. (2020). Remote sensing for estimating and mapping single and basal crop coefficients: A review on spectral vegetation indices approaches. In *Agricultural Water Management* (Vol. 233). Elsevier B.V. <https://doi.org/10.1016/j.agwat.2020.106081>
- Rembold, Felix, Michele Meroni, Ferdinando Urbano, Antoine Royer, Clement Atzberger, Guido Lemoine, Herman Eerens, and Dominique Haesen. 2015. "Remote Sensing Time Series Analysis for Crop Monitoring with the SPIRITS Software: New Functionalities and Use Examples." *Frontiers in Environmental Science* 3 (JUL): 1–11. <https://doi.org/10.3389/fenvs.2015.00046>.
- Rolle, Matteo, Stefania Tamea, Pierluigi Claps, Emna Ayari, Nicolas Baghdadi, and Mehrez Zribi. 2022. "Analysis of Maize Sowing Periods and Cycle Phases Using Sentinel 1&2 Data Synergy." *Remote Sensing* 14 (15): 3712. <https://doi.org/10.3390/rs14153712>.
- Rouse, J. W., R. H. Haas, J. A. Schell, and D.W. Deering. 1973. "Monitoring the Vernal Advancement and Retrogradation (Green Wave Effect) of Natural Vegetation." *Progress Report RSC 1978-1*, 112.
- Salcedo-Sanz, S., Ghamisi, P., Piles, M., Werner, M., Cuadra, L., Moreno-Martínez, A., Izquierdo-Verdiguier, E., Muñoz-Marí, J., Mosavi, A., & Camps-Valls, G. (2020). Machine learning information fusion in Earth observation: A comprehensive review of methods, applications and data sources. *Information Fusion*, 63, 256–272. <https://doi.org/10.1016/j.inffus.2020.07.004>
- Schaufler, Stefan, Bernhard Bauer-Marschallinger, Simon Hochstätger, and Wolfgang Wagner. 2018. "Modelling and Correcting Azimuthal Anisotropy in Sentinel-1 Backscatter Data." *Remote Sensing Letters* 9 (8): 799–808. <https://doi.org/10.1080/2150704X.2018.1480071>.
- Schonlau, Matthias, and Rosie Yuyan Zou. 2020. "The Random Forest Algorithm for Statistical Learning." *Stata Journal* 20 (1): 3–29. <https://doi.org/10.1177/1536867X20909688>.
- Segal, Mark R. 2004. "Machine Learning Benchmarks and Random Forest Regression Publication Date Machine Learning Benchmarks and Random Forest Regression." *Center for Bioinformatics and Molecular Biostatistics*, 15.
- Shataee, S., Kalbi, S., Fallah, A., & Pelz, D. (2012). Forest attribute imputation using machine-learning methods and ASTER data: Comparison of k-NN, SVR and random forest regression algorithms.

*International Journal of Remote Sensing*, 33(19), 6254–6280.  
<https://doi.org/10.1080/01431161.2012.682661>

- Shi, Tao, and Steve Horvath. 2006. “Unsupervised Learning with Random Forest Predictors.” *Journal of Computational and Graphical Statistics* 15 (1): 118–38. <https://doi.org/10.1198/106186006X94072>.
- SMOLA, ALEX J., and BERNHARD SCHOLKOPF. 2004. “A Tutorial on Support Vector Regression.” *Statistics and Computing* 14: 199–222.
- Song, Yang, and Jing Wang. 2019. “Mapping Winter Wheat Planting Area and Monitoring Its Phenology Using Sentinel-1 Backscatter Time Series.” *Remote Sensing* 11 (4). <https://doi.org/10.3390/rs11040449>.
- Stendardi, Laura, Stein Rune Karlsen, Georg Niedrist, Renato Gerdol, Marc Zebisch, Mattia Rossi, and Claudia Notarnicola. 2019. “Exploiting Time Series of Sentinel-1 and Sentinel-2 Imagery to Detect Meadow Phenology in Mountain Regions.” *Remote Sensing* 11 (5): 1–24. <https://doi.org/10.3390/rs11050542>.
- Tamm, Tanel, Karlis Zalite, Kaupo Voormansik, and Liina Talgre. 2016. “Relating Sentinel-1 Interferometric Coherence to Mowing Events on Grasslands.” *Remote Sensing* 8 (10): 1–19. <https://doi.org/10.3390/rs8100802>.
- Torres, Ramon, Paul Snoeij, Dirk Geudtner, David Bibby, Malcolm Davidson, Evert Attema, Pierre Potin, et al. 2012. “GMES Sentinel-1 Mission.” *Remote Sensing of Environment* 120 (May): 9–24. <https://doi.org/10.1016/j.rse.2011.05.028>.
- Vavlas, Nikolaos Christos, Toby W. Waive, Jeroen Meersmans, Paul J. Burgess, Giacomo Fontanelli, and Goetz M. Richter. 2020. “Deriving Wheat Crop Productivity Indicators Using Sentinel-1 Time Series.” *Remote Sensing* 12 (15). <https://doi.org/10.3390/RS12152385>.
- Veloso, Amanda, Stéphane Mermoz, Alexandre Bouvet, Thuy Le Toan, Milena Planells, Jean François Dejoux, and Eric Ceschia. 2017. “Understanding the Temporal Behavior of Crops Using Sentinel-1 and Sentinel-2-like Data for Agricultural Applications.” *Remote Sensing of Environment* 199 (September): 415–26. <https://doi.org/10.1016/j.rse.2017.07.015>.
- Villarroya-Carpio, Arturo, Juan M. Lopez-Sanchez, and Marcus E. Engdahl. 2022. “Sentinel-1 Interferometric Coherence as a Vegetation Index for Agriculture.” *Remote Sensing of Environment* 280 (April): 113208. <https://doi.org/10.1016/j.rse.2022.113208>.
- Vreugdenhil, Mariette, Wolfgang Wagner, Bernhard Bauer-Marschallinger, Isabella Pfeil, Irene Teubner, Christoph Rüdiger, and Peter Strauss. 2018. “Sensitivity of Sentinel-1 Backscatter to Vegetation Dynamics: An Austrian Case Study.” *Remote Sensing* 10 (9). <https://doi.org/10.3390/rs10091396>.
- Wagenseil, H., and C. Samimi. 2006. “Assessing Spatio-Temporal Variations in Plant Phenology Using Fourier Analysis on NDVI Time Series: Results from a Dry Savannah Environment in Namibia.” *International Journal of Remote Sensing* 27 (16): 3455–71. <https://doi.org/10.1080/01431160600639743>.
- Wang, Li'ai, Xudong Zhou, Xinkai Zhu, Zhaodi Dong, and Wenshan Guo. 2016. “Estimation of Biomass in Wheat Using Random Forest Regression Algorithm and Remote Sensing Data.” *Crop Journal* 4 (3): 212–19. <https://doi.org/10.1016/j.cj.2016.01.008>.
- Xue, J., & Su, B. (2017). Significant remote sensing vegetation indices: A review of developments and applications. In *Journal of Sensors* (Vol. 2017). Hindawi Limited. <https://doi.org/10.1155/2017/1353691>



- You, Xingzhi, Jihua Meng, Miao Zhang, and Taifeng Dong. 2013. "Remote Sensing Based Detection of Crop Phenology for Agricultural Zones in China Using a New Threshold Method." *Remote Sensing* 5 (7): 3190–3211. <https://doi.org/10.3390/rs5073190>.
- Yuzugullu, Onur, Stefano Marelli, Esra Erten, Bruno Sudret, and Irena Hajnsek. 2017. "Determining Rice Growth Stage with X-Band SAR: A Metamodel Based Inversion." *Remote Sensing* 9 (5): 1–20. <https://doi.org/10.3390/rs9050460>.
- Zhang, Ling, and Bo Zhang. 2002. "Relationship between Support Vector Set and Kernel Functions in SVM." *Journal of Computer Science and Technology* 17 (5): 549–55. <https://doi.org/10.1007/BF02948823>.
- Zhong, Lei, Yaoming Ma, Mhd Suhyb Salama, and Zhongbo Su. 2010. "Assessment of Vegetation Dynamics and Their Response to Variations in Precipitation and Temperature in the Tibetan Plateau." *Climatic Change* 103 (3): 519–35. <https://doi.org/10.1007/s10584-009-9787-8>.
- Zingale, Silvia, Paolo Guarnaccia, Agata Matarazzo, Giovanni Lagioia, and Carlo Ingrao. 2022. "A Systematic Literature Review of Life Cycle Assessments in the Durum Wheat Sector." *Science of the Total Environment* 844 (June): 157230. <https://doi.org/10.1016/j.scitotenv.2022.157230>.
- Zribi, M., A. Chahbi, M. Shabou, Z. Lili-Chabaane, B. Duchemin, N. Baghdadi, R. Amri, and A. Chehbouni. 2011. "Soil Surface Moisture Estimation over a Semi-Arid Region Using ENVISAT ASAR Radar Data for Soil Evaporation Evaluation." *Hydrology and Earth System Sciences* 15 (1): 345–58. <https://doi.org/10.5194/hess-15-345-2011>.
- Zribi, M., Baghdadi, N., Holah, N., & Fafin, O. (2005). New methodology for soil surface moisture estimation and its application to ENVISAT-ASAR multi-incidence data inversion. *Remote sensing of environment*, 96(3-4), 485-496.

## IV.3. Sensibilité de l'estimation de l'humidité du sol aux descripteurs de la végétation estimés à partir des données SAR

### IV.3.1. Résumé

Dans la partie précédente du chapitre, nous avons utilisé la cohérence interférométrique et l'indice normalisé du rapport de polarisation pour reconstruire les cycles NDVI du blé. Les résultats ont mis en relief la pertinence des données en bande C pour décrire la dynamique de la végétation. Dans cette deuxième partie, nous avons exploré le potentiel des descripteurs calculés à partir des données SAR pour estimer l'humidité du sol sur des parcelles dans une région semi-aride.

L'estimation de l'humidité de surface soulève plusieurs problématiques telles que la description de la végétation et sa variabilité spatiotemporelle. L'indice NDVI a prouvé sa pertinence comme étant une variable descriptive de la dynamique des végétations dans le WCM. Cet indice est très bien limité par la présence des nuages. Dans cette partie des travaux, nous avons analysé la pertinence des autres variables alternatives au NDVI, calculées à partir des données SAR.

Nous avons utilisé des mesures in-situ d'humidité du sol durant deux cycles de végétation pendant 2015-2016 et 2016-2017 sur des parcelles dans la plaine de Kairouan avec une base supplémentaire du printemps 2022 acquises pendant les passages satellites Sentinel-1. A partir des données SAR en bande C, nous avons calculé le rapport de polarisation et son indice normalisé IN. L'indice NDVI est calculé à partir des données Sentinel-2.

Afin de mettre en évidence les contributions des données radar dans l'estimation des propriétés de la végétation, nous avons limité la base des données à des valeurs NDVI entre 0.25 et 0.7. Pour éviter l'effet de la rugosité des sols nus, nous avons éliminé les mesures à des valeurs NDVI inférieures à 0.25. En se basant sur des anciens travaux, le potentiel du signal en bande C reste sensible à l'humidité du sol à une valeur seuil NDVI égale à 0.7. Lorsque ce seuil est dépassé, la végétation est très dense et la profondeur de pénétration du signal est limitée.

Les analyses de sensibilité des données radar en fonction des mesures d'humidité du sol ont mis en relief la sensibilité du signal radar à l'humidité du sol surtout en polarisation VV. Cette sensibilité est impactée par les phases de croissance de la végétation. La sensibilité des données en VV décroît de 0.18 dB/vol.%, lorsque les valeurs NDVI varient entre 0.25 et 0.4, à 0.07 dB/vol.%, à des NDVI fluctuant entre 0.55 et 0.7.

Cette dégradation de sensibilité est observable avec les données en VH avec des valeurs comprises entre 0.06 et 0.03 dB/vol.% pour les mêmes gammes NDVI. En analysant les sensibilités en fonction des phénophases, nous avons considéré deux périodes dont la première comprend la phase de croissance de la végétation jusqu'à l'épiaison commençant du mois de Décembre jusqu'à mi-Mars. La deuxième période englobe la phase de maturation jusqu'à la sénescence et la récolte. Durant la phase de croissance de la végétation, l'analyse met en relief la sensibilité des données en bande C à l'humidité de surface du sol en polarisation parallèle VV. Les données en polarisation croisée VH sont moins sensibles au contenu du sol en eau en les comparant avec les données en VV. La sensibilité du signal radar en VV diminue avec l'augmentation du volume de végétation, atteignant un niveau similaire à la sensibilité du signal VH, d'environ 0,02 dB/vol.%, pendant la deuxième période nommée la phase productive.

En utilisant le WCM couplé au IEM-B, nous avons utilisé trois descripteurs de la végétation : NDVI, le rapport de polarisation à une échelle linéaire et l'indice de normalisation de ce ratio. A chaque descripteur, nous avons calibré le modèle pour estimer les paramètres nécessaires A et B avec 70% des données utilisées. Après la validation du modèle calibré avec 30% de la base des données, nous l'avons inversé pour estimer les humidités du sol avec l'algorithme du Look-up Tables. La comparaison des humidités estimées et des mesures in-situ en utilisant les trois descripteurs se caractérise par des RMSE variables entre 5.58 vol.% et 7.45 vol.%. L'estimation la plus précise confère l'utilisation du NDVI. Des performances proches caractérisent l'utilisation du IN et du rapport de polarisation avec des RMSE égales à 6.7 vol.% et 7.45 vol.%, respectivement. L'article suivant confère les détails de la base de données, la méthodologie utilisées ainsi que les résultats et la discussion.

#### IV.3.2. Article

## Sensitivity of surface soil moisture retrieval to satellite-derived vegetation descriptors over wheat fields in the Kairouan plain

Emna Ayari<sup>a,b</sup>, Mehrez Zribi<sup>a</sup>, Zohra Lili-Chabaane<sup>b</sup>, Zeineb Kassouk<sup>b</sup>, Lionel Jarlan<sup>a</sup>, Nemesio Rodriguez-Fernandez<sup>a</sup> and Nicolas Baghdadi<sup>c</sup>

<sup>a</sup>CESBIO, CNES/CNRS/INRAE/IRD/UPS, Université de Toulouse, Toulouse, France; <sup>b</sup>Carthage University, National Agronomic Institute of Tunisia, LR17AGR01 InteGRatEd Management of Natural Resources: remoTE Sensing, Spatial Analysis and Modeling (GREEN-TEAM), Tunis, Tunisia; <sup>c</sup>CIRAD, CNRS, INRAE, TETIS, University of Montpellier, AgroParisTech, Montpellier, France

### ABSTRACT

Soil moisture estimation is a key component in hydrological processes and irrigation amounts' estimation. The synergetic use of optical and radar data has been proven to retrieve the surface soil moisture at a field scale using the Water Cloud Model (WCM). In this work, we evaluate the impact of satellite-derived vegetation descriptors to estimate the surface soil moisture. Therefore, we used the Sentinel-1 data to test the polarization ratio ( $\sigma_{VH}^0/\sigma_{VV}^0$ ) and the normalized polarization ratio (IN) and the frequently used optical Normalized Difference vegetation Index (NDVI) as vegetation descriptors. Synchronous with Sentinel-1 acquisitions, in situ soil moisture were collected over wheat fields in the Kairouan plain in the center of Tunisia. To avoid the bare soil roughness effect and the radar signal saturation in dense vegetation context, we considered the data where the NDVI values vary between 0.25 and 0.7. The soil moisture inversion using the WCM and NDVI as a vegetation descriptor was characterized by an RMSE value of 5.6 vol.%. A relatively close performance was obtained using IN and ( $\sigma_{VH}^0/\sigma_{VV}^0$ ) with RMSE under 7.5 vol.%. The results revealed the consistency of the radar-derived data in describing the vegetation for the retrieval of soil moisture.

### ARTICLE HISTORY

Received 10 May 2023  
Revised 4 August 2023  
Accepted 14 September 2023

### KEYWORDS

Surface soil moisture; wheat; radar; Sentinel-1; normalized difference vegetation index; semi-arid

### Introduction

Water shortages threaten the Mediterranean basin, especially in the southern part, where the impacts of climate change are the most felt (Schilling et al., 2020; Trambly & Somot, 2018). Therefore, the optimization of water resource management is essential for sustainable agriculture (Massari et al., 2021). Surface soil moisture is a key component in the hydrological processes that controls the amount of runoff and infiltrated water (Brocca et al., 2010, 2017; Koster et al., 2016). For soil water content estimation, several soil moisture monitoring techniques based on punctual soil sampling, such as the gravimetric method, and automated soil moisture measurement techniques, such as time domain reflectometry and Thetaprobe sensors, have been used. These methods are time-consuming and require substantial labor to assess the spatial heterogeneities and the temporal dynamics of the soil moisture (Peng et al., 2021; Walker et al., 2004).

To overcome these limitations, remote sensing products were used as an alternative to retrieve surface soil moisture. Owing to the lower sensitivity of microwave signals to weather conditions, operational soil moisture products are available with a spatial resolution varying between 25 and 35 km and a revisit time

of up to one day and include the Soil Moisture and Ocean Salinity (SMOS) (Al Bitar et al., 2017; Kerr et al., 2001), Soil Moisture Active/Passive (SMAP) (Entekhabi et al., 2014) and Advanced Scatterometer (ASCAT) (Wagner et al., 2013). These products have been evaluated by a large number of studies (Albergel et al., 2009; Chen et al., 2018; El Hajj et al., 2018; Mohanty et al., 2017; Wagner et al., 2007; Kerr et al., 2010). The coarse resolution of these products is insufficient to cover soil moisture heterogeneities at the agricultural field scale. Therefore, a high spatial resolution of soil moisture is needed. In this context, several efforts were devoted to retrieving the soil moisture using synthetic radar aperture (SAR) data owing to its sensitivity to the geometric and dielectric properties of the soil. At the field scale, various approaches have been developed to retrieve surface soil moisture using available radar acquisitions in the X-band (Aubert et al., 2013; El Hajj et al., 2016; Fontanelli et al., 2013; Gorrab et al., 2015), C-band (Amazirh et al., 2018; Amri et al., 2012; Bousbih et al., 2017; Ezzahar et al., 2019; Gao et al., 2017; Kumar et al., 2019; Ouadi et al., 2020; Wang et al., 2018, 2023) and L-band (Fascetti et al., 2017; Hamze et al.,

2021; Hosseini & McNairn, 2017; Lievens & Verhoest, 2011; Shi et al., 1995, 1997; Zribi et al., 2019).

Due to the lack of available L-band data, most of the available works were developed using the X- and C-bands, especially after the launch of Sentinel-1 A and B on 3 April 2014 and 25 April 2016, respectively (ESA, 2012). These approaches are based on radar signal behavior modeling and inversion to estimate soil moisture. Over bare soil fields, various empirical models, semiempirical models such as Oh and Dubois and physical models such as the integral equation model (IEM), have been used (Baghdadi & Zribi, 2006; Baghdadi et al., 2011; Choker et al., 2017; Panciera et al., 2014; Tao et al., 2015). The main aim of these models is to relate the radar signal to ground data such as ground truth soil moisture measurements and geometric statistical parameters, including the root mean square of height (Hrms) and the correlation length (Lc).

The presence of vegetation impacts the radar signal behavior. Therefore, different models were proposed in this context to consider the crop contribution in the scattering process (Ulaby et al., 1990; Ulaby, 1975; Ulaby et al., 1984). The water cloud model (WCM) (Attema & Ulaby, 1978) has been extensively used in many works due to its simplicity. The total backscattering is the sum of the vegetation contribution, the attenuated bare soil contribution and the soil-vegetation interaction contribution. The interaction term is often neglected in the case of the C-band. The WCM may be coupled to the aforementioned bare soil models to calculate the soil contribution. The vegetation contribution and the attenuation term are calculated as a function of the crop descriptor. Notably, crop description is critical for the soil moisture estimation process.

The choice of the vegetation descriptor was extensively discussed and tested due to the complexity of the geometric structure and dynamics of vegetation. Some vegetation descriptors may be measured in situ, such as vegetation height, leaf area index, leaf water area index, aboveground biomass and vegetation water content (Chauhan et al., 2018; El Hajj et al., 2014; Kumar et al., 2015). Using optical data, crop descriptions may include indices such as the normalized difference vegetation index (NDVI) (Ayari et al., 2021; Baghdadi et al., 2017; Bousbih et al., 2018; Prakash et al., 2012) or be directly extracted from MODIS products such as NDVI, the leaf area index (LAI) and the enhanced vegetation index (EVI) (Wang et al., 2019). Several studies have estimated the descriptors using established empirical relationships between SAR data and vegetation variables (Ouaadi et al., 2021) or between optical data and variables (Liu & Shi, 2016; Ma et al., 2020). Periasamy (2018) investigated the potential of C-band Sentinel-1 to estimate

the Above Ground Biomass using the calculated SAR variables at *i* pixel: such as VH backscattering coefficients, the inverse dual polarization diagonal distance  $((\sigma_{VV,max}^0 - \sigma_{VV,i}^0) + \sigma_{VH,i}^0)/\sqrt{2}$ , and the vertical dual de-polarization index  $((\sigma_{VV,i}^0 + \sigma_{VH,i}^0)/\sigma_{VV,i}^0)$ . To retrieve the soil moisture at field-scale, Bhogapurapu et al. (2022) used the copolarized purity parameter  $DpRVI_C = \frac{q(q+3)}{(q+1)^2}$ , where *q* is the ratio parameter  $(\sigma_{XY}^0/\sigma_{XX}^0)$  and X and Y are H or V polarizations, respectively, as the vegetation descriptor over croplands and shrublands. The aforementioned derived parameter already proved its pertinence to monitor the vegetation growth cycle in (Mandal et al., 2020).

In the L-band, Wang et al. (2021) tested four vegetation descriptors to retrieve the soil moisture, including the vegetation water content (VWC-NDVI) estimated using the empirical relationship between in situ measurements and the NDVI and the derived SAR data, such as the RVI  $((8 \times \sigma_{HV}^0)/(2 \times \sigma_{HV}^0 + \sigma_{VV}^0 + \sigma_{HH}^0))$ , the polarization ratio  $(\sigma_{HV}^0/\sigma_{VV}^0)$  and the VH backscattering coefficients. A similar accuracy was obtained by the VWC-NDVI and the polarization ratio as crop descriptors with RMSE values equal to 8.8 vol.% and 9.1 vol.%, respectively (Wang et al., 2021).

For grasslands, using X-band data, El Hajj et al. (2016) investigated the potential of vegetation descriptors derived from optical data such as the fraction of absorbed active radiation, the fractional vegetation cover, the leaf area index and NDVI. For NDVI values fluctuating between 0.45 and 0.75, the RMSE value was 3.6 vol.% when the NDVI was used as the vegetation variable. When the NDVI exceeded 0.75, the RMSE increased to 6 vol.%. The soil moisture retrieval accuracy was similar for the rest of the tested descriptors. The use of the NDVI as vegetation descriptor is limited by the cloud presence and its saturation within dense vegetation context. Therefore, in the present work, as an alternative to NDVI, we investigate the potential of the derived Sentinel-1 C-band SAR data to incorporate the wheat cover effects when estimating surface soil in the semi-arid Kairouan plain in Tunisia. The used data and the adopted methodology are described in the second section. In the third section, we present the results and the discussion. In the final section, we draw the conclusions.

## Materials and methodology

### Study area and ground-based data

The study area is located in the plain of Kairouan in Tunisia (35°1'–35°55' N, 9°23'–10°17' E) as illustrated in Figure 1. This alluvial flat landscape covers an area

of 3000 km<sup>2</sup> and is characterized by a semi-arid climate. The annual quantity of precipitation is approximately 300 mm with an irregular spatiotemporal distribution. The temperature varies from 11°C in the coldest months, namely, December, January and February, to 30°C during July and August, the hottest months. The land use mainly comprises cereals, olive trees, orchards and seasonal market garden crops (Amri et al., 2012; Shabou et al., 2015; Zribi et al., 2011).

In the present work, we used collected insitu data in several selected wheat fields in the plain of Kairouan during two agricultural years (2015/2016; 2016/2017) and the spring of 2022 (from April to mid-May). The wheat cycle in Kairouan starts with sowing events in December, vegetation development, and the heading approximately during the mid of March and

senescence phases. It ends with the harvest extending from the end of May to the end of June. Over the wheat reference fields and during S-1 acquisitions, soil moisture measurements were collected at approximately 20 points by the handheld Thetaprobe in the first top layer of soil (first 5 cm). The used Thetaprobe were already calibrated with gravimetric measurements over the same studied area in (Zribi et al., 2014). As detailed in Table 1, the soil moisture values vary from 7.5 to 41.2 vol.%.

### Satellite data

#### Sentinel-1 (S-1)

Since the launch of Sentinel-1A and B on 3 April 2014 and 25 April 2016, respectively, C-band synthetic aperture radar (SAR) data are




Figure 1. Location of the study area and the reference wheat fields in the Kairouan Plain.

Table 1. Characteristics of Sentinel-1 images and collected ground-based soil moisture during the agricultural years (2015–2016 and 2016–2017) and the spring of 2022 (due to the failure of the Sentinel-1B, the C-band images in 2022 were acquired every 12 days with Sentinel-1 A).

	Total number of S-1 images	Number of S-1 images	Orbit	Revisit time	Number of test fields	Soil moisture (vol.%)	
						Min	Max
2015–2016	19	7	Ascending	6 days	9	7.6	39.1
06/12–10/05		12	Descending				
2016–2017	19	10	Ascending	6 days	10	7.5	41.2
23/12–23/04		9	Descending				
2021–2022	8	4	Ascending	12 days	15	7.7	28.9
08/04–15/05		4	Descending				

available in a variety of modes, polarizations and resolutions. For the present study, we used Ground Range Detected S-1 images acquired in Interferometric Wide Swath (IW) mode at a frequency of 5.405 GHz in vertical-vertical (VV) and vertical-horizontal (VH) polarizations. For the study area, the selected images were characterized by a pixel spacing of 10 m × 10 m and an incidence angle between 39° and 40°, as described in Table 1.

The already processed S-1 images were downloaded from Google Earth Engine (<https://developers.google.com/earth-engine/datasets/catalog/sentinel>). For each S-1 scene, the backscattering coefficients were generated in dB scale in VV-polarization ( $\sigma_{VV}^0$ ) and VH-polarization ( $\sigma_{VH}^0$ ) in each pixel were derived after five processing steps, namely, orbit file application, border and thermal noise removal, radiometric calibration and terrain correction. After converting each scene to the linear scale, the backscattering coefficients were averaged per field. The polarization ratio ( $\sigma_{VH}^0/\sigma_{VV}^0$ ) in linear scale was computed for each field. The normalized index IN was computed from the polarization ratio ( $\sigma_{VH}^0/\sigma_{VV}^0$ ) converted in dB scale for each reference field during each wheat growth season using the following equation in Rolle et al. (2022):

$$IN = \frac{\sigma_{VH}^0/\sigma_{VV}^0 - \sigma_{VH}^0/\sigma_{VVmin}^0}{\sigma_{VH}^0/\sigma_{VVmax}^0 - \sigma_{VH}^0/\sigma_{VVmin}^0} \quad (1)$$

The normalization of the polarization ratio aims to have a radar index comparable to the NDVI, where the values range from 0 (when  $\sigma_{VH}^0/\sigma_{VV}^0$  min to 1 (when  $\sigma_{VH}^0/\sigma_{VV}^0 = \sigma_{VH}^0/\sigma_{VV}^0$  max) and the  $\sigma_{VH}^0/\sigma_{VVmin}^0$  and  $\sigma_{VH}^0/\sigma_{VVmax}^0$  are calculated per reference field and for each wheat growth season.

### Sentinel-2 (S-2)

The surface reflectance data were cloud-free selected and downloaded from the Theia site (<https://www.theia-land.fr/donnees-satellites/>). The Sentinel-2 data were corrected for atmospheric effects via the MAJA software (Hagolle et al., 2017), which detected clouds and their shadows and produced level 2A reflectance data. We used the red and infrared bands, B4 and B8, respectively, to calculate the normalized difference vegetation index (NDVI). For each wheat field and each date, the mean value of NDVI is calculated.

### Water cloud model (WCM)

As developed by (Attema & Ulaby, 1978), the WCM considers the total backscattering as the sum of the vegetation contribution, the bare soil contribution attenuated by the vegetation and the contribution of soil-vegetation interactions. Due to the limited penetration depth of the C-band signal, the interaction

term is often neglected. Consequently, the total backscattering coefficient at the field scale can be calculated using the following equations (2–4):

$$\sigma^0 = \sigma_{veg}^0 + \tau^2 \times \sigma_{soil}^0 \quad (2)$$

$$\sigma_{veg}^0 = AV1 \cos \theta (1 - \tau^2) \quad (3)$$

$$\tau^2 = \exp(-2BV2 \sec \theta) \quad (4)$$

The bare soil backscattering  $\sigma_{soil}^0$  was calculated using the integral equation model with the calibrated correlation length (IEM-B) as detailed in (Baghdadi et al., 2006). The bare soil properties included the measured soil moisture and constant geometrical parameter (Hrms) for all the wheat reference fields. Due to the lack of roughness measurements, we considered that Hrms is equal to 1 cm as measured in semi-arid Mediterranean regions in (Bousbih et al., 2017; Ouadi et al., 2021) and tested in (Ouadi et al., 2020).

The Integral Equation Model was funded by Fung et al., 1992 as function of the SAR sensor parameters (incidence angle, polarization and the frequency) as well as the surface properties such as the roughness and dielectric properties. The potential of the IEM to simulate the radar backscattering coefficients was examined in several works. The correlation length is one of the inputs of IEM which is difficult to estimate and the less accurate among the roughness measurements. Therefore, Baghdadi et al. (2006), replaced the correlation length with a calibrated parameter expressed as function of the incidence angle  $\theta$  and the Hrms values as the following equation for the C-band data in VV polarization and using the Gaussian correlation function:

$$Lopt(VV) = 1.281 + 0.134(\sin(0.19\theta))^{-1.59} Hrms \quad (5)$$

In the present paper, our main concern is about correcting the vegetation cover effect in the soil moisture retrieve process using different descriptors calculated whether from optical or radar data. In this context, we avoided the analysis of bare soil (NDVI > 0.25) to allow a precise estimation of each descriptor's contribution.

Additionally, we used the threshold of NDVI under 0.7 to avoid dealing with very dense vegetation context. In fact, the C-band radar signal has already shown its limitation in correcting the effect of very dense vegetation for soil moisture retrieval.

In (Baghdadi et al., 2017), the Sentinel-1 signal simulation using the WCM and the NDVI as vegetation descriptor revealed that the vegetation contribution dominates the attenuated bare soil backscattering when NDVI is equal to 0.7 and the soil moisture is about 5 vol.%. At an incidence angle higher than 40°, the NDVI threshold is about 0.6.

By comparing the potential of L and C-bands data, the authors of (El Hajj et al., 2019) demonstrated that

the penetration depth of the C-band signal is limited where the NDVI is equal to 0.7. Based on these conclusions, the operational products of surface soil moisture based on the synergy of Sentinel-1 and Sentinel-2 were limited to NDVI values lower than 0.75 (El Hajj et al., 2017). The main aim is to better estimate the contributions of each vegetation descriptor within the optimum inversion context. The vegetation contribution  $\sigma_{veg}^0$ . The vegetation contribution and the attenuation term  $\tau^2$  were calculated as functions of the vegetation descriptors ( $V1$  and  $V2$ ) and the incidence angle  $\theta$ .

In the present study, we tested three vegetation descriptors ( $V1 = V2 = NDVI$ ), ( $V1 = V2 =$  polarization ratio in linear scale) and ( $V1 = V2 = IN$ ).  $A$  and  $B$  are parameters that were calibrated and validated depending on the vegetation properties and the SAR sensor parameters. The  $A$  and  $B$  are two key parameters in the WCM simulations of the total backscattering over covered fields. As discussed in (Park et al., 2019), the accuracy of these parameters will improve the estimation of the attenuation and the volume scattering and consequently the accuracy of the surface soil moisture

Seventy percent of the entire dataset was used for the calibration (163 points), and 30% was devoted to the validation step (70 points).

## Results

### Radar sensitivity to surface soil moisture

In Figure 2, we scatterplot the backscattering coefficients in VV and VH polarizations as a function of the

in-situ measurements of the surface soil moisture. Using the copolarized data ( $\sigma_{VV}^0$ ), we observe better sensitivity to soil moisture with a value of 0.12 dB/vol.% compared to 0.04 dB/vol.% using the VH polarization ( $\sigma_{VH}^0$ ). The correlation coefficient values vary between 0.56 and 0.12 for VV and VH, respectively. According to Figure 2, some discrepancies were observed. These points are characterized by high NDVI values (NDVI > 0.6), indicating the presence of dense vegetation combined with soil moisture values varying between 25 and 35 vol.%. The presence of vegetation introduces volume scattering in the backscattering process while the bare soil contribution decreases with the vegetation development. This effect is more clearly highlighted in the cross-polarization (VH) than in the copolarization (VV).

To examine the vegetation impact on the soil moisture retrieval, in Figure 3 the backscattering coefficients in dB were analyzed as function of the measured soil moisture according to three classes of NDVI:  $0.25 < NDVI \leq 0.4$ ,  $0.4 < NDVI \leq 0.55$  and  $0.55 < NDVI \leq 0.7$ . The sensitivity of the VV-polarized data to the soil moisture (correlation coefficient) decreases from 0.18 dB/vol.% ( $r = 0.71$ ) to 0.07 dB/vol.% ( $r = 0.43$ ) when the NDVI values increase from 0.25 to 0.7. Using the VH-polarized C-band data, the sensitivity of radar signal to the soil moisture varies between 0.06 and 0.03 dB/vol.%. The intercomparison between the two polarizations highlights that the co-polarized data is more sensitive to soil moisture than the cross-polarized one.


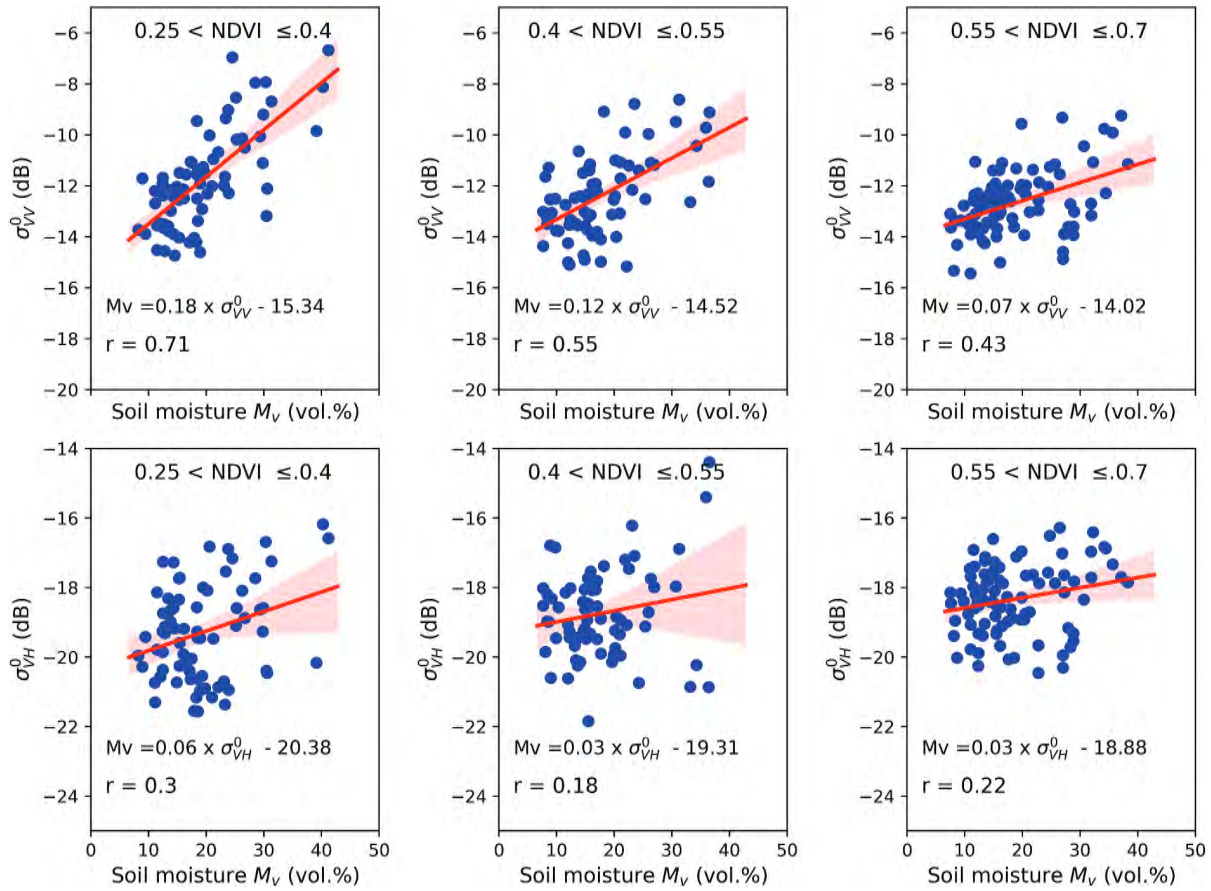


Figure 2. Scatterplots of the backscattering coefficients in VV and VH polarizations as a function of the in-situ measurements of soil moisture over the wheat reference fields in the Kairouan plain.





**Figure 3.** Scatterplots of the Sentinel-1 backscattering coefficients as a function of the in-situ measurements of soil moisture over the wheat reference fields according to three classes of NDVI ( $0.25 < \text{NDVI} \leq 0.4$ ,  $0.4 < \text{NDVI} \leq 0.55$  and  $0.55 < \text{NDVI} \leq 0.7$ ).

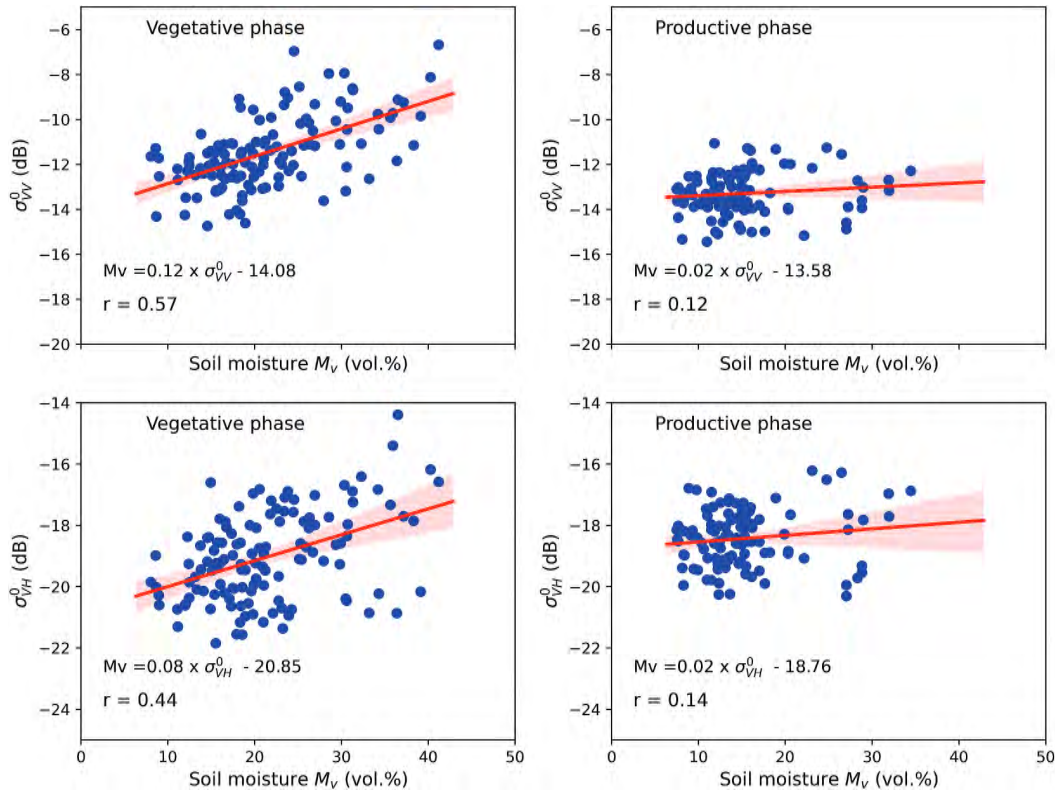
In Figure 4, the sensitivity of the backscattering coefficients is illustrated as function of the soil moisture according to the vegetation development phases: vegetative phase and productive phase. For the first phase which occurred from December to the mid of March, the vegetation is developed and marked finally by the heading event (the NDVI values increase to a maximum value). The second phase, which started after the heading event is marked by the presence of the vegetation volume and the grain filling until the harvest starting from the end of May (the NDVI values decrease to a maximum value).

During the first phase, we observe that the Sentinel-1 is more sensitive to the soil moisture in VV polarization (0.12 dB/vol.%) more than VH polarization (0.08 dB/vol.%). This may be induced from the sensitivity of VV polarization to the bare soil contribution in this first phase of wheat development. Regarding the second phase, when the vegetation covers the soil and its volume governs the scattering process, the sensitivity of the VV-polarized signal decreases to be in the same range of the VH-polarized data. Owing to this lower sensitivity of cross-polarized data to soil moisture, we selected only the copolarized data to estimate the soil moisture.

### Empirical relationships between vegetation descriptors

In Figure 5, we analyzed the NDVI as a function of the calculated radar variables such as the polarization ratio in dB ( $\sigma_{VH}^0/\sigma_{VV}^0$ ) and its normalization (IN). Positive correlations characterize the linear relationships between the polarization ratio and the NDVI. The correlation coefficients vary from 0.67 to 0.58 using the data during 2015/2016 and 2016/2017, respectively.

The lowest correlation coefficient, equal to 0.17, is observed in the scatterplot of the NDVI as a function of the polarization ratio during the spring of 2022, where the polarization ratio values are between  $-6$  and  $-4$  dB with low NDVI value dynamics. The high values of the ratio indicate high VH backscattering in addition to a lower contribution of VV backscattering. Otherwise, well-developed vegetation, contributes by volume scattering within the total backscattering, regarding a decreased contribution from bare soil. This situation could be observed especially in the senescence phase of the wheat where the vegetation is present and mature with a yellow color and the maximum developed biomass. Therefore, the NDVI values are low regarding high ratio values, as identified by the red circles in Figure 5, during 2016/2017. The



**Figure 4.** Scatterplots of the Sentinel-1 backscattering coefficients as a function of the in-situ measurements of soil moisture over the wheat reference fields according to two wheat growth phases (vegetative and productive).

same trends were observed for winter wheat using the polarization ratio (Ouaadi et al., 2020; Veloso et al., 2017). The same discrepancies were observed for the data between April and May 2022, which used the IN with an *correlation* coefficient equal to 0.2. These discrepancies confirmed the limited potential of radar data in case of dense vegetation especially after wheat maturation.

### Radar signal modeling over wheat fields

The use of WCM requires the calibration and validation of *A* and *B* parameters for each tested vegetation descriptor, namely, NDVI, polarization ratio and IN.

The *A* values vary between 0.05 and 0.125, and the *B* values range from 0.55 to 1.18. The highest values of *A* and *B*, 0.1 and 1.18, respectively, are found using the polarization ratio. Over the same validation site, using the NDVI as a vegetation descriptor and the WCM coupled with the empirical model, the calibrated *A* and *B* parameters are equal to 0.06 and 0.42, respectively (Bousbih et al., 2017, 2018)


For the WCM coupled to IEM-B was tested in (Baghdadi et al., 2017) over the same study site of Kairouan plain, using the C-band data, the *A* parameter is equal to 0.095, and the *B* parameter is approximately 0.55. In Figure 6, we scatterplot the modeled and S-1 observed backscattering coefficients with the respective calibrated coefficients *A* and *B* and the statistical parameters root mean square error

(RMSE), bias and correlation coefficients (*r*). The RMSE and the bias values vary from 1.2 to 1.32 dB and from  $-0.1$  to  $-0.05$  dB, respectively. The *r* values fluctuate between 0.59 and 0.69 using the three satellite-derived variables.


After the WCM calibration using 70% of the dataset, we used the *A* and *B* parameters to simulate the signal over the wheat fields. Figure 7 shows the relationships between the modeled backscattering coefficients and the Sentinel-1 coefficients. Using the NDVI as the vegetation variable ( $V1=V2=NDVI$ ), the RMSE and the bias values are equal to 1.26 dB and 0.02 dB, respectively. Based on the S-1 data, we notice almost the same RMSE values equal to 1.15 dB using the IN and 1.13 dB using the polarization ratio. According to the bias calculations, we observe low bias values between  $-0.06$  dB and 0.02 dB. High correlation values characterize the linear relationships between the simulated radar signal and the Sentinel-1 signal for VV polarization varying between 0.61 and 0.7.

### Soil moisture estimation

To retrieve the soil moisture, we performed an inversion of the WCM using the lookup table algorithm. In Figure 8, we represent the estimated soil moisture as a function of the in-situ measurements and the statistical parameters (*r*, RMSE and bias). The inversion of soil moisture using the WCM model and the optical



**Figure 5.** Scatterplots of the NDVI as a function of the polarization ratio and the normalized index (IN) during 2015/2016, 2016/2017 and the spring of 2022. The red circles represent the saturation problems identified during the senescence period, especially in 2016/2017 (see text).




**Figure 6.** Scatterplots of calibrated backscattering coefficients and the VV-polarized S-1 data using the remote sensing data as vegetation descriptors (NDVI, IN and the polarization ratio in linear scale) with the corresponding statistical parameters (RMSE, bias and r).


index as a vegetation descriptor is characterized by the lowest RMSE value of 5.58 vol.%.

A relatively close performance was obtained using IN and the polarization ratio with RMSE values equal to 6.7 and 7.45 vol.%, respectively. However, the correlation decreases significantly from 0.68 to 0.53 and 0.4 when using IN and the polarization ratio,

respectively. Considering the polarization ratio, we observe a satisfactory level of accuracy, where the RMSE and bias values are approximately 7.45 vol.% and  $-1.47$  vol.%, respectively. A relatively close performance characterizes the use of the IN as a wheat descriptor in the soil moisture estimation with a mean underestimation of 2 vol.%.



**Figure 7.** Scatterplots of validation backscattering coefficients and the VV-polarized S-1 data using the remote sensing data as vegetation descriptors (NDVI, in and the polarization ratio in linear scale) with the corresponding statistical parameters (RMSE, bias and  $r$ ).



**Figure 8.** Scatterplots of the estimated soil moisture as a function of the in-situ measurements using the inversion of WCM as a function of the vegetation descriptor (NDVI, in and the polarization ratio in linear scale ( $\sigma_{VH}^0/\sigma_{VV}^0$ )) with the statistical parameters (RMSE, bias and  $r$ ).

## Discussion

The incorporation of the SAR-derived variables as vegetation descriptor results produced a relatively close accuracy to the soil moisture estimations attained by the optical index. In terms of RMSE values, a difference of 10% between the IN and the polarization ratio characterizes the performance of the soil water content. This result may be due to the normalization of the polarization ratio, which is an index with a range of values between 0 and 1. Consequently, this normalization decreases the differences between the fields in terms of roughness effects and vegetation-induced backscattering.

The aforementioned results were in the same range of accuracy in previous works. Over the same study area, the authors of (Bousbih et al., 2018) estimated the soil moisture using Sentinel-1 in VV polarization and

the NDVI as a wheat descriptor. The RMSE and correlation coefficient of the soil moisture content estimates were 6.4 vol.% and 0.63, respectively. Wang et al. (2019) selected the NDVI as the optimum descriptor of vegetation compared with other normalized vegetation parameters, such as the enhanced vegetation index (EVI) and fraction of photosynthetically active radiation (FPAR). Based on the statistical metrics by Wang et al. (2019), the inversion of WCM using the NDVI induced an RMSE value equal to 8.8 vol.% and a bias of  $-0.2$  vol.%. Bhogapurapu et al. (2022) investigated the potential of the NDVI and the Sentinel-1 copolarized purity parameter ( $DpRVI_C$ ) as crop descriptors to estimate the surface soil moisture. The use of  $DpRVI_C$  to estimate the soil moisture was characterized by RMSE value equal to 5.5 vol.% despite a value of 7.6 vol.% using the NDVI over croplands. In semi-arid region, Ouadi et al.

(2020) estimated the aboveground biomass (AGB) and vegetation water content (VWC) using the empirical relationships between in situ measurements and the Sentinel-1 polarization ratio and coherence. The retrieved variables were used as vegetation descriptors in the WCM to estimate the surface soil moisture. By comparing the potential of the NDVI and the derived AGB and VWC from the polarization ratio over the Kairouan site, a similar accuracy of the soil water content estimation was observed. The RMSE and bias values were lower than 8 vol.% and 2 vol.%, respectively.

Despite the potential of the normalized index to detect sowing events in Rolle et al. (2022), the integration of IN in soil moisture retrieval is characterized by a moderate RMSE value of 6.7 vol.% and a correlation coefficient of 0.53. This performance may be due to a characteristic of the normalized ratio, which reduced spatial vegetation variations between fields. Based on the aforementioned results, the relationships between the optical and SAR-derived information must be further investigated according to the wheat growth phases. This investigation focuses on the effect of vegetation volume scattering on the process of soil moisture estimation. In further steps, we aim to test the potential of other SAR-vegetation descriptors such as the interferometric coherence and the polarimetric parameters which can correct the vegetation canopy effects in the surface soil moisture retrieval using radar data. Additionally, one of the limitations of the developed approach is the consideration of constant roughness parameters to estimate the soil moisture. This assumption is derived from ground measurements and previous studies over wheat fields in semi-arid context (Bousbih et al., 2017; Ouaadi et al., 2020, 2021) which highlighted that the small variations in the range of Hrms during wheat growth seasons. Therefore, the developed method of surface soil moisture retrieval can be transposable in the southern Mediterranean regions over wheat fields.

## Conclusions

In this work, we retrieved the surface soil moisture at a depth of five cm over wheat fields in the Kairouan Plain. We used the Sentinel-1 data to calculate the back-scattering coefficients, the polarization ratio and its normalization and the Sentinel-2 data to calculate the NDVI. To estimate the soil moisture, the WCM coupled with the modified integral equation model was calibrated using 70% of the dataset and validated by 30% of the dataset. We estimate the soil moisture using the look-up table. The results highlighted the importance of the derived SAR ratio in linear scale ( $\sigma_{VH}^0/\sigma_{VV}^0$ ) and the normalized index IN as alternatives for the NDVI to retrieve the soil moisture at the field scale. The RMSE of soil moisture retrieval ranged between 5.58 and 7.45 vol.

% using the different variables (NDVI,  $\sigma_{VH}^0/\sigma_{VV}^0$  and IN). In the case of the Kairouan Plain,  $\sigma_{VH}^0/\sigma_{VV}^0$  and IN can be considered a reliable tool to retrieve the soil moisture when the NDVI values are lower than 0.7 and higher than 0.25. These Sentinel-1-derived data may be a solution for vegetation description with full gap-free time series during cloud presence, especially in temperate and tropical climate regions. In the context of future missions such as NISAR and ROSE-L, SAR acquisitions in the L-band will be available. Hence, the description of vegetation volume scattering using L-band data will be further investigated. Consequently, the correction of the vegetation effect will be more precise and reliable using the L-band data than the C-band case.

## Acknowledgments

This research has been supported by the European Space Agency Climate Change Initiative for Soil Moisture (grant 4000126684/19/I-NB), the Viana (ERA-Net ARIMNet) Project, the PHC Utique IPASS Project, the Chaams (ERANET3-602 CHAAMS) Project, the Irrigation+ ((ESA n° 4000129870/20/I-NB) Project; the TAPAS TOSCA/CNES project and H2020 ACCWA project. We would like to thank the ARTS program/IRD for awarding a PhD scholarship to Emna Ayari. We extend our warm thanks to the technical teams at the IRD and INAT (Institut National Agronomique de Tunisie) who participated in the ground truth measurement campaigns and data processing.

## Disclosure statement

No potential conflict of interest was reported by the author(s).

## Data availability statement

The data that support the findings of this study are available from the co-author, Mehrez Zribi, upon reasonable request.

## References

- Albergel, C., Rüdiger, C., Carrer, D., Calvet, J. C., Fritz, N., Naeimi, V., Bartalis, Z., & Hasenauer, S. (2009). An evaluation of ASCAT surface soil moisture products with in-situ observations in Southwestern France. *Hydrology and Earth System Sciences*, 13(2), 115–124. <https://doi.org/10.5194/hess-13-115-2009>
- Al Bitar, A., Mialon, A., Kerr, Y. H., Cabot, F., Richaume, P., Jacquette, E., Quesney, A., Mahmoodi, A., Tarot, S., Parrons, M., Al-Yaari, A., Pellarin, T., Rodriguez-Fernandez, N., & Wigneron, J. P. (2017). The global SMOS level 3 daily soil moisture and brightness temperature maps. *Earth System Science Data*, 9(1), 293–315. <https://doi.org/10.5194/essd-9-293-2017>
- Amazirh, A., Merlin, O., Er-Raki, S., Gao, Q., Rivalland, V., Malbeteau, Y., Khabba, S., & Escorihuela, M. J. (2018). Retrieving surface soil moisture at high spatio-temporal resolution from a synergy between Sentinel-1 radar and Landsat thermal data: A study case over bare soil. *Remote*

- Sensing of Environment*, 211, 321–337. <https://doi.org/10.1016/j.rse.2018.04.013>
- Amri, R., Zribi, M., Chabaane, Z. L., Wagner, W., Member, S., & Hasenauer, S. (2012). Analysis of C-Band scatterometer moisture estimations derived over a semiarid region. *IEEE Transactions on Geoscience & Remote Sensing*, 50(7), 2630–2638. <https://doi.org/10.1109/TGRS.2012.2186458>
- Attema, E. P. W., & Ulaby, F. T. (1978). Vegetation modeled as a water cloud. *Radio Science*, 13(2), 357–364. <https://doi.org/10.1029/RS013i002p00357>
- Aubert, M., Baghdadi, N. N., Zribi, M., Ose, K., el Hajj, M., Vaudour, E., & Gonzalez-Sosa, E. (2013). Toward an operational bare soil moisture mapping using terrasar-x data acquired over agricultural areas. *IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing*, 6(2), 900–916. <https://doi.org/10.1109/JSTARS.2012.2220124>
- Ayari, E., Kassouk, Z., Lili-Chabaane, Z., Baghdadi, N., Bousbih, S., & Zribi, M. (2021). Cereal crops soil parameters retrieval using L-band ALOS-2 and C-band sentinel-1 sensors. *Remote Sens (Basel)*, 13(7), 1393. <https://doi.org/10.3390/rs13071393>
- Baghdadi, N., Abou Chaaya, J., & Zribi, M. (2011). Semiempirical calibration of the integral equation model for SAR data in C-Band and cross polarization using radar images and field measurements. *IEEE Geoscience and Remote Sensing Letters*, 8(1), 14–18. <https://doi.org/10.1109/LGRS.2010.2050054>
- Baghdadi, N., El Hajj, M., Zribi, M., & Bousbih, S. (2017). Calibration of the water cloud model at C-Band for Winter crop fields and grasslands 1–13. *Remote Sensing*, 9(9), 969. <https://doi.org/10.3390/rs9090969>
- Baghdadi, N., Holah, N., & Zribi, M. (2006). Calibration of the integral equation model for SAR data in C-band and HH and VV polarizations. *International Journal of Remote Sensing*, 27(4), 805–816. <https://doi.org/10.1080/01431160500212278>
- Baghdadi, N., & Zribi, M. (2006). Evaluation of radar backscatter models IEM, OH and Dubois using experimental observations. *International Journal of Remote Sensing*, 27(18), 3831–3852. <https://doi.org/10.1080/01431160600658123>
- Bhogapurapu, N., Dey, S., Homayouni, S., Bhattacharya, A., & Rao, Y. S. (2022). Field-scale soil moisture estimation using sentinel-1 GRD SAR data. *Advances in Space Research*, 70(12), 3845–3858. <https://doi.org/10.1016/j.asr.2022.03.019>
- Bousbih, S., Zribi, M., Hajj, M. E., Baghdadi, N., Lili-Chabaane, Z., Gao, Q., & Fanise, P. (2018). Soil moisture and irrigation mapping in a semi-arid region, based on the Synergetic use of Sentinel-1. *Remote Sens (Basel)* 22. *Remote Sensing*, 10(12), 1953. <https://doi.org/10.3390/rs10121953>
- Bousbih, S., Zribi, M., Lili-Chabaane, Z., Baghdadi, N., El Hajj, M., Gao, Q., & Mougenot, B. (2017). Potential of sentinel-1 radar data for the assessment of soil and cereal cover parameters. *Sensors (Switzerland)*, 17(11), 2617. <https://doi.org/10.3390/s17112617>
- Brocca, L., Ciabatta, L., Massari, C., Camici, S., & Tarpanelli, A. (2017). Soil moisture for hydrological applications: Open questions and new opportunities. *Water*, 9(2), 140. <https://doi.org/10.3390/w9020140>
- Brocca, L., Melone, F., Moramarco, T., Wagner, W., Naeimi, V., Bartalis, Z., & Hasenauer, S. (2010). Improving runoff prediction through the assimilation of the ASCAT soil moisture product. *Hydrology and Earth System Sciences*, 14(10), 1881–1893. <https://doi.org/10.5194/hess-14-1881-2010>
- Chauhan, S., Srivastava, H. S., & Patel, P. (2018). Wheat crop biophysical parameters retrieval using hybrid-polarized RISAT-1 SAR data. *Remote Sensing of Environment*, 216, 28–43. <https://doi.org/10.1016/j.rse.2018.06.014>
- Chen, F., Crow, W. T., Bindlish, R., Colliander, A., Burgin, M. S., Asanuma, J., & Aida, K. (2018). Global-scale evaluation of SMAP, SMOS and ASCAT soil moisture products using triple collocation. *Remote Sensing of Environment*, 214, 1–13. <https://doi.org/10.1016/j.rse.2018.05.008>
- Choker, M., Baghdadi, N., Zribi, M., el Hajj, M., Paloscia, S., Verhoest, N. E. C., Lievens, H., & Mattia, F. (2017). Evaluation of the oh, Dubois and IEM backscatter models using a large dataset of SAR data and experimental soil measurements. *Water*, 9(1), 38. <https://doi.org/10.3390/w9010038>
- El Hajj, M., Baghdadi, N., Belaud, G., Zribi, M., Cheviron, B., Courault, D., Hagolle, O., & Charron, F. (2014). Irrigated grassland monitoring using a time series of TerraSAR-X and COSMO-SkyMed X-Band SAR data. *Remote Sensing*, 6(10), 10002–10032. <https://doi.org/10.3390/rs61010002>
- El Hajj, M., Baghdadi, N., & Zribi, M. (2019). Comparative analysis of the accuracy of surface soil moisture estimation from the C- and L-bands. *Int. J. Appl. Earth Obs. Geoinf*, 82, 101888. <https://doi.org/10.1016/j.jag.2019.05.021>
- El Hajj, M., Baghdadi, N., Zribi, M., & Bazzi, H. (2017). Synergic use of Sentinel-1 and Sentinel-2 images for operational soil moisture mapping at high spatial resolution over agricultural areas. *Remote Sensing*, 9(12), 1–28. <https://doi.org/10.3390/rs9121292>
- 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 Sensing of Environment*, 176, 202–218. <https://doi.org/10.1016/j.rse.2016.01.027>
- El Hajj, M., Baghdadi, N., Zribi, M., Rodríguez-Fernández, N., Wigneron, J. P., Al-Yaari, A., Al Bitar, A., Albergel, C., & Calvet, J. C. (2018). Evaluation of SMOS, SMAP, ASCAT and Sentinel-1 soil moisture products at sites in Southwestern France. *Remote Sensing*, 10(4), 1–17. <https://doi.org/10.3390/rs10040569>
- Entekhabi, D., Yueh, S. H., O'Neill, P. E., Kellogg, K. H., Allen, A. M., Bindlish, R., Brown, M., Chan, S. T., Colliander, A., Crow, W. T., Das, N. N., Lannoy, G. D., Dunbar, R. S., Edelstein, W. N., Entin, J. K., Escobar, V. M., Goodman, S. D., Jackson, T. J., & West, R. D. (2014). SMAP handbook. *JPL Publication*, JPL 400–1567.
- ESA. (2012). *Sentinel-1: ESA's radar observatory mission for GMES operational services*. ESA Special Publication.
- Ezzahar, J., Ouadi, N., Zribi, M., Elfarkh, J., Aouade, G., Khabba, S., Er-Raki, S., Chehbouni, A., & Jarlan, L. (2019). Evaluation of backscattering models and support vector machine for the retrieval of bare soil moisture from sentinel-1 data. *Remote Sensing*, 12(1), 1–20. <https://doi.org/10.3390/rs12010072>
- Fascetti, F., Pierdicca, N., & Pulvirenti, L. (2017). Empirical fitting of forward backscattering models for multitemporal retrieval of soil moisture from radar data at L-band. *Journal of Applied Remote Sensing*, 11(1), 016002. <https://doi.org/10.1117/1.jrs.11.016002>
- Fontanelli, G., Paloscia, S., Zribi, M., & Chahbi, A. (2013). Sensitivity analysis of X-band SAR to wheat and barley

- leaf area index in the Merguellig Basin. *Remote Sensing Letters*, 4(11), 1107–1116. <https://doi.org/10.1080/2150704X.2013.842285>
- Fung, A. K., Li, Z., & Chen, K. S. (1992). Backscattering from a randomly rough dielectric surface. *IEEE Transactions on Geoscience and Remote Sensing*, 30(2), 356–369. <https://doi.org/10.1109/36.134085>
- Gao, Q., Zribi, M., Escorihuela, M. J., & Baghdadi, N. (2017). Synergetic use of sentinel-1 and sentinel-2 data for soil moisture mapping at 100 m resolution. *Sensors (Switzerland)*, 17(9), 1966. <https://doi.org/10.3390/s17091966>
- Gorab, A., Zribi, M., Baghdadi, N., Mougenot, B., Fanise, P., & Lili-Chabaane, Z. (2015). Retrieval of both soil moisture and texture using TerraSAR-X images. *Remote Sensing*, 7(8), 10098–10116. <https://doi.org/10.3390/rs70810098>
- Hagolle, O., Huc, M., Descardins, C., Auer, S., & Richter, R. (2017). MAJA Algorithm Theoretical Basis Document (1.0). Zenodo. <https://zenodo.org/record/1209633>
- Hamze, M., Baghdadi, N., el Hajj, M. M., Zribi, M., Bazzi, H., Cheviron, B., & Faour, G. (2021). Integration of L-Band derived soil roughness into a bare soil moisture retrieval approach from C-Band SAR data. *Remote Sensing*, 13(11), 2102. <https://doi.org/10.3390/rs13112102>
- Hosseini, M., & McNairn, H. (2017). Using multi-polarization C- and L-band synthetic aperture radar to estimate biomass and soil moisture of wheat fields. *International Journal of Applied Earth Observation and Geoinformation*, 58, 50–64. <https://doi.org/10.1016/j.jag.2017.01.006>
- Kerr, Y. H., Waldteufel, P., Wigneron, J. -P., Delwart, S., Cabot, F., Boutin, J., Escorihuela, M. -J., Font, J. et al. 2010. The SMOS Mission : New Tool for Monitoring Key Elements of the Global Water Cycle. Proceedings of the IEEE, 98, 666–685. <http://doi.org/10.1109/JPROC.2010.2043032>
- Kerr, Y. H., Waldteufel, P., Wigneron, J.-P., Martinuzzi, J., Font, J., & Berger, M. (2001). Soil moisture retrieval from space: The soil moisture and Ocean Salinity (SMOS) mission. *IEEE Transactions on Geoscience and Remote Sensing*, 39(8), 1729–1735. <https://doi.org/10.1109/36.942551>
- Koster, R. D., Brocca, L., Crow, W. T., Burgin, M. S., & de Lannoy, G. J. M. (2016). Precipitation estimation using L-band and C-band soil moisture retrievals. *Water Resources Research*, 52(9), 7213–7225. <https://doi.org/10.1002/2016WR019024>
- Kumar, P., Prasad, R., Choudhary, A., Gupta, D. K., Mishra, V. N., Vishwakarma, A. K., Singh, A. K., & Srivastava, P. K. (2019). Comprehensive evaluation of soil moisture retrieval models under different crop cover types using C-band synthetic aperture radar data. *Geocarto International*, 34(9), 1022–1041. <https://doi.org/10.1080/10106049.2018.1464601>
- Kumar, K., Suryanarayana Rao, H. P., & Arora, M. K. (2015). Study of water cloud model vegetation descriptors in estimating soil moisture in Solani catchment. *Hydrological Processes*, 29(9), 2137–2148. <https://doi.org/10.1002/hyp.10344>
- Lievens, H., & Verhoest, N. E. C. (2011). On the retrieval of soil moisture in wheat fields from L-band SAR based on water cloud modeling, the IEM, and effective roughness parameters. *IEEE Geoscience and Remote Sensing Letters*, 8(4), 740–744. <https://doi.org/10.1109/LGRS.2011.2106109>
- Liu, C., & Shi, J. (2016). Estimation of vegetation parameters of water cloud model for Global soil moisture retrieval using time-series L-Band aquarius Observations. *IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing*, 9(12), 5621–5633. <https://doi.org/10.1109/JSTARS.2016.2596541>
- Ma, C., Li, X., & McCabe, M. F. (2020). Retrieval of high-resolution soil moisture through combination of Sentinel-1 and Sentinel-2 data. *Remote Sensing*, 12(14), 12. <https://doi.org/10.3390/rs12142303>
- Mandal, D., Kumar, V., Ratha, D., Dey, S., Bhattacharya, A., Lopez-Sanchez, J. M., McNairn, H., & Rao, Y. S. (2020). Dual polarimetric radar vegetation index for crop growth monitoring using sentinel-1 SAR data. *Remote Sensing of Environment*, 247, 111954. <https://doi.org/10.1016/j.rse.2020.111954>
- Massari, C., Modanesi, S., Dari, J., Gruber, A., De Lannoy, G. J. M., Giroto, M., Quintana-Seguí, P., Le Page, M., Jarlan, L., Zribi, M., Ouadi, N., Vreugdenhil, M., Zappa, L., Dorigo, W., Wagner, W., Brombacher, J., Pelgrum, H., Jaquot, P., Freeman, V. et al. (2021). A review of irrigation information retrievals from space and their utility for users. *Remote Sensing*, 13(20), 1–26. <https://doi.org/10.3390/rs13204112>
- Mohanty, B. P., Cosh, M. H., Lakshmi, V., & Montzka, C. (2017). Soil moisture Remote Sensing: State-of-the-Science. *Vadose Zone Journal*, 16(1), 1–9. <https://doi.org/10.2136/vzj2016.10.0105>
- Ouadi, N., Ezzahar, J., Khabba, S., Er-Raki, S., Chakir, A., Ait Hssaine, B., le Dantec, V., Rafi, Z., Beaumont, A., Kasbani, M., & Jarlan, L. (2021). C-band radar data and in situ measurements for the monitoring of wheat crops in a semi-arid area (center of Morocco). *Earth System Science Data*, 13(7), 3707–3731. <https://doi.org/10.5194/essd-13-3707-2021>
- Ouadi, 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 Sensing of Environment*, 251, 112050. <https://doi.org/10.1016/j.rse.2020.112050>
- Panciera, R., Tanase, M. A., Lowell, K., & Walker, J. P. (2014). Evaluation of IEM, Dubois, and oh radar backscatter models using airborne L-Band SAR. *IEEE Transactions on Geoscience and Remote Sensing*, 52(8), 4966–4979. <https://doi.org/10.1109/TGRS.2013.2286203>
- Park, S. E., Jung, Y. T., Cho, J. H., Moon, H., & Han, S. H. (2019). Theoretical evaluation of water cloud model vegetation parameters. *Remote Sensing*, 11(8), 894. <https://doi.org/10.3390/rs11080989>
- Peng, J., Albergel, C., Balenzano, A., Brocca, L., Cartus, O., Cosh, M. H., Crow, W. T., Dabrowska-Zielinska, K., Dadson, S., Davidson, M. W. J., de Rosnay, P., Dorigo, W., Gruber, A., Hagemann, S., Hirschi, M., Kerr, Y. H., Lovergine, F., Mahecha, M. D. ... Loew, A. (2021). A roadmap for high-resolution satellite soil moisture applications – confronting product characteristics with user requirements. *Remote Sensing of Environment*, 252, 112162. <https://doi.org/10.1016/j.rse.2020.112162>
- Periasamy, S. (2018). Significance of dual polarimetric synthetic aperture radar in biomass retrieval: An attempt on Sentinel-1. *Remote Sensing of Environment*, 217, 537–549. <https://doi.org/10.1016/j.rse.2018.09.003>
- Prakash, R., Singh, D., & Pathak, N. P. (2012). A fusion approach to retrieve soil moisture with SAR and optical

- data. *IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing*, 5(1), 196–206. <https://doi.org/10.1109/JSTARS.2011.2169236>
- Rolle, M., Tamea, S., Claps, P., Ayari, E., Baghdadi, N., & Zribi, M. (2022). Analysis of maize sowing periods and cycle phases using Sentinel 1&2 data synergy. *Remote Sensing*, 14(15), 3712. <https://doi.org/10.3390/rs14153712>
- Schilling, J., Hertig, E., Trambly, Y., & Scheffran, J. (2020). Climate change vulnerability, water resources and social implications in North Africa. *Regional Environmental Change*, 20(1). <https://doi.org/10.1007/s10113-020-01597-7>
- Shabou, M., Mougenot, B., Chabaane, Z. L., Walter, C., Boulet, G., Aissa, N. B., & Zribi, M. (2015). Soil clay content mapping using a time series of Landsat TM data in semi-arid lands. *Remote Sensing*, 7(5), 6059–6078. <https://doi.org/10.3390/rs70506059>
- Shi, J., Wang, J., Hsu, A., O'Neill, P., & Engman, E. T. (1995). Estimation of soil moisture and surface roughness parameters using L-band SAR measurements. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 1, 507–509. <https://doi.org/10.1109/igarss.1995.520322>
- Shi, J., Wang, J., Hsu, A. Y., O'Neill, P. E., & Engman, E. T. (1997). Estimation of bare surface soil moisture and surface roughness parameter using L-band SAR image data. *IEEE Transactions on Geoscience and Remote Sensing*, 35(5), 1254–1266. <https://doi.org/10.1109/36.628792>
- Tao, L., Li, J., Jiang, J., He, S., Cai, Q., & Chen, X. (2015). Evaluation of radar backscattering models using L- and C-band synthetic aperture radar data. *Journal of Applied Remote Sensing*, 9(1), 094091. <https://doi.org/10.1117/1.jrs.9.094091>
- Trambly, Y., & Somot, S. (2018). Future evolution of extreme precipitation in the Mediterranean. *Climatic Change*, 151(2), 289–302. <https://doi.org/10.1007/s10584-018-2300-5>
- Ulaby, F. T. (1975). Radar response to vegetation. *IEEE Transactions on Antennas & Propagation*, 23(1), 36–45. <https://doi.org/10.1109/TAP.1975.1140999>
- Ulaby, F. T., Allen, C. T., Eger, G., & Kanemasu, E. (1984). Relating the microwave backscattering coefficient to leaf area index. *Remote Sensing of Environment*, 14(1–3), 113–133. [https://doi.org/10.1016/0034-4257\(84\)90010-5](https://doi.org/10.1016/0034-4257(84)90010-5)
- Ulaby, F. T., Sarabandi, K., McDonald, K., Whitt, M., & Craig, M. (1990). Michigan Microwave Canopy Scattering Model. *International Journal of Remote Sensing*, 11(7), 1223–1253. <https://doi.org/10.1080/01431169008955090>
- Veloso, A., Mermoz, S., Bouvet, A., le Toan, T., Planells, M., Dejoux, J. F., & Ceschia, E. (2017). Understanding the temporal behavior of crops using Sentinel-1 and Sentinel-2-like data for agricultural applications. *Remote Sensing of Environment*, 199, 415–426. <https://doi.org/10.1016/j.rse.2017.07.015>
- Wagner, W., Blöschl, G., Pampaloni, P., Calvet, J. C., Bizzarri, B., Wigneron, J. P., & Kerr, Y. (2007). Operational readiness of microwave remote sensing of soil moisture for hydrologic applications. *Hydrology Research*, 38(1), 1–20. <https://doi.org/10.2166/nh.2007.029>
- Wagner, W., Hahn, S., Kidd, R., Melzer, T., Bartalis, Z., Hasenauer, S., Figa-Saldaña, J., de Rosnay, P., Jann, A., Schneider, S., Komma, J., Kubu, G., Brugger, K., Aubrecht, C., Züger, J., Gangkofner, U., Kienberger, S., Brocca, L. . . . Rubel, F. (2013). The ASCAT soil moisture product: A review of its specifications, validation results, and emerging applications. *Meteorologische Zeitschrift*, 22(1), 5–33. <https://doi.org/10.1127/0941-2948/2013/0399>
- Walker, J. P., Willgoose, G. R., & Kalma, J. D. (2004). In situ measurement of soil moisture: A comparison of techniques. *Journal of Hydrology*, 293(1–4), 85–99. <https://doi.org/10.1016/j.jhydrol.2004.01.008>
- Wang, L., He, B., Bai, X., & Xing, M. (2019). Assessment of different vegetation parameters for parameterizing the coupled water cloud model and advanced integral equation model for soil moisture retrieval using time series Sentinel-1A data. *Photogrammetric Engineering & Remote Sensing*, 85(1), 43–54. <https://doi.org/10.14358/PERS.85.1.xxx>
- Wang, H., Magagi, R., & Goïta, K. (2018). Potential of a two-component polarimetric decomposition at C-band for soil moisture retrieval over agricultural fields. *Remote Sensing of Environment*, 217, 38–51. <https://doi.org/10.1016/j.rse.2018.08.003>
- Wang, Z., Zhao, T., Qiu, J., Zhao, X., Li, R., & Wang, S. (2021). Microwave-based vegetation descriptors in the parameterization of water cloud model at L-band for soil moisture retrieval over croplands. *GIScience & Remote Sensing*, 58(1), 48–67. <https://doi.org/10.1080/15481603.2020.1857123>
- Wang, Z., Zhao, T., Shi, J., Wang, H., Ji, D., Yao, P., Zheng, J., Zhao, X., & Xu, X. (2023). 1-km soil moisture retrieval using multi-temporal dual-channel SAR data from Sentinel-1 A/B satellites in a semi-arid watershed. *Remote Sensing of Environment*, 284, 284. <https://doi.org/10.1016/j.rse.2022.113334>
- Zribi, M., Chahbi, A., Shabou, M., Lili-Chabaane, Z., Duchemin, B., Baghdadi, N., Amri, R., & Chehbouni, A. (2011). Soil surface moisture estimation over a semi-arid region using ENVISAT ASAR radar data for soil evaporation evaluation. *Hydrology and Earth System Sciences*, 15(1), 345–358. <https://doi.org/10.5194/hess-15-345-2011>
- Zribi, M., Gorrab, A., & Baghdadi, N. (2014). A new soil roughness parameter for the modelling of radar backscattering over bare soil. *Remote Sensing of Environment*, 152, 62–73. <https://doi.org/10.1016/j.rse.2014.05.009>
- Zribi, M., Muddu, S., Bousbih, S., Al Bitar, A., Tomer, S. K., Baghdadi, N., & Bandyopadhyay, S. (2019). Analysis of L-band SAR data for soil moisture estimations over agricultural areas in the tropics. *Remote Sensing*, 11(9), 11. <https://doi.org/10.3390/rs11091122>



## IV.4. Conclusions

Dans ce chapitre, nous avons examiné le potentiel des données en bande C Sentinel-1 pour décrire la végétation dans le processus d'estimation d'humidité du sol en premier lieu et la construction du cycle NDVI des blés en second lieu. Les trois variables, notamment NDVI, le rapport de polarisation IN et son indice normalisé, sont utilisées comme étant des descripteurs de la végétation dans le WCM sur des parcelles de blé dans la plaine de Kairouan. Dans ce contexte, nous avons testé l'indice de la normalisation du rapport de polarisation (IN) et la cohérence interférométrique calculées à partir des données Sentinel-1 telles que pour estimer l'indice optique NDVI. L'approche développée se base sur l'utilisation des équations d'ajustement et les algorithmes d'apprentissage supervisée tels que Random Forest et Support Vector Regressor pour établir des modèles d'estimation du NDVI à chaque phase phénologique du cycle de blé. Ce dernier est divisé en deux parties dont la première décrit la croissance de la végétation jusqu'à l'épiaison. La deuxième partie se scinde en deux sous-périodes avec la première octroie avec la phase de maturation et la deuxième sous-période décerne la phase de senescence.

Après la calibration et la validation des modèles par période, nous avons testé cette approche d'estimation par période pour retrouver le cycle NDVI avec des RMSE variables entre 0.12 et 0.19. La reconstruction des cycles NDVI se caractérise par un faible niveau de corrélation durant la période de maturation et senescence. Face à un couvert séché et ainsi un NDVI décroissant, nous observons un indice radar non négligeable lié à l'effet volume provenant de la biomasse sèche. Cet effet a affaibli la précision sur cette période du cycle de végétation.

Le potentiel de l'indice de la normalisation du rapport de polarisation est examiné pour estimer l'humidité du sol. L'état hydrique du sol à une profondeur de 5 cm est estimé en inversant le WCM couplé avec le IEM-B, avec des RMSE variantes entre 5.58 vol.% et 7.45 vol.%. Les résultats sont en bonne concordance avec les anciens travaux dans la même zone d'étude. En outre, ils ont introduit la possibilité de substituer l'indice NDVI par d'autres variables calculées à partir des données radar.

Les résultats présentés dans ce chapitre ont mis en relief le potentiel des données en bande C acquises par Sentinel-1 pour décrire la dynamique du blé. En utilisant des variables estimées par les données SAR, nous avons pu les intégrer dans l'estimation de l'humidité de surface du sol et l'estimation d'un indice optique. Ce potentiel peut être impliqué dans d'autres applications agronomiques telles que l'estimation des volumes d'irrigation et de l'évapotranspiration. En outre, l'utilisation des données radar peut être une solution pour obtenir des séries temporelles des indices optiques et des estimations d'humidité du sol sans lacunes surtout dans les zones tempérées ou tropicales qui se caractérisent par la forte présence des nuages.

## Chapitre V

---

Apport de l'humidité de surface du sol  
dans le suivi de la variabilité climatique  
à une échelle régionale

---

# Chapitre V

## Apport de l'humidité de surface du sol dans le suivi de la variabilité climatique à une échelle régionale

---

### V.1. Introduction

L'humidité de surface du sol constitue une frontière critique entre l'atmosphère et la terre. Il s'agit d'un facteur déterminant dans la répartition des processus hydrologiques entre infiltration, ruissellement et évapotranspiration (Dong et al., 2022, 2023 ; Feldman et al., 2020 ; Short Gianotti et al., 2020). Sa dynamique est jugée comme étant un indicateur robuste et généralisé dans les études hydroclimatologiques, météorologiques et agronomiques (Berg et al., 2017 ; Dong et al., 2022 ; Feldman et al., 2018, 2022, 2023 ; Yao et al., 2021 ; Zhao & Dai, 2015).

Dans le contexte actuel d'assèchement des sols, l'humidité du sol est une propriété clé dans les assimilations des scénarii de projection des changements climatiques (Cook et al., 2020 ; Plummer et al., 2017). D'ailleurs, Orth & Seneviratne, (2012) ont identifié un effet mémoire exercé par l'humidité du sol sur les systèmes climatiques. Il s'agit d'une variable saisonnière qui reflète l'impact des régimes des précipitations sur les propriétés du sol et les caractéristiques de la végétation.

De plus, les événements extrêmes de sécheresse ou des inondations sont les plus marqués sur ses séries d'humidité du sol ce qui améliore, par conséquence, les prévisions des variables climatiques (Brocca et al., 2017 ; Feng et al., 2022 ; Massari et al., 2014 ; Orth & Seneviratne, 2012 ; Qiao et al., 2022). En outre, les séries temporelles d'humidité du sol ont été utilisées pour quantifier les précipitations à une large échelle (Brocca et al., 2014 ; Koster et al., 2016) . Également, Dong et al., (2022) ont confirmé le rôle du contenu en eau du sol comme étant une variable clé dans l'identification et la prévision des zones de transition de l'évapotranspiration limitée par l'eau ou par l'énergie.

Bien qu'il s'agisse d'une variable clé dans la modélisation, elle était mal simulée dans les modèles climatiques globaux à cause de sa résolution spatiale grossière qui ne considère pas les hétérogénéités des observations de surface à une échelle régionale (Zhao & Dai, 2015).

De ce fait, à une échelle spatiale plus fine de l'ordre de 1 Km, Madelon et al., (2023) ont prouvé le potentiel des produits opérationnels en utilisant la synergie des satellites Sentinel-1 et Sentinel-2 ou la synergie de Sentinel-1 et Sentinel-3 avec d'autres produits opérationnels tels que SMAP et Copernicus Global Land Service (CGLS). Ces travaux ont mis en relief le potentiel de ces produits pour l'utiliser ultérieurement dans la modélisation numérique des prévisions climatiques.


Dans ce contexte, plusieurs questions peuvent soulever : Est-ce que l'humidité de surface est une variable fiable pour identifier les anomalies climatiques sur une série temporelle ? Dans le cas de confirmation, quelles sont les résolutions spatiales et temporelles adéquates ?

Notre objectif dans ce chapitre est d'analyser l'apport des observations de l'humidité de surface multi-annuelle pour évaluer les anomalies et les évolutions climatiques. Dans une première partie, nous nous sommes intéressés à la validation du potentiel d'une série temporelle des données opérationnelles d'humidité de sol en surface (HRSM), depuis 2017 jusqu'à juin 2022 en les comparant aux données SMAP. Ces produits sont établis à partir des données radar et optiques acquises par Sentinel-1 et Sentinel-2, respectivement, selon l'approche développée par (El Hajj et al., 2017). Dans la deuxième partie, une analyse des séries temporelles des données HRSM est réalisée en fonction des étages bioclimatiques de la Tunisie.

## V.2. Matériels et Méthodes

### V.2.1. Base de données

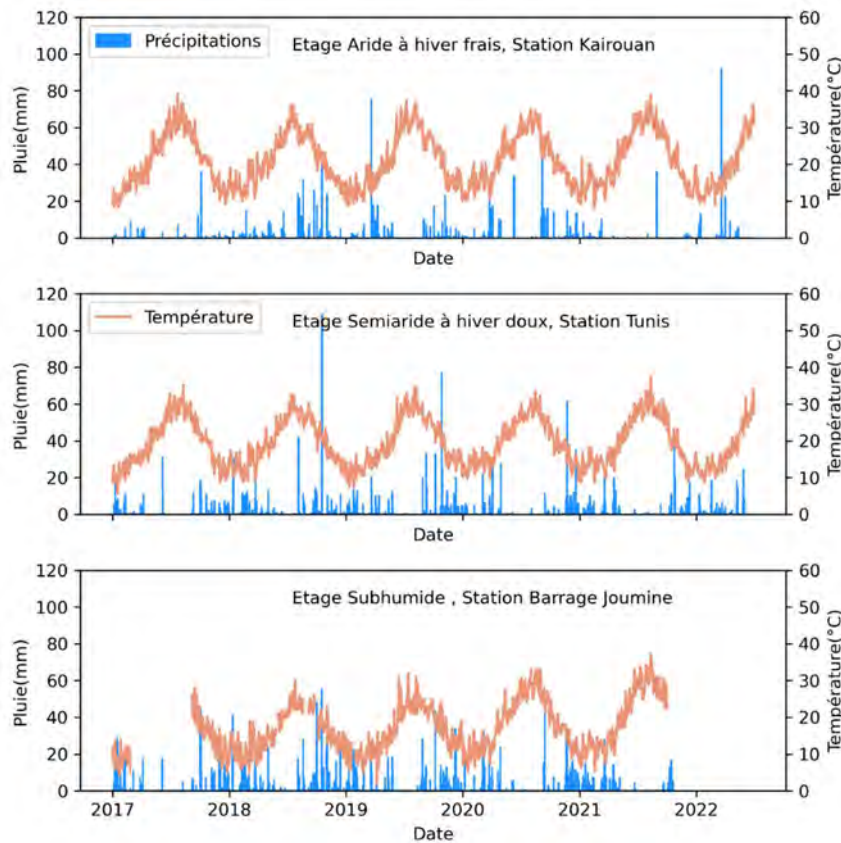
Les travaux dans ce chapitre sont établis sur une large échelle spatiale couvrant approximativement les trois quarts de la Tunisie. Cette zone, illustrés dans la **Figure 35**, se caractérise par une variabilité des étages bioclimatiques selon la classification d'Emberger, 1976 : étage humide, subhumide, semi-aride à hiver frais, semi-aride à hiver doux, aride à hiver frais et aride à hiver doux. Cette variabilité climatique a induit une variabilité d'adaptation des systèmes de productions agricole locales et régionales. Pour comprendre cette dynamique, nous allons analyser la capacité de la variable humidité de surface du sol à interpréter la variation des conditions agrométéorologiques et climatiques de la zone étudiée.



**Figure 35.** Classification des étages bioclimatiques de la zone d'étude en Tunisie avec la localisation des stations météorologiques (la station barrage Jôumine, la station Tunis et la station de Kairouan).

Dans le cadre de ce travail, nous avons utilisé les produits HRSM à une résolution spatiale de 1 Km et les données composites L3 SMAP à une résolution spatiale de 36 Km. La description des données est détaillée dans la section des produits opérationnels d'humidité de surface du sol dans le deuxième chapitre du présent manuscrit.

Pour renforcer les analyses en fonction des étages bioclimatiques, nous avons eu le recours à des séries des variables météorologiques principalement des précipitations des trois stations localisées dans la **Figure 36**. Les stations barrage Jôumine, Tunis et Kairouan appartiennent respectivement aux étages subhumide, semi-aride à hiver doux et aride à hiver frais. Ces séries des précipitations et des températures journalières des stations sont illustrées dans la **Figure 36**. Les séries de température se caractérisent par une saisonnalité avec des pics au niveau des saisons estivales. En contrepartie, des précipitations extrêmes et irrégulières marquent les stations des étages aride et semi-aride.



**Figure 36.** Séries temporelles des précipitations et des températures des trois stations : barrage Joumine (données fournies par la direction des barrages), Tunis et Kairouan (données fournies par le site Meteostat <https://meteostat.net/fr/> ).

### V.2.2. Méthodologie

Les analyses de la série temporelle des produits opérationnels d’humidité de surface ont été conduites en fonction des moyennes d’humidité par dates des produits HRSM et SMAP et des moyennes d’humidité mensuelles. Dans un premier temps, les moyennes des humidités de surfaces HRSM et SMAP ont été calculées par étage bioclimatique par date des produits d’humidité. Notamment, un indice est calculé à partir de ces moyennes selon l’équation suivante :

$$I_{A,j,p} = \frac{Moy_{j,p} - (Moy_{j,p})_{min}}{(Moy_{j,p})_{max} - (Moy_{j,p})_{min}}$$

Avec  $I_{A,j,p}$  est l’indice normalisé par date d’acquisition  $j$  à l’étage bioclimatique  $p$ ,  $Moy_{j,p}$  est la moyenne des humidités de surface de la date  $j$  de l’étage  $p$ ,  $(Moy_{j,p})_{min}$  et  $(Moy_{j,p})_{max}$  sont les moyennes minimale et maximales, respectivement, des humidités de surface de l’étage  $p$  sur toute la série temporelle des produits.

Dans un deuxième temps, nous avons calculé la moyenne mensuelle des produits HRSM et SMAP par année à chaque étage bioclimatique. Les délimitations des étages bioclimatiques de la carte d'Emberger 1976 ont été numérisées par AGEOS (<https://opengeodata-ageos-tunisie.hub.arcgis.com/datasets>). Dans un second temps, à partir des moyennes mensuelles de chaque étage bioclimatique, nous avons calculé l'indice de SSM pour chaque mois. Cet indice exprimé selon l'équation suivante :

$$I_{M,i,p} = \frac{Moy_{mens,i,p} - (Moy_{mens,i,p})_{min}}{(Moy_{mens,i,p})_{max} - (Moy_{mens,i,p})_{min}}$$

Avec  $I_{M,i,p}$  est l'indice normalisé mensuel à l'étage bioclimatique  $p$ ,  $Moy_{mens,i,p}$  est la moyenne des humidités de surface du mois  $i$  de l'étage  $p$ ,  $(Moy_{mens,i,p})_{min}$  et  $(Moy_{mens,i,p})_{max}$  sont les moyennes mensuelles minimale et maximales, respectivement, des humidités de surface du mois  $i$  de l'étage  $p$  sur toute la série temporelle des produits.

Les séries temporelles des moyennes mensuelles des données d'humidité de sol et des indices mensuels ont été analysées en fonction des deux saisons pluvieuse et sèche. La saison pluvieuse couvre les mois du Septembre au Mai et la saison sèche couvre les mois d'été (Juin, Juillet et Août).

### V.3. Résultats et Discussion

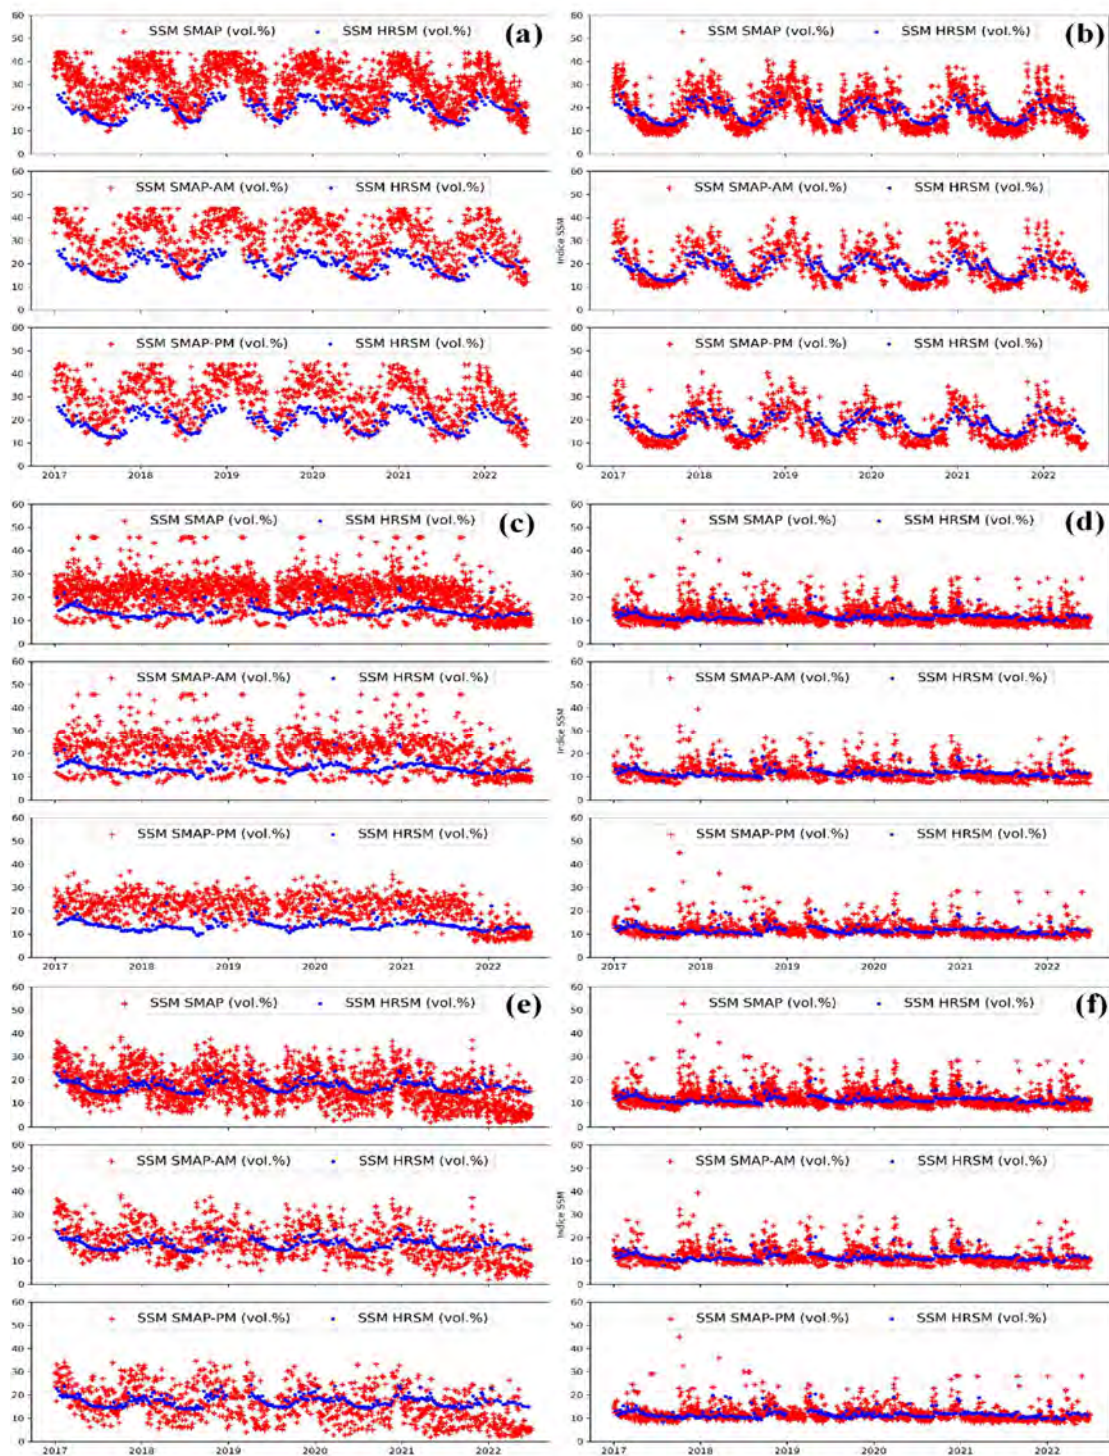
#### V.3.1. Intercomparaison des produits HRSM et SMAP

Hormis l'année 2022, les produits HRSM sont générés chaque six jours d'une part. D'autre part, les données SMAP sont disponibles environ chaque deux à trois jours avec deux acquisitions par jour. Afin de trouver les explications des différences observées dans les moyennes mensuelles, nous avons examiné les séries de mesures d'humidité de surface du sol en fonction de la date de génération et en tenant compte de l'étage bioclimatique.

Dans la Figure 37, nous présentons les séries des humidités HRSM et SMAP moyennées par étage bioclimatique. Bien que les données HRSM soient saturées au niveau de 29 vol.%, ces produits reprennent l'évolution des humidités de surface du sol en utilisant les données SMAP pour les deux étages humide et subhumide (**Figure 37, a et b**). Les pics des humidités de surface du sol des étages bioclimatiques aride et semi-arides sont parfois ratés par les données HRSM. Cette variabilité est accentuée lorsque l'hiver est doux (**Figure 37, c et e**).




Nous observons également une diminution prononcée des humidités de surface du sol durant 2022 surtout au niveau des données SMAP. Ceci peut être due à la résolution temporelle des produits HRSM qui passe de six jours à douze jours après la panne du Sentinel-1 B.




**Figure 37.** Séries temporelles des mesures d’humidité à partir des produits SMAP, SMAP-AM, SMAP-PM et HRSM entre 2017 et 2022 en fonction des étages bioclimatiques : (a) humide (b) subhumide (c) aride à hiver doux (d) aride à hiver frais (e) semi-aride à hiver doux et (f) semi-aride à hivers frais.

Pour confirmer l'origine des pics des humidités des surfaces du sol, nous avons tracé l'évolution des humidités en fonction des pluies de trois stations météorologiques appartenant aux étages subhumide, semi-aride à hiver doux et aride à hiver frais. La **Figure 38** illustre l'évolution des de l'humidité de surface du sol des différents produits HRSM et SMAP à l'étage subhumide. Sur la période allant depuis 2017 jusqu'à 2021, les précipitations journalières varient entre 1 mm et 55 mm enregistrées dans la station de Joumine appartenant au climat subhumide. A titre d'exemple, le 12/01/2018, une quantité de 41 mm est enregistrée. A cette même date, la valeur d'humidité de surface du sol de SMAP est de l'ordre de 40.66 vol.%. Sur la chronique des données HRSM, les dates des produits d'humidités disponibles sont 11/01/2018 et 17/01/2018 dont les valeurs correspondantes à ce climat sont de l'ordre de 23.27 vol.% et 22.23 vol.%, respectivement. Par conséquent, l'impact de la lame précipitée n'est pas visualisé sur les mesures d'humidité HRSM.



**Figure 38.** Séries temporelles des mesures d'humidité à partir des produits SMAP, SMAP-AM, SMAP-PM et HRSM entre 2017 et 2022 à un climat subhumide.

Afin de mettre en avant la cohérence entre les deux types de données pour le suivi des changements relatifs, nous avons calculé la normalisation des valeurs d'humidité par date d'acquisition Sentinel-1 et SMAP sur la chronique entre 2017 et 2022. La **Figure 39** décrit l'évolution temporelle de l'indice normalisé des humidités de sol en utilisant les deux produits SMAP et HRSM.




**Figure 39.** Séries temporelles de l'indice normalisé des mesures d'humidité à partir des produits SMAP, SMAP-AM, SMAP-PM et HRSM entre 2017 et 2022 en fonction des étages bioclimatiques : (a) humide (b) subhumide (c) aride à hiver doux (d) aride à hiver frais (e) semi-aride à hiver doux et (f) semi-aride à hiver frais.

Pour les climats humide et subhumides, selon la **Figure 39**, les courbes de normalisation des humidités SMAP, SMAP-AM ou SMAP-PM et HRSM se concordent en termes d'évolution. Au niveau du climat humide, on observe un décalage au niveau des valeurs minimales de l'indice en utilisant les données HRMS par rapport aux données SMAP. Ce décalage peut être dû à un manque de précision dans la description de la végétation. La même évolution d'indice caractérise les courbes d'indice en semi-aride et aride à hiver doux. Comme il est montré dans la partie précédente, les données HRSM ont raté parfois les pluies tombées. Par conséquent, quelques pics d'indice d'humidité en utilisant les données SMAP ne sont pas reflétés par l'indice HRSM en aride et semi-aride à hiver frais.

### V.3.2. Evolution mensuelle des humidités de surface du sol des produits HRSM

Dans la **Figure 40**, nous avons exposé les moyennes mensuelles d'humidité en fonction de l'année et des étages bioclimatiques. Les moyennes mensuelles des produits d'humidité HRSM varient entre 10 et 24 vol.%. L'examen des moyennes mensuelles sur les six années traitées (2017-2022) dévoile deux tendances : une diminution des moyennes mensuelles d'humidité de surface du sol depuis le mois de Janvier jusqu'à Juin.




**Figure 40.** Variation des moyennes mensuelles des humidités de surface du sol sur l'étendue des produits HRSM (entre Janvier 2017 jusqu'à Juin 2022) en fonction des étages bioclimatiques.

Les moyennes mensuelles humidité reprennent la tendance d'augmentation après le mois de septembre qui annonce le début de la saison agricole automnale (**Figure 40**). En fonction des étages, les moyennes mensuelles les plus élevées caractérisent l'étage humide avec des moyennes qui varient entre 13 vol.% et 24 vol.%. En contrepartie, l'étage d'aride hiver frais se distingue par les moyennes les plus faibles qui fluctuent entre 10 vol.% et 14 vol.% (**Figure 40**).

### V.3.3. Intercomparaison des moyennes mensuelles HRSM et SMAP

La **Figure 41** expose la variation des moyennes mensuelles extraites des données SMAP en fonction des données HRMS coloré par étage. Un RMSE et un coefficient de corrélation de 6.15 vol.% et 0.69, respectivement, caractérisent la relation entre les deux types de données SMAP et HRMS. Les valeurs RMSE varient entre 5.97 et 6.49 vol.% en utilisant les données à des différents temps d'acquisition SMAP-PM et SMAP-AM, respectivement avec des coefficients de corrélation supérieures à 0.68.



**Figure 41.** Moyennes mensuelles des produits SMAP (a) SMAP-AM (b) et SMAP-PM (c) en fonction des moyennes mensuelles HRSM colorées par étage bioclimatique.


Selon la **Figure 41**, l'étage humide se caractérise par les valeurs SMAP relativement élevées par rapport aux autres étages qui dépassent 30 vol.%. En comparant les deux types de données de cet étage, ces valeurs ne sont pas observables avec les données HRSM et se limitent à des valeurs inférieures à 29 vol.%. Une différence entre les moyennes mensuelles des deux produits de l'étage aride hiver doux est observable aussi. Pour comprendre la source de ces différences, nous avons examiné les séries temporelles des moyennes mensuelles des humidités en fonction des saisons dans la partie suivante.

Nous avons séparé les moyennes mensuelles et l'indice de normalisation selon deux saisons : une saison où les événements pluvieux sont plus probables qui dure neuf mois (du Septembre au mois de Mai) et une saison sèche qui dure trois mois d'été (Juin, Juillet et Août). Les **Figures 42 et 43** illustrent la comparaison entre les moyennes mensuelles et les valeurs d'indice normalisé mensuel en utilisant les données HRSM et les données SMAP, SMAP-AM et SMAP-PM durant la saison pluvieuse. D'une manière générale, selon la **Figure 42**, les graphiques révèlent une bonne concordance entre les évolutions temporelles des humidités moyennes mensuelles calculées à partir des données HRSM et SMAP.

Durant l'année 2022, les moyennes mensuelles d'humidité sont les plus basses par rapport aux autres années de la série temporelle. Ce comportement a caractérisé surtout par les moyennes mensuelles des produits SMAP surtout aux étages aride et semi-aride à hiver doux (**Figure 42, c et e**). Il est aussi lié aux conditions climatiques de cette année de 2022 qui est marquée par une pénurie des précipitations et une sécheresse extrême. Elle est la quatrième année de sécheresse successive en Tunisie.

L'intercomparaison entre les deux produits est caractérisée par des valeurs RMSE qui varient entre 1.85 vol.% et 11.66 vol.%. La comparaison des données HRSM, en fonction de la séparation entre les données SMAP acquises le matin (AM) ou le soir (PM), présente des valeurs RMSE fluctuant entre 2,4 et 12,27 vol.% pour les premières, et entre 1,54 % et 11,1 vol.% pour les secondes.

Les plus faibles valeurs RMSE qui ne dépassent pas 2.41 vol.%, marquent les humidités de l'étage aride (**Figure 42, d**). Ceci peut être due à la faible gamme de variation des humidités de surface à cet étage. Les étages subhumide et semi-arides témoignent d'un bon accord en évolution et en valeurs entre les moyennes mensuelles des deux produits (**Figure 42, b, f et e**).



**Figure 42.** Séries temporelles des moyennes mensuelles calculées à partir des données SMAP, SMAP-AM, SMAP-PM et HRSM durant la saison pluvieuse entre 2017 et 2022 en fonction des étages bioclimatiques : (a) humide (b) subhumide (c) aride à hiver doux (d) aride à hiver frais (e) semi-aride à hiver doux et (f) semi-aride à hiver frais.

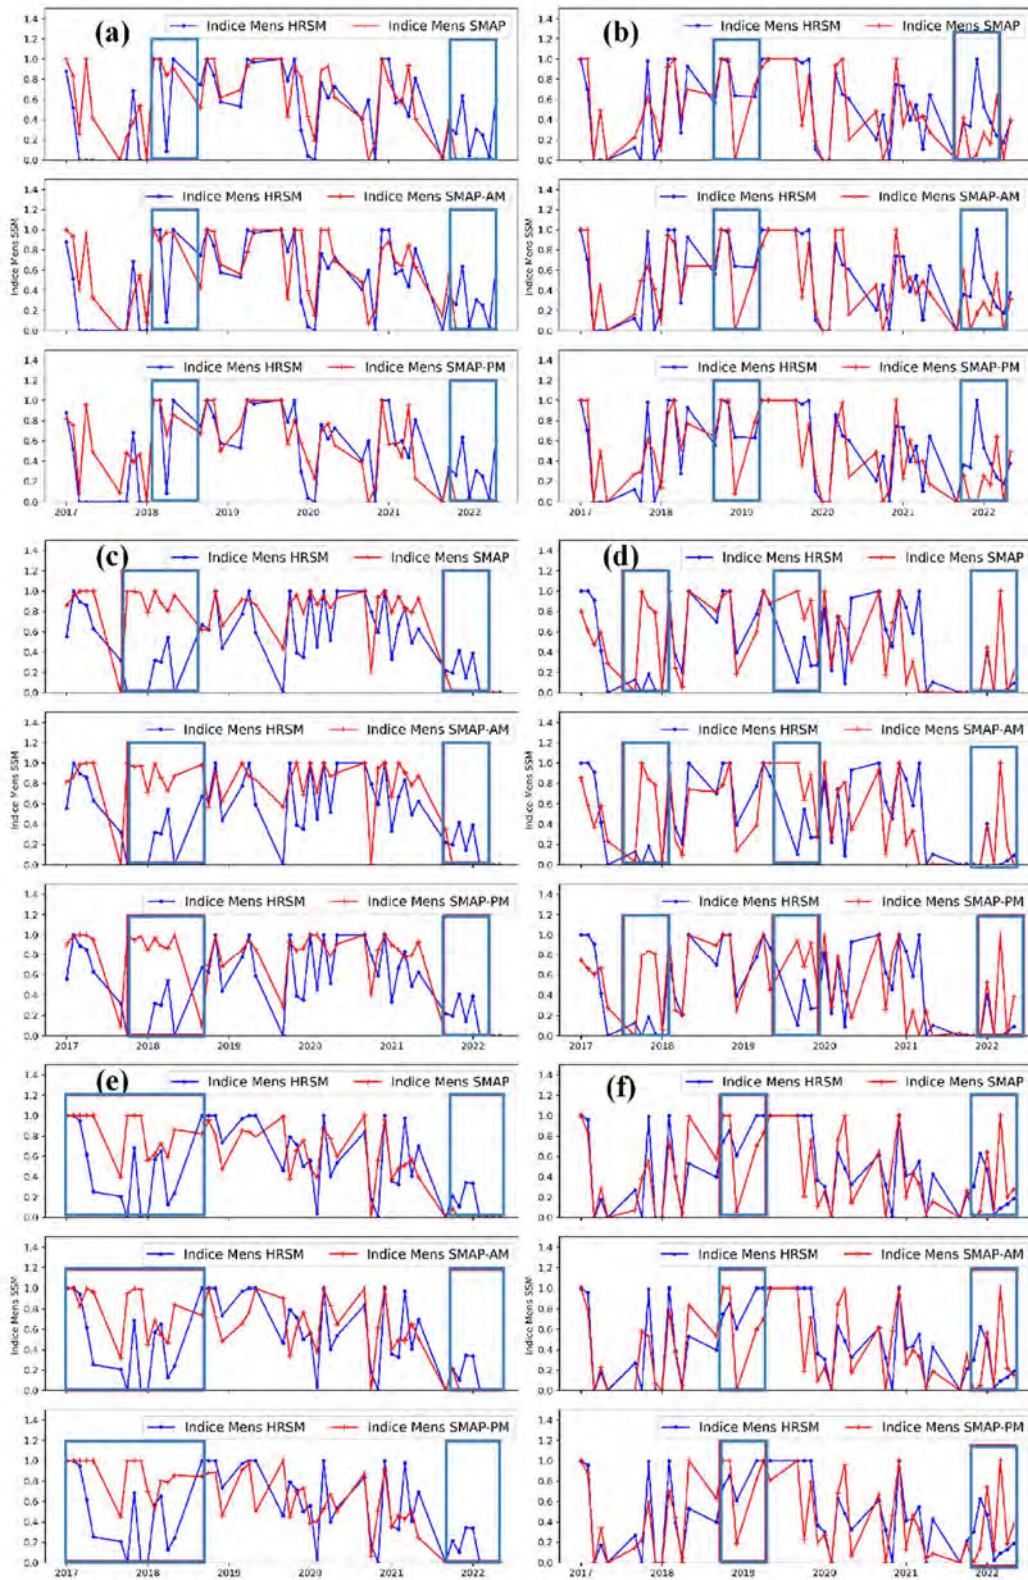
Bien que les évolutions des humidités HRSM et SMAP soient simultanées pour les étages humide et aride à hiver doux, les valeurs RMSE restent élevées et dépassent 8 vol.%. Selon la **Figure 42**, les séries des humidités HRSM et SMAP-AM de l'étage humide se distinguent par des RMSE qui peuvent atteindre 12.27 vol.%.

Cette différence entre les deux séries est due suite à la saturation des produits HRSM à des humidités de l'ordre de 29 vol.%. Ce qui n'est pas le cas pour les produits SMAP qui peuvent atteindre les 40 vol.%. Cette différence entre les moyennes mensuelles a induit des valeurs de RMSE supérieures à 11 vol.%. Malgré les différences entre les moyennes, nous pouvons retrouver les mêmes cycles de variations ce qui illustre la robustesse des produits HRSM pour évaluer la variabilité climatique sur le territoire.

La superposition des courbes de la normalisation des moyennes mensuelles calculées à partir des produits SMAP et HRSM durant la saison pluvieuse, est illustrée dans la **Figure 43**. Bien que l'évolution des deux séries temporelles soient en concordance, il existe quelques cas où on a deux comportements antagonistes de l'indice : un pic de l'indice normalisé des produits SMAP face à une valeur minimale de l'indice correspondant à un mois sec et vice versa. Ces cas sont encadrés en rouge dans la **Figure 43**. A titre d'exemple, pour le climat aride à hiver frais nous avons un pic d'indice d'humidité mensuel SMAP pour le mois du Mars 2022. En contrepartie, un minimum d'indice d'humidité mensuel HRSM est indiqué pour le même mois.

Pour les étages humide, aride à hiver doux et semi-aride à hiver doux, l'indice mensuel SMAP depuis octobre 2021 jusqu'à Mai 2022 est nul marquant la période la plus sèche durant toute la série temporelle. Par contre, l'indice des humidités mensuelles HRSM reste relativement élevé par rapport à l'indice SMAP. Cette différence entre les deux produits peut être due à la résolution temporelle des produits utilisés. Dans le cas du HRSM, les produits sont générés chaque six jours. Entre deux produits successifs, il existe probablement des pluies ratées et leurs impacts ne sont pas visibles sur la série temporelle des humidités HRSM. Avec une résolution temporelle entre deux et trois jours, l'effet de ses pluies est détectable et se manifeste par une augmentation des valeurs d'humidité et par la suite la valeur de l'indice normalisé.





**Figure 43.** Séries temporelles des indices mensuels calculés à partir des données SMAP, SMAP-AM, SMAP-PM et HRSM durant la saison pluvieuse entre 2017 et 2022 en fonction des étages bioclimatiques : (a) humide (b) subhumide (c) aride à hiver doux (d) aride à hiver frais (e) semi-aride à hiver doux et (f) semi-aride à hiver frais. Les cadres en bleus localisent les zones de différence entre les indices des deux produits d'humidité.

Le **Tableau 7** représente les valeurs RMSE caractérisant les inter-comparaisons entre les produits SMAP et HRSM en fonction des étages bioclimatiques selon la saison sèche ou pluvieuse. Globalement, la saison sèche se caractérise par des RMSE relativement faibles par rapport à la saison pluvieuse suite à la faible probabilité des précipitations durant la saison sèche.

**Tableau 7.** Les valeurs RMSE de l'humidité volumétrique caractérisant la relation des moyennes mensuelles calculées à partir des données SMAP, SMAP-AM et SMAP-PM en fonction des moyennes mensuelles des humidités de surface HRSM selon l'étage bioclimatique et selon la saison pluvieuse (P) et la saison sèche (S).

	Humide		Subhumide		Aride hiver doux		Aride hiver frais		Semi-aride hiver doux		Semi-aride hiver frais	
	P	S	P	S	P	S	P	S	P	S	P	S
<b>RMSE (vol.%)</b>	P	S	P	S	P	S	P	S	P	S	P	S
<b>SMAP/ HRSM</b>	11.66	7.31	3.47	3.4	8.4	8.94	1.85	1.08	4.33	3.13	2.38	3.38
<b>SMAP-AM/ HRSM</b>	12.27	8.06	3.88	2.97	8.91	9.16	2.41	1.07	4.56	3.11	2.46	3.1
<b>SMAP-PM/ HRSM</b>	11.1	6.92	3.36	3.92	8	8.84	1.54	1.11	4.55	3.59	2.6	3.7

A l'exception de l'étage semi-aride à hiver frais, la différence entre les deux séries temporelles de HRSM et SMAP durant la saison sèche est plus prononcée que la saison pluvieuse. Les valeurs RMSE, de l'ordre de 9 vol.%, caractérisent l'étage aride à hiver doux et l'étage humide durant la période sèche. Notamment, les étages (aride à hiver frais, semi-aride à hiver doux, semi-aride à hiver frais et subhumide) sont caractérisés par des valeurs RMSE inférieures à 4 vol.%. La variabilité entre les étages et les saisons peut être due à la différence de résolution temporelle entre les données HRSM et SMAP.

L'impact des pluies sont plus observables avec les données SMAP à une résolution temporelle entre deux et trois jours par rapport aux produits HRSM disponibles chaque six jours. De plus, les activités anthropiques telles que l'irrigation des parcelles agricoles influencent les séries temporelles d'humidité de surface du sol. Par conséquent, les hétérogénéités entre les étages bioclimatiques sont de plus en plus prononcées. Nous pouvons distinguer entre les effets des précipitations et des irrigations en comparant les RMSE des deux saisons sèches et pluvieuses. A un étage bioclimatique humide, les cultures sont souvent conduites en pluviale et compte généralement sur les pluies.

A des précipitations minimales durant la saison sèche, les différences entre les moyennes mensuelles d'humidité diminuent. Inversement, pour l'étage aride à hiver frais, la gamme de la variation des humidités est limitée surtout que la Tunisie depuis 2019, vit une période exceptionnelle de quatre années de sécheresse successives.

#### V.4. Conclusions et perspectives

Le travail enchaîné jusqu'à ce stade, s'est focalisé sur l'analyse de la variabilité spatiotemporelle de l'humidité de surface du sol HRSM sur le territoire tunisien. Les données HRSM de 1 Km, disponibles chaque six jours, sont comparées avec les données d'humidité SMAP de 36 Km dont la résolution temporelle est entre deux et trois jours. Cette comparaison a visé la variation de la variation des humidités HRSM durant la période depuis Janvier 2017 jusqu'à Juin 2022 en fonction des étages climatiques et des précipitations journalières dans plusieurs stations météorologiques.

En fonction des étages bioclimatiques numérisés de la carte d'Emberger, nous avons calculé la moyenne des humidités par date d'acquisition S-1 et des produits composites SMAP et les moyennes mensuelles tout au long de la série (depuis Janvier 2017 jusqu'à Juin 2022). L'analyse des indices normalisées est abordé dans la partie des résultats pour ramener les humidités mensuelles au même intervalle de variation entre 0 et 1. Selon les analyses, nous avons observé que les séries temporelles des produits HRSM à 1 Km récupèrent la même variation saisonnière des séries SMAP à 36 Km. Ces résultats introduisent la pertinence des produits HRSM pour étudier la variabilité climatique en Tunisie à des différents contextes climatiques.

## Conclusions et perspectives

---

# Conclusions et perspectives

---

Le monde actuel est menacé par le réchauffement climatique qui provoque impérativement une augmentation de la demande évaporative, et de la transpiration de la végétation face à une diminution des précipitations. Ceci découle un déficit hydrique de plus en plus prononcé spécifiquement dans le bassin méditerranéen. Cette situation a soulevé un besoin primordial d'une gestion optimisée des ressources en eau. Il s'agit d'une gestion basée sur la quantification et la cartographie précise des ressources hydriques disponibles en fonction de la variabilité spatiotemporelle des états de surface. La caractérisation de l'état hydrique constitue l'une des variables prenantes dans la quantification des ressources disponibles. Il s'agit d'une variable clé dans les processus hydrologiques tels que le ruissellement, l'infiltration et l'évapotranspiration ainsi que le domaine agronomique.

Dans le but de suivre l'hétérogénéité spatiale et temporelle de l'humidité du sol, plusieurs approches basées sur les produits de la télédétection ont été développées. Des efforts considérables ont été investis pour estimer l'humidité à partir des images radar. Grâce à sa sensibilité aux états de surface, l'imagerie radar à synthèse d'ouverture a prouvé son potentiel pour estimer l'humidité en se basant sur les interactions entre la surface et les ondes électromagnétiques émises par le capteur.

Les travaux de la présente thèse s'intègrent dans ce cadre scientifique. Ils visent l'évaluation du potentiel des données radar en bande L acquises par ALOS-2 et en bande C acquises par Sentinel-1 pour estimer l'humidité du sol dans une région semi-aride de la plaine de Kairouan au centre de la Tunisie. Témoignant un rabattement de la nappe de l'ordre de 30 m depuis 1986 jusqu'à 2010, la plaine de Kairouan est surexploitée par les agriculteurs pour répondre à leurs besoins d'irriguer leurs exploitations. Ce forçage anthropique s'additionne aux facteurs naturels pour désigner la plaine de Kairouan comme étant un observatoire de la crise d'eau. Cette région réclame un besoin à des approches robustes pour l'aide à la décision et la protection des ressources hydriques en surexploitation et en voix permanente de dégradation qualitative et quantitative. Dans une première partie de la thèse, nous avons évalué le potentiel des données radar en bandes L et C pour estimer l'humidité du sol dans des parcelles de culture homogène (céréales) et des cultures en lignes (piments).

Dans le cas des céréales, nous avons simulé le signal radar en bandes C et L en utilisant deux options du modèle de rétrodiffusion du couvert végétal WCM : en négligeant ou en considérant le terme de diffusion lié aux interactions sol-végétation. Le WCM était couplé aux deux modèles de simulation du signal du sol nu IEM-B pour les données en co-polarisation (C-VV et L-HH) ou bien les équations empiriques. L'inversion des deux options du WCM ont révélé la pertinence du WCM couplé à IEM-B pour estimer l'humidité du sol avec des RMSE inférieures 5 vol.% en comparant les humidités estimées et les humidités mesurées sur les parcelles de référence. L'intégration du terme d'interaction sol-végétation a amélioré l'estimation des humidités pour le cas les données en bande C en polarisation parallèle (C-VV) et surtout en bande L en polarisation croisée (L-HV), avec des RMSE passant de 13.68 vol.% à 6.81 vol.%. Cette amélioration était limitée en utilisant les données en bande C en polarisation VH.

Les cultures en rangs du piment sont irriguées goutte-à-goutte et séparées par le sol nu. Cette irrigation locale a engendré une répartition hétérogène de l'humidité entre les lignes de la végétation et la partie du sol nu. Dans ce cas, nous avons proposé une version modifiée du WCM pour modéliser le comportement du signal sur les parcelles des piments en utilisant les mesures radar bi-fréquence (L-HH et C-VV). Pour investiguer la performance du modèle proposé, des simulations du WCM modifié couplé au IEM-B ont été faites à différentes conditions d'humidité et des variables biophysiques (la fraction du couvert végétale et la hauteur). Ultérieurement, les analyses de la sensibilité des coefficients de rétrodiffusion simulés aux humidités ont souligné la sensibilité des données L-HH jusqu'à une hauteur de 0.5 m et une fraction de couvert égale à 0.4. Ces seuils des variables sont plus limités en utilisant les données C-VV.

Dans la partie précédente, afin de décrire la végétation dans le WCM, nous avons utilisé soit les mesures in-situ de la hauteur des piments soit les valeurs NDVI calculées à partir des données satellites optiques qui sont fortement impactées par les nuages. Ces données sont fortement perturbées dans les zones tropicales et tempérées. C'est dans ce sens que nous nous sommes intéressés, dans la deuxième partie, à utiliser les données SAR en bande C pour décrire la dynamique de la végétation. L'indice normalisé du rapport de polarisation (IN) et la cohérence interférométrique en polarisation VV ont été exploités pour estimer la dynamique du couvert végétal et ainsi proposer une relation avec l'indice optique NDVI à chaque période du cycle du blé : la période de croissance du blé, la période de maturation et la période de sénescence. Pour établir les modèles qui relient les indices radar au NDVI, nous avons utilisé

des équations d'ajustement et les algorithmes d'apprentissage supervisé de régression tels que Random Forest (RF) et Support Vector Machine (SVM). Les modèles de restitution de l'indice optique à partir des mesures radar sont validés et testés sur des parcelles de blé dans la plaine de Kairouan avec des RMSE relativement faibles durant la période de croissance de la végétation. Sur des parcelles test de la plaine de Kairouan, le cycle entier du NDVI est reconstruit avec des RMSE variant entre 0.12 et 0.19. Lors de la période de la senescence, face à un couvert séché et ainsi un NDVI très faible proche des valeurs du sol nu, nous observons un indice radar non négligeable lié à l'effet volume provenant de la biomasse sèche. Cet effet rend la corrélation la plus faible sur cette dernière période du cycle de végétation.

Afin de tester la pertinence des descripteurs de la végétation à partir des données radar, nous avons testé l'indice IN et le rapport de polarisation pour estimer l'humidité du sol sans passer par les données optiques. En inversant le WCM couplé avec IEM-B, les humidités sont estimées avec des RMSE inférieures à 7.5 vol.%. Ces résultats rapportent le potentiel des mesures radar en bande C pour décrire la végétation et introduire l'effet du volume de la végétation non inclus dans les données optiques.

Le potentiel des mesures en bande C par les satellites Sentinel-1 en synergie avec les données Sentinel-2 a été exploré pour générer des produits opérationnels d'humidité de surface du sol (HRSM) par l'équipe INRAE-TETIS en utilisant l'algorithme S2MP. Les séries temporelles des produits HRSM allant du Janvier 2017 au Juin 2022 ont été analysées dans la dernière partie de la thèse. Dans une première étape, nous avons évalué et comparé les données HRSM avec les données composites L3 SMAP à une résolution spatiale de 36 Km en fonction des différents étages bioclimatiques en Tunisie. Dans cette partie, nous avons constaté que les produits HRSM sont capables de reproduire la même saisonnalité et évolution que les produits SMAP à résolution spatiale grossière. Les valeurs élevées des humidités HRSM ont été validées par les précipitations des différentes stations in situ.

En se basant sur les moyennes mensuelles des humidités de la surface du sol, les relations des humidités SMAP en fonction des humidités HRSM se caractérisent par un coefficient de corrélation de 0.69 et un RMSE de 6.15 vol.%. L'étage bioclimatique humide se caractérise par une faible corrélation entre les moyennes mensuelles HRSM et SMAP. Ceci peut être dû suite à la saturation des données HRSM à une valeur de 29 vol.%. Hormis cet étage, l'évolution des humidités de surface du sol HRSM sont en concordance à l'évolution des humidités SMAP.

Les moyennes mensuelles ont été analysées en fonction de deux périodes : une période pluvieuse englobant les mois du Septembre jusqu'au mois du Mai et une période sèche comprenant les trois mois Juin, Juillet et Août. L'illustration des moyennes mensuelles HRSM et SMAP souligne une concordance relative entre les deux évolutions des séries temporelles d'humidité. L'investigation et la comparaison des moyennes mensuelles HRSM durant les années ont révélé une diminution des valeurs d'humidité depuis la fin de 2021 et au premier trimestre de 2022 surtout au niveau de l'étage aride à hiver doux. Cette décroissance se concorde à la période de sécheresse extrême actuelle en Tunisie.

Les analyses des séries de l'indice normalisé des moyennes mensuelles durant les deux saisons pluvieuse et sèche, rapportent la capacité des données HRSM à reproduire les mêmes évolutions que les données SMAP. Les indices normalisés les plus faibles caractérisent les mois les plus secs sur la série temporelle depuis Septembre de l'année 2021 surtout au niveau de l'étage aride à hiver frais et le semi-aride hiver doux. Depuis le mois du Février 2022, la sécheresse est plus prononcée surtout au niveau des étages aride et ses deux variantes et l'étage semi-aride à hiver doux. A partir de ces analyses, nous pouvons constater que les données HRSM peuvent contribuer à l'identification des périodes de sécheresse.

Les principales perspectives qui font suite aux travaux menés dans la présente thèse sont :

- L'analyse des mesures radar ALOS-2 a mis en relief le potentiel des données en bande L pour estimer les humidités de surface du sol lorsque la végétation est dense par rapport aux mesures Sentinel-1 en bande C. L'approche développée d'estimation d'humidité mérite d'être testée avec d'autres types d'occupation du sol comme l'arboriculture qui constituent l'une des occupations majeures dans la plaine de Kairouan. En outre, des tests pourraient être conduites dans d'autres zones plus larges dont le potentiel agricole est important sous des différentes conditions climatiques plus sèches ou plus humides.
- Ultérieurement, la spatialisation des estimations d'humidité du sol à haute résolution temporelle et spatiale à partir des données en bande L ou bien en se basant sur la synergie des données en bandes C et L serait envisageable. Dans ce contexte, nous pourrions utiliser d'autres données en bande L telles que les images acquises par les deux satellites SAOCOM-1A et SAOCOM-1B, lancés le 07 octobre 2018 et 30/08/2020, respectivement, offrant une image chaque 8 jours par constellation. Dans les prochaines années, d'autres missions vont être lancées telles que ALOS-4, NISAR, ROSE-L et



Tandem-L qui pourraient renforcer les acquisitions en bande L et permettre d'aller vers des produits d'humidité opérationnels, basés sur la synergie des données en bandes L et C.

- En utilisant les données en bande C, plusieurs travaux ont été développés pour estimer les doses d'irrigation et la cartographie des zones irriguées. Avec la future disponibilité des données en bande L, nous pourrions tester la pertinence des approches pour estimer les quantités d'irrigation sur plusieurs contextes climatiques. Ultérieurement, nous pourrions utiliser la synergie des données SAR en bi-fréquence en bandes C et L pour spatialiser les zones irriguées à une échelle régionale.
- Les analyses des produits d'humidité de surface du sol ont révélé la pertinence des produits HRSM pour identifier les périodes de sécheresse en Tunisie en fonction des étages bioclimatiques et de l'irrigation. Ces produits à une résolution spatiale plus fine pourront être analysés pour détecter les événements extrêmes dans d'autres sites dont le contexte climatique et le forçage anthropique sont fortement mélangés. En perspective, une analyse des évolutions des cartes des étages bioclimatiques pourrait être affinée avec ces données haute résolution spatiale. Ces données pourraient ainsi rejoindre les produits basse résolution spatiale comme les produits ASCAT, SMAP et SMOS comme variables climatiques utiles pour le suivi des changements climatiques.
- Dans le but d'améliorer les estimations des différents termes du bilan hydrologique, nous pouvons tester l'apport de la synergie radar-thermique. Grâce à la mission Thermal Infrared Imaging (TRISHNA), des données thermiques à haute résolution seront disponibles chaque 8 jours. Ces mesures peuvent affiner les quantifications des différents processus hydrologiques tel que l'évapotranspiration.

# Références

---

- Ait Hssaine, B., Merlin, O., Ezzahar, J., Ojha, N., Er-Raki, S., & Khabba, S. (2020). An evapotranspiration model self-calibrated from remotely sensed surface soil moisture, land surface temperature and vegetation cover fraction: Application to disaggregated SMOS and MODIS data. *Hydrology and Earth System Sciences*, 24(4), 1781–1803. <https://doi.org/10.5194/hess-24-1781-2020>
- Akbar, R., Short Gianotti, D. J., Salvucci, G. D., & Entekhabi, D. (2020). Partitioning of historical precipitation into evaporation and runoff based on hydrologic dynamics identified with recent SMAP satellite Measurements. *Water Resources Research*, 56(12). <https://doi.org/10.1029/2020WR027307>
- Alazard, M. (2013). Etude des relations surface-souterrain du système aquifère d’El Haouareb (Tunisie centrale) sous contraintes climatiques et anthropiques. *thèse de doctorat en systèmes intégrés en Biologie, agronomie, géosciences, hydrosciences et environnement, spécialité eaux continentales et sociétés*, Université Montpellier 2, 376.
- Alazard, M., Leduc, C., Travi, Y., Boulet, G., & Ben Salem, A. (2015). Estimating evaporation in semi-arid areas facing data scarcity: Example of the El Haouareb dam (Merguellil catchment, Central Tunisia). *Journal of Hydrology: Regional Studies*, 3, 265–284. <https://doi.org/10.1016/j.ejrh.2014.11.007>
- Amazirh, A., Merlin, O., Er-Raki, S., Gao, Q., Rivalland, V., Malbeteau, Y., Khabba, S., & Escorihuela, M. J. (2018). Retrieving surface soil moisture at high spatio-temporal resolution from a synergy between Sentinel-1 radar and Landsat thermal data: A study case over bare soil. *Remote Sensing of Environment*, 211, 321–337. <https://doi.org/10.1016/j.rse.2018.04.013>
- Ameur, F., Amichi, H., & Leauthaud, C. (2020). Agroecology in North African irrigated plains? Mapping promising practices and characterizing farmers’ underlying logics. *Regional Environmental Change*. <https://doi.org/10.1007/s10113-020-01719-1/Published>
- Ammar, S. Ben, Zouari, K., Leduc, C., & M’Barek, J. (2006). Caractérisation isotopique de la relation barrage-nappe dans le bassin du Merguellil (Plaine de Kairouan, Tunisie centrale). *Hydrological Sciences Journal*, 51(2), 272–284. <https://doi.org/10.1623/hysj.51.2.272>.
- Amri, R., Zribi, M., Lili Chabaane, Z., Wagner, W., Member, S., & Hasenauer, S. (2012). Analysis of C-band scatterometer moisture estimations derived over a semiarid Region. *IEEE transactions on geoscience and remote sensing*, 50(7), 2630–2638.
- Armand, R. (2009). Étude des états de surface du sol et de leur dynamique pour différentes pratiques de travail du sol. Mise au point d’un indicateur de ruissellement. *Thèse de doctorat en géographie*. Université de Strasbourg, 210. <https://theses.hal.science/tel-00461222>
- Armand, R., Bockstaller, C., Auzet, A. V., & Van Dijk, P. (2009). Runoff generation related to intra-field soil surface characteristics variability. Application to conservation tillage context. *Soil and Tillage Research*, 102(1), 27–37. <https://doi.org/10.1016/j.still.2008.07.009>
- Araus, J. L. (2004). The problems of sustainable water use in the Mediterranean and research requirements for agriculture. *Annals of Applied Biology*, 144(3), 259–272. <https://doi.org/10.1111/j.1744-7348.2004.tb00342.x>
- Attema, E. P. W., & Ulaby, F. T. (1978). Vegetation modeled as a water cloud. *Radio Science*, 13(2), 357–364. <https://doi.org/10.1029/RS013i002p00357>
- Aubert, M., Baghdadi, N. N., Zribi, M., Ose, K., El Hajj, M., Vaudour, E., & Gonzalez-Sosa, E. (2013). Toward an operational bare soil moisture mapping using Terrasar-x data acquired over agricultural areas. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 6(2), 900–916. <https://doi.org/10.1109/JSTARS.2012.2220124>

- Austin, R. B., & Jones, H. G. (1975). *The physiology of wheat. Part III* (No. REP-10388. CIMMYT.).
- Auzet, A. V., Boiffin, J., & Ludwig, B. (1995). Concentrated flow erosion in cultivated catchments: Influence of soil surface state. *Earth Surface Processes and Landforms*, 20(8), 759–767. <https://doi.org/10.1002/esp.3290200807>
- Babaeian, E., Sadeghi, M., Jones, S. B., Montzka, C., Vereecken, H., & Tuller, M. (2019). Ground, Proximal, and Satellite Remote Sensing of Soil Moisture. *Reviews of Geophysics*, 57(2), 530–616. <https://doi.org/10.1029/2018RG000618>
- Baghdadi, N., El Hajj, M., Zribi, M., & Bousbih, S. (2017). Calibration of the Water Cloud Model at C-Band for Winter Crop Fields and Grasslands. *Remote sensing*, 1–13. <https://doi.org/10.3390/rs9090969>
- Baghdadi, N., Gherboudj, I., Zribi, M., Sahebi, M., King, C., & Bonn, F. (2004). Semi-empirical calibration of the IEM backscattering model using radar images and moisture and roughness field measurements. *International Journal of Remote Sensing*, 25(18), 3593–3623. <https://doi.org/10.1080/01431160310001654392>
- Baghdadi, N., Saba, E., Aubert, M., Zribi, M., & Baup, F. (2011). Evaluation of radar backscattering models IEM, Oh, and Dubois for SAR data in X-band over bare soils. *IEEE Geoscience and Remote Sensing Letters*. <https://doi.org/10.1109/LGRS.2011.2158982>
- Baghdadi, N., & Zribi, M. (2006). Evaluation of radar backscatter models IEM, OH and Dubois using experimental observations. *International Journal of Remote Sensing*, 27(18), 3831–3852. <https://doi.org/10.1080/01431160600658123>
- Baghdadi, N., Zribi, M., Paloscia, S., Verhoest, N. E. C., Lievens, H., Baup, F., & Mattia, F. (2015). Semi-empirical calibration of the integral equation model for co-polarized L-band backscattering. *Remote Sensing*, 7(10), 13626–13640. <https://doi.org/10.3390/rs71013626>
- Bartalis, Z., Wagner, W., Naeimi, V., Hasenauer, S., Scipal, K., Bonekamp, H., Figa, J., & Anderson, C. (2007). Initial soil moisture retrievals from the METOP-A Advanced Scatterometer (ASCAT). *Geophysical Research Letters*, 34(20). <https://doi.org/10.1029/2007GL031088>
- Bazzi, H., Baghdadi, N., Charron, F., & Zribi, M. (2022). Comparative Analysis of the Sensitivity of SAR Data in C and L Bands for the Detection of Irrigation Events. *Remote Sensing*, 14(10). <https://doi.org/10.3390/rs14102312>
- Bell, J. P., Dean, T. J., & Hodnett, M. G. (1987). Soil moisture measurement by an improved capacitance technique, part II. field techniques, evaluation and calibration. *Journal of Hydrology*, 79–90.
- Bentamy, A., & Fillon, D. C. (2012). Gridded surface wind fields from Metop/ASCAT measurements. *International Journal of Remote Sensing*, 33(6), 1729–1754. <https://doi.org/10.1080/01431161.2011.600348>
- Berg, A., Sheffield, J., & Milly, P. C. D. (2017). Divergent surface and total soil moisture projections under global warming. *Geophysical Research Letters*, 44(1), 236–244. <https://doi.org/10.1002/2016GL071921>
- Bhattacharyya, R., Prakash, V., Kundu, S., & Gupta, H. S. (2006). Effect of tillage and crop rotations on pore size distribution and soil hydraulic conductivity in sandy clay loam soil of the Indian Himalayas. *Soil and Tillage Research*, 86(2), 129–140. <https://doi.org/10.1016/j.still.2005.02.018>
- Bhogapurapu, N., Dey, S., Homayouni, S., Bhattacharya, A., & Rao, Y. S. (2022). Field-scale soil moisture estimation using sentinel-1 GRD SAR data. *Advances in Space Research*, 70(12), 3845–3858. <https://doi.org/10.1016/j.asr.2022.03.019>

- Blaes, X., & Defourny, P. (2003). Retrieving crop parameters based on tandem ERS 1/2 interferometric coherence images. *Remote Sensing of Environment*, 88(4), 374–385. <https://doi.org/10.1016/j.rse.2003.08.008>
- Bousbih, S., Zribi, M., Hajj, M. El, Baghdadi, N., Lili-Chabaane, Z., Gao, Q., & Fanise, P. (2018). Soil moisture and irrigation mapping in a semi-arid region, based on the synergetic use of Sentinel-1. *Remote Sensing*, 22. <https://doi.org/10.3390/rs10121953>
- Bousbih, S., Zribi, M., Pelletier, C., Gorrab, A., Lili-Chabaane, Z., Baghdadi, N., Aissa, N. Ben, & Mougenot, B. (2019). Soil texture estimation using radar and optical data from Sentinel-1 and Sentinel-2. *Remote Sensing*, 11(13). <https://doi.org/10.3390/rs11131520>
- Bousbih, S., Zribi, M., Lili-Chabaane, Z., Baghdadi, N., El Hajj, M., Gao, Q., & Mougenot, B. (2017). Potential of sentinel-1 radar data for the assessment of soil and cereal cover parameters. *Sensors (Switzerland)*, 17(11). <https://doi.org/10.3390/s17112617>
- Bouzaïane, S. & Lafforgue, A., (1986). Monographie hydrologique des oueds Zeroud et Merguellil [Hydrological monograph of wadis Zeroud and Merguellil]. Direction Générale des Ressources en Eau, Orsom, Tunis.
- Bretreger, D., Hancock, G., Yeo, I.-Y., Martinez, D. C., Wells, D. T., Cox, T., Kunkel, V., & Gibson, A. (2022). Comparing the reliability of two soil moisture probes for high clay content NSW soils. *Water E-Journal*, 8(3), 1–17. <https://doi.org/10.21139/wej.2022.035>
- Brocca, L., Ciabatta, L., Massari, C., Camici, S., & Tarpanelli, A. (2017). Soil moisture for hydrological applications: Open questions and new opportunities. *Water (Switzerland)*, 9(2). <https://doi.org/10.3390/w9020140>
- Brocca, L., Ciabatta, L., Massari, C., Moramarco, T., Hahn, S., Hasenauer, S., Kidd, R., Dorigo, W., Wagner, W., & Levizzani, V. (2014). Soil as a natural rain gauge: Estimating global rainfall from satellite soil moisture data. *Journal of Geophysical Research*, 119(9), 5128–5141. <https://doi.org/10.1002/2014JD021489>
- Brocca, L., Tarpanelli, A., Filippucci, P., Dorigo, W., Zaussinger, F., Gruber, A., & Fernández-Prieto, D. (2018). How much water is used for irrigation? A new approach exploiting coarse resolution satellite soil moisture products. *International Journal of Applied Earth Observation and Geoinformation*, 73, 752–766. <https://doi.org/10.1016/j.jag.2018.08.023>
- Caloz, R., & Collet, C. (2001). Précis de télédétection-Volume 3 : Traitements numériques d'images de télédétection (Vol. 3). PUQ.
- Carlson, T. (2007). An overview of the “Triangle Method” for estimating surface evapotranspiration and soil moisture from satellite imagery. *Sensors*, 7, 1612–1629.
- Casenave, A., & Valentin, C. (1989). Les états de surface de la zone sahélienne : influence sur l’infiltration.
- Chahbi Bellakanji, A. (2015). Télédétection et modélisation de la dynamique de végétation pour une estimation précoce et une analyse spatiale des rendements des céréales dans un contexte semi-aride en Tunisie centrale. *Thèse de doctorat en sciences agronomiques Spécialité : Génie Rural, Eaux et Forêts*, 209.
- Chan, S. K., Bindlish, R., O’Neill, P. E., Njoku, E., Jackson, T., Colliander, A., Chen, F., Burgin, M., Dunbar, S., Piepmeier, J., Yueh, S., Entekhabi, D., Cosh, M. H., Caldwell, T., Walker, J., Wu, X., Berg, A., Rowlandson, T., Pacheco, A., ... Kerr, Y. (2016). Assessment of the SMAP Passive Soil Moisture Product. *IEEE Transactions on Geoscience and Remote Sensing*, 54(8), 4994–5007. <https://doi.org/10.1109/TGRS.2016.2561938>

- Chan, S. K., Bindlish, R., O'Neill, P., Jackson, T., Njoku, E., Dunbar, S., Chaubell, J., Piepmeier, J., Yueh, S., Entekhabi, D., Colliander, A., Chen, F., Cosh, M. H., Caldwell, T., Walker, J., Berg, A., McNairn, H., Thibeault, M., Martínez-Fernández, J., ... Kerr, Y. (2018). Development and assessment of the SMAP enhanced passive soil moisture product. *Remote Sensing of Environment*, 204, 931–941. <https://doi.org/10.1016/j.rse.2017.08.025>
- Chanzy, A. (1993). Basic soil surface characteristics derived from active microwave remote sensing. *Remote Sensing Reviews*, 7(3–4), 303–319. <https://doi.org/10.1080/02757259309532183>
- Chauhan, S., Srivastava, H. S., & Patel, P. (2018). Wheat crop biophysical parameters retrieval using hybrid-polarized RISAT-1 SAR data. *Remote Sensing of Environment*, 216, 28–43. <https://doi.org/10.1016/j.rse.2018.06.014>
- Chebbi, A., Zammouri, M., Cunha, M. C., Nazoumou, Y., Besbes, M., & Bargaoui, Z. (2008). Optimization of withdrawals from an aquifer: A case study of Kairouan (Tunisia). *Water International*, 33(1), 100–115. <https://doi.org/10.1080/02508060801927887>
- Childs, E. C., & Bybordi, M. (1969). The vertical movement water in stratified porous material: 1. Infiltration. *Water Resources Research*, 5(2), 446–459. <https://doi.org/10.1029/WR005i002p00446>
- Choker, M., Baghdadi, N., Zribi, M., El Hajj, M., Paloscia, S., Verhoest, N. E. C., Lievens, H., & Mattia, F. (2017). Evaluation of the Oh, Dubois and IEM backscatter models using a large dataset of SAR data and experimental soil measurements. *Water (Switzerland)*, 9(1). <https://doi.org/10.3390/w9010038>
- Chow, V. Te, Maidment, D. R., & Mays, L. W. (1988). *Applied hydrology*. McGraw-Hill.
- Collard, A. L., Riaux, J., Massuel, S., Raïssi, M., & Burte, J. (2015). “Et si on faisait comme ceux de la plaine ?” Aspirations et limites d’une petite agriculture dynamique en Tunisie centrale. *Cahiers Agricultures*, 24(6), 335–341. <https://doi.org/10.1684/agr.2015.0779>
- Colliander, A., Cosh, M. H., Misra, S., Jackson, T. J., Crow, W. T., Chan, S., Bindlish, R., Chae, C., Holifield Collins, C., & Yueh, S. H. (2017). Validation and scaling of soil moisture in a semi-arid environment: SMAP validation experiment 2015 (SMAPVEX15). *Remote Sensing of Environment*, 196, 101–112. <https://doi.org/10.1016/j.rse.2017.04.022>
- Collinet, J., & Valentin, C. (1979). Un schéma des interrelations hydrodynamiques dans les milieux naturels et cultivés : valorisation des données morphologiques.
- Cook, B. I., Mankin, J. S., Marvel, K., Williams, A. P., Smerdon, J. E., & Anchukaitis, K. J. (2020). Twenty-first Century Drought Projections in the CMIP6 Forcing Scenarios The multi-model ensemble shows robust drying in the mean state across many regions. <https://doi.org/10.1029/2020>
- Cudennec, C., Beji, R., Le Goulven, P., & Bachta, M. S. (2003). Analyse des interactions entre ressources en eau et usages agricoles dans le bassin versant de l’oued Merguellig, Tunisie centrale. *Séminaire PCSI*, Montpellier, France, 1–5.
- Dabrowska-Zielinska, K., Inoue, Y., Kowalik, W., & Gruszczynska, M. (2007). Inferring the effect of plant and soil variables on C- and L-band SAR backscatter over agricultural fields, based on model analysis. *Advances in Space Research*, 39(1), 139–148. <https://doi.org/10.1016/j.asr.2006.02.032>
- Dai, A., Zhao, T., & Chen, J. (2018). Climate Change and Drought: a precipitation and evaporation perspective. In *Current Climate Change Report*, Vol. 4, Issue 3, pp. 301–312, Springer. <https://doi.org/10.1007/s40641-018-0101-6>
- Dari, J., Brocca, L., Quintana-Seguí, P., Escorihuela, M. J., Stefan, V., & Morbidelli, R. (2020). Exploiting high-resolution remote sensing soil moisture to estimate irrigation water amounts over a Mediterranean region. *Remote Sensing*, 12(16). <https://doi.org/10.3390/RS12162593>

- Dean, T. J., Bell, J. P., & Baty, A. J. B. (1987). Soil moisture measurement by an improved capacitance technique, part i. sensor design and performance. In *Journal of Hydrology* (Vol. 93).
- Decharme, B., & Douville, H. (2006). Introduction of a sub-grid hydrology in the ISBA land surface model. *Climate Dynamics*, 26(1), 65–78. <https://doi.org/10.1007/s00382-005-0059-7>
- Derwich, L. J., Zouar, K., & Michelot, J. L. (2012). Recharge and paleo recharge of the deep groundwater aquifer system in the Zeroud Basin (Kairouan plain, Central Tunisia). *Quaternary International*, 257, 56–63. <https://doi.org/10.1016/j.quaint.2011.12.003>
- De Jeu, R., & Dorigo, W. (2016). On the importance of satellite observed soil moisture. *International Journal of Applied Earth Observation and Geoinformation*, 45, 107–109. <https://doi.org/10.1016/j.jag.2015.10.007>
- Dobson, M. C., & Ulaby, F. T. (1986). Active Microwave Soil Moisture Research. In *IEEE Transactions on Geoscience and Remote Sensing* (Issue 1).
- Dong, J., Akbar, R., Feldman, A. F., Gianotti, D. S., & Entekhabi, D. (2023). Land Surfaces at the Tipping-Point for Water and Energy Balance Coupling. *Water Resources Research*, 59(2). <https://doi.org/10.1029/2022WR032472>
- Dong, J., Akbar, R., Short Gianotti, D. J., Feldman, A. F., Crow, W. T., & Entekhabi, D. (2022). Can Surface Soil Moisture Information Identify Evapotranspiration Regime Transitions? In *Geophysical Research Letters* (Vol. 49, Issue 7). John Wiley and Sons Inc. <https://doi.org/10.1029/2021GL097697>
- Dorigo, W. A., Wagner, W., Hohensinn, R., Hahn, S., Paulik, C., Xaver, A., Gruber, A., Drusch, M., Mecklenburg, S., Van Oevelen, P., Robock, A., & Jackson, T. (2011). The International Soil Moisture Network: A data hosting facility for global in situ soil moisture measurements. *Hydrology and Earth System Sciences*, 15(5), 1675–1698. <https://doi.org/10.5194/hess-15-1675-2011>
- Dorigo, W., Himmelbauer, I., Aberer, D., Schremmer, L., Petrakovic, I., Zappa, L., Preimesberger, W., Xaver, A., Annor, F., Ardö, J., Baldocchi, D., Bitelli, M., Blöschl, G., Bogena, H., Brocca, L., Calvet, J. C., Camarero, J. J., Capello, G., Choi, M., ... Sabia, R. (2021). The International Soil Moisture Network: Serving Earth system science for over a decade. In *Hydrology and Earth System Sciences* (Vol. 25, Issue 11, pp. 5749–5804). Copernicus GmbH. <https://doi.org/10.5194/hess-25-5749-2021>
- Droogers, P., Immerzeel, W. W., Terink, W., Hoogeveen, J., Bierkens, M. F. P., Van Beek, L. P. H., & Debele, B. (2012). Water resources trends in Middle East and North Africa towards 2050. *Hydrology and Earth System Sciences*, 16(9), 3101–3114. <https://doi.org/10.5194/hess-16-3101-2012>
- Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Isola, C., Laberinti, P., Martimort, P., Meygret, A., Spoto, F., Sy, O., Marchese, F., & Bargellini, P. (2012). Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services. *Remote Sensing of Environment*, 120, 25–36. <https://doi.org/10.1016/j.rse.2011.11.026>.
- Dubois, P., Van Zyl, J., & Engman, T. (1995). Measuring Soil Moisture with Imaging Radars. *IEEE Trans. Geosci. Remote Sens.*, 33, 915–926. <https://doi.org/doi:10.1109/36.406677>
- Edokossi, K., Calabria, A., Jin, S., & Molina, I. (2020). GNSS-reflectometry and remote sensing of soil moisture: A review of measurement techniques, methods, and applications. In *Remote Sensing* (Vol. 12, Issue 4). MDPI AG. <https://doi.org/10.3390/rs12040614>
- El Ghali A (1993). Néotectonique et évolution tectono-sédimentaire associées aux jeux de la faille de Sbiba-Kairouan du Crétacé supérieur à l'actuel (Tunisie centrale). *Thèse de doctorat*, Université de Tunis II, Faculty of Sciences of Tunis, 215.
- El Hajj, M., Baghdadi, N., Zribi, M., & Bazzi, H. (2017). Synergic use of Sentinel-1 and Sentinel-2 images for operational soil moisture mapping at high spatial resolution over agricultural areas. *Remote Sensing*, 9(12), 1–28. <https://doi.org/10.3390/rs9121292>

- 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 Sensing of Environment*, 176, 202–218. <https://doi.org/10.1016/j.rse.2016.01.027>
- El-Rayes, M. A., & Ulaby, F. T. (1987). Microwave Dielectric Spectrum of Vegetation-Part I: Experimental Observations. In *IEEE Transactions on geoscience and remote sensing* (Issue 5).
- Éliard, J. L., de Sousa, F., & Lince, P. (1979). Manuel général d'agriculture.
- Elliott, J., Deryng, D., Müller, C., Frieler, K., Konzmann, M., Gerten, D., Glotter, M., Flörke, M., Wada, Y., Best, N., Eisner, S., Fekete, B. M., Folberth, C., Foster, I., Gosling, S. N., Haddeland, I., Khabarov, N., Ludwig, F., Masaki, Y., ... Wissler, D. (2014). Constraints and potentials of future irrigation water availability on agricultural production under climate change. *Proceedings of the National Academy of Sciences of the United States of America*, 111(9), 3239–3244. <https://doi.org/10.1073/pnas.1222474110>
- Engman, E. T., & Chauhan, N. (1995). Status of Microwave Soil Moisture Measurements with Remote Sensing.
- 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., ... Van Zyl, J. (2010). The soil moisture active passive (SMAP) mission. *Proceedings of the IEEE*, 98(5), 704–716. <https://doi.org/10.1109/JPROC.2010.2043918>
- Entekhabi, D., Rodriguez-Iturbe, I., & Castelli, F. (1996). Mutual interaction of soil moisture state and atmospheric processes. In *Journal of Hydrology ELSEVIER*, (Vol. 184).
- Entekhabi, D., Yueh, S. H., O'Neill, P. E., Kellogg, K. H., Allen, A. M., Bindlish, R., Brown, M., Chan, S. T., Colliander, A., Crow, W. T., Das, N. N., Lannoy, G. D., Dunbar, R. S., Edelstein, W. N., Entin, J. K., Escobar, V. M., Goodman, S. D., Jackson, T. J., Jai, B., ... & West, R. D. (2014). SMAP Handbook Soil Moisture Active Passive Mapping Soil Moisture and Freeze/Thaw from Space.
- Evans, L. T. (1978). the influence of irradiance before and after anthesis on grain yield and its components in microcrops of wheat grown in a constant daylength and temperature regime. In *Field Crops Research* (Vol. 1).
- Ezzahar, J., Ouadi, N., Zribi, M., Elfarkh, J., Aouade, G., Khabba, S., Er-Raki, S., Chehbouni, A., & Jarlan, L. (2020). Evaluation of backscattering models and support vector machine for the retrieval of bare soil moisture from sentinel-1 data. *Remote Sensing*, 12(1), 1–20. <https://doi.org/10.3390/RS12010072>
- Fascetti, F., Pierdicca, N., & Pulvirenti, L. (2017). Empirical fitting of forward backscattering models for multitemporal retrieval of soil moisture from radar data at L-band. *Journal of Applied Remote Sensing*, 11(1), 016002. <https://doi.org/10.1117/1.jrs.11.016002>
- Feldman, A. F., Akbar, R., & Entekhabi, D. (2018). Characterization of higher-order scattering from vegetation with SMAP measurements. *Remote Sensing of Environment*, 219, 324–338. <https://doi.org/10.1016/j.rse.2018.10.022>
- Feldman, A. F., Short Gianotti, D. J., Konings, A. G., McColl, K. A., Akbar, R., Salvucci, G. D., & Entekhabi, D. (2018). Moisture pulse-reserve in the soil-plant continuum observed across biomes. *Nature Plants*, 4(12), 1026–1033. <https://doi.org/10.1038/s41477-018-0304-9>
- Feldman, A. F., Short Gianotti, D. J., Trigo, I. F., Salvucci, G. D., & Entekhabi, D. (2019). Satellite-Based Assessment of Land Surface Energy Partitioning–Soil Moisture Relationships and Effects of Confounding Variables. *Water Resources Research*, 55(12), 10657–10677. <https://doi.org/10.1029/2019WR025874>

- Feldman, A. F., Short Gianotti, D. J., Dong, J., Akbar, R., Crow, W. T., McColl, K. A., Konings, A. G., Nippert, J. B., Tumber-Dávila, S. J., Holbrook, N. M., Rockwell, F. E., Scott, R. L., Reichle, R. H., Chatterjee, A., Joiner, J., Poulter, B., & Entekhabi, D. (2023). Remotely Sensed Soil Moisture Can Capture Dynamics Relevant to Plant Water Uptake. In *Water Resources Research*, Vol. 59, Issue 2. John Wiley and Sons Inc. <https://doi.org/10.1029/2022WR033814>
- Feldman, A. F., Short Gianotti, D. J., Trigo, I. F., Salvucci, G. D., & Entekhabi, D. (2020). Land-Atmosphere Drivers of Landscape-Scale Plant Water Content Loss. *Geophysical Research Letters*, 47(22). <https://doi.org/10.1029/2020GL090331>
- Feldman, A. F., Short Gianotti, D. J., Trigo, I. F., Salvucci, G. D., & Entekhabi, D. (2022). Observed Landscape Responsiveness to Climate Forcing. *Water Resources Research*, 58(1). <https://doi.org/10.1029/2021WR030316>
- Feng, Y., Wang, H., Liu, W., & Sun, F. (2022). Global Soil Moisture-Climate Interactions during the Peak Growing Season. *Journal of Climate*. <https://doi.org/10.1175/JCLI-D-22>
- Feuillette, S., Bousquet, F., & Le Goulven, P. (2003). SINUSE: A multi-agent model to negotiate water demand management on a free access water table. *Environmental Modelling and Software*, 18(5), 413–427. [https://doi.org/10.1016/S1364-8152\(03\)00006-9](https://doi.org/10.1016/S1364-8152(03)00006-9)
- Figa-Saldaña, J., Wilson, J. J. W., Attema, E., Gelsthorpe, R., Drinkwater, M. R., & Stoffelen, A. (2002). The advanced scatterometer (ASCAT) on the meteorological operational (MetOp) platform: A follow on for European wind scatterometers.
- Finco, C., Pontoreau, C., Schamper, C., Massuel, S., Hovhannissian, G., & Rejiba, F. (2018). Time-domain electromagnetic imaging of a clayey confining bed in a brackish environment: A case study in the Kairouan Plain Aquifer (Kelbia saltlake, Tunisia). *Hydrological Processes*, 32(26), 3954–3965. <https://doi.org/10.1002/hyp.13303>
- Frison, P. L., Fruneau, B., Kmiha, S., Soudani, K., Dufrière, E., Le Toan, T., Koleček, T., Villard, L., Mougin, E., & Rudant, J. P. (2018). Potential of Sentinel-1 data for monitoring temperate mixed forest phenology. *Remote Sensing*, Vol. 10, Issue 12. <https://doi.org/10.3390/rs10122049>
- Fung, A. K., Li, Z., & Chen, K. S. (1992). Backscattering from a Randomly Rough Dielectric Surface. *IEEE Transactions on Geoscience and Remote Sensing*, 30(2), 356–369. <https://doi.org/10.1109/36.134085>
- Gadelmawla, E. S., Koura, M. M., Maksoud, T. M. A., Elewa, I. M., & Soliman, H. H. (2002). Roughness parameters.
- Gafrej, R. (2016). Avec le changement climatique, quel avenir de l’agriculture en Tunisie ?
- Gao, Q., Zribi, M., Escorihuela, M. J., & Baghdadi, N. (2017). Synergetic use of sentinel-1 and sentinel-2 data for soil moisture mapping at 100 m resolution. *Sensors (Switzerland)*, 17(9). <https://doi.org/10.3390/s17091966>
- Gao, Z., Xu, X., Wang, J., Yang, H., Huang, W., & Feng, H. (2013). A method of estimating soil moisture based on the linear decomposition of mixture pixels. *Mathematical and Computer Modelling*, 58(3–4), 606–613. <https://doi.org/10.1016/j.mcm.2011.10.054>
- Gaskin, G. J., & Miller, J. D. (1996). Measurement of Soil Water Content Using a Simplified Impedance Measuring Technique. In *J. agric. Engng Res* (Vol. 63).
- Giorgi, F. and Lionello, P. (2008). Climate change projections for the Mediterranean region, *Global Planet. Change*, 63, 90–104.
- Girard, Michel-Claude, and Colette-Marie Girard. (2010) Traitement des données de télédétection, *Environnement et ressources naturelles*. Dunod.



- Gorrab, A. (2014). Développement et validation de méthodologies pour le suivi des états de surface des sols agricoles nus par télédétection radar (bande X). *Thèse de doctorat en sciences agronomiques Spécialité : Génie Rural, Eaux et Forêts*, 231.
- Gorrab, A., Zribi, M., Baghdadi, N., Mougenot, B., Fanise, P., & Lili-Chabaane, Z. (2015). Retrieval of both soil moisture and texture using TerraSAR-X images. *Remote Sensing*, 7(8), 10098–10116. <https://doi.org/10.3390/rs70810098>
- Graham, A. J., & Harris, R. (2003). Extracting biophysical parameters from remotely sensed radar data: a review of the water cloud model. *Progress in Physical Geography*, 27:2017, <https://doi.org/10.1191/0309133303pp378ra>
- Habaieb, H., & Albergel, J. (2000). Vers une gestion optimale des ressources en eau exemple de la Tunisie. *70*, 1–8.
- Hagolle, O., Huc, M., Descardins, C., Auer, S., Richter, R. (2017). MAJA ATBD Algorithm Theoretical Basis Document. <https://doi.org/https://doi.org/10.5281/zenodo.1209633>
- Haldar, D., Verma, A., Kumar, S., & Chauhan, P. (2022). Estimation of mustard and wheat phenology using multi-date Shannon entropy and Radar Vegetation Index from polarimetric Sentinel- 1. *Geocarto International*, 37(20), 5935–5962. <https://doi.org/10.1080/10106049.2021.1926554>
- Hallikainen, M. T., Ulaby, F. T., Dobson, M. C., El-Rayes, M. A., & Wu, L.-K. (1985). Microwave Dielectric Behavior of Wet Soil-Part 1: Empirical Models and Experimental Observations. In *IEEE Transactions on Geoscience and Remote sensing* (Issue 1).
- Hamze, M., Baghdadi, N., el Hajj, M. M., Zribi, M., Bazzi, H., Cheviron, B., & Faour, G. (2021). Integration of L-Band Derived Soil Roughness into a Bare Soil Moisture Retrieval Approach from C-Band SAR Data. *Remote Sensing*, 13(11), 2102. <https://doi.org/10.3390/rs13112102>
- Hayat, F., Ahmed, M. A., Zarebanadkouki, M., Cai, G., & Carminati, A. (2019). Measurements and simulation of leaf xylem water potential and root water uptake in heterogeneous soil water contents. *Advances in Water Resources*, 124, 96–105. <https://doi.org/10.1016/j.advwatres.2018.12.009>
- Heathman, G. C., Starks, P. J., Ahuja, L. R., & Jackson, T. J. (2003). Assimilation of surface soil moisture to estimate profile soil water content. *Journal of Hydrology*, 279(1–4), 1–17. [https://doi.org/10.1016/S0022-1694\(03\)00088-X](https://doi.org/10.1016/S0022-1694(03)00088-X)
- He, B., Xing, M., & Bai, X. (2014). A synergistic methodology for soil moisture estimation in an alpine prairie using radar and optical satellite data. *Remote Sensing*, 6(11), 10966–10985. <https://doi.org/10.3390/rs61110966>
- Hosseini, M., & McNairn, H. (2017). Using multi-polarization C- and L-band synthetic aperture radar to estimate biomass and soil moisture of wheat fields. *International Journal of Applied Earth Observation and Geoinformation*, 58, 50–64. <https://doi.org/10.1016/j.jag.2017.01.006>
- Hssaine, B. A., Chehbouni, A., Er-Raki, S., Khabba, S., Ezzahar, J., Ouaadi, N., Ojha, N., Rivalland, V., & Merlin, O. (2021). On the utility of high-resolution soil moisture data for better constraining thermal-based energy balance over three semi-arid agricultural areas. *Remote Sensing*, 13(4), 1–23. <https://doi.org/10.3390/rs13040727>
- Hssaine, B. A., Merlin, O., Rafi, Z., Ezzahar, J., Jarlan, L., Khabba, S., & Er-Raki, S. (2018). Calibrating an evapotranspiration model using radiometric surface temperature, vegetation cover fraction and near-surface soil moisture data. *Agricultural and Forest Meteorology*, 256–257, 104–115. <https://doi.org/10.1016/j.agrformet.2018.02.033>

- 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., ... Escadafal, R. (2015). Remote Sensing of Water Resources in Semi-Arid Mediterranean Areas: the joint international laboratory TREMA. *International Journal of Remote Sensing*, 36(19–20), 4879–4917. <https://doi.org/10.1080/01431161.2015.1093198>
- Jerbi, H., Massuel, S., Leduc, C., & Tarhouni, J. (2018). Assessing groundwater storage in the Kairouan plain aquifer using a 3D lithology model (Central Tunisia). *Arabian Journal of Geosciences*, 11(10). <https://doi.org/10.1007/s12517-018-3570-y>
- Jester, W., & Klik, A. (2005). Soil surface roughness measurement - Methods, applicability, and surface representation. *Catena*, 64(2–3), 174–192. <https://doi.org/10.1016/j.catena.2005.08.005>
- Jonckheere, I., Fleck, S., Nackaerts, K., Muys, B., Coppin, P., Weiss, M., & Baret, F. (2004). Review of methods for in situ leaf area index determination Part I. Theories, sensors and hemispherical photography. *Agricultural and Forest Meteorology*, 121(1–2), 19–35. <https://doi.org/10.1016/j.agrformet.2003.08.027>
- IPCC. (2022). Climate Change 2022: Impacts, Adaptation, and Vulnerability. Contribution of Working Group II to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [H.-O. Pörtner, D.C. Roberts, M. Tignor, E.S. Poloczanska, K. Mintenbeck, A. Alegría, M. Craig, S. Langsdorf, S. Löschke, V. Möller, A. Okem, B. Rama (eds.)]. Cambridge University Press. Cambridge University Press (Issue August). <https://doi.org/10.5281/zenodo.4768833>
- Kankaku, Y., Suzuki, S., & Osawa, Y. (2013). ALOS-2 mission and development status. *IEEE Transactions on Geoscience and Remote Sensing*, 2396–2399.
- Karam, M. A., Fung, A. K., & Antar, Y. M. M. (1988). Electromagnetic Wave Scattering from Some Vegetation Samples. *IEEE Transactions on Geoscience and Remote Sensing*, 26(6), 799–808. <https://doi.org/10.1109/36.7711>
- Karam, M. A., Amar, F., Fung, A. K., Mougin, E., Lopes, A., Le Vine, D. M., & Beaudoin, A. (1995). A microwave polarimetric scattering model for forest canopies based on vector radiative transfer theory. *Remote Sensing of Environment*, 53(1), 16–30. [https://doi.org/10.1016/0034-4257\(95\)00048-6](https://doi.org/10.1016/0034-4257(95)00048-6)
- Kellogg, K., Rosen, P., Barela, P., Sagi, R., Kumar, R., Hoffman, P., Edelstein, W., Shen, Y., Sreekantha, C. V., Bhan, R., Standley, S., Dunn, C., Guerrero, A. M., Harinath, N., Sarma, C. V. H. S., Shaffer, S., Baker, C., & Xaypraseuth, P. (2020). NASA-ISRO Synthetic Aperture Radar (NISAR) Mission. *IEEE Aerospace Conference*.
- Kerr, Y. H., Al-Yaari, A., Rodriguez-Fernandez, N., Parrens, M., Molero, B., Leroux, D., Bircher, S., Mahmoodi, A., Mialon, A., Richaume, P., Delwart, S., Al Bitar, A., Pellarin, T., Bindlish, R., Jackson, T. J., Rüdiger, C., Waldteufel, P., Mecklenburg, S., & Wigneron, J. P. (2016). Overview of SMOS performance in terms of global soil moisture monitoring after six years in operation. *Remote Sensing of Environment*, 180, 40–63. <https://doi.org/10.1016/j.rse.2016.02.042>
- Kerr, Y. H., Waldteufel, P., Wigneron, J. P., Delwart, S., Cabot, F., Boutin, J., Escorihuela, M. J., Font, J., Reul, N., Gruhier, C., Juglea, S. E., Drinkwater, M. R., Hahne, A., Martin-Neira, M., & Mecklenburg, S. (2010). The SMOS L: New tool for monitoring key elements of the global water cycle. *Proceedings of the IEEE*, 98(5), 666–687. <https://doi.org/10.1109/JPROC.2010.2043032>
- Kerr, Y. H., Waldteufel, P., Wigneron, J.-P., Martinuzzi, J., Font, J., & Berger, M. (2001). Soil moisture retrieval from space: the soil moisture and ocean salinity (SMOS) mission. *IEEE Transactions on Geoscience and Remote Sensing*, 39(8), 1729–1735. <https://doi.org/10.1109/36.942551>
- Kingumbi, A., Bargaoui, Z., Ledoux, E., Besbes, M., & Hubert, P. (2007). Modélisation hydrologique stochastique d'un bassin affecté par des changements d'occupation : Cas du Merguellil en Tunisie centrale. *Hydrological Sciences Journal*, 52(6), 1232–1252. <https://doi.org/10.1623/hysj.52.6.1232>

- Koster, R. D., Chang, Y., Wang, H., & Schubert, S. D. (2016). Impacts of local soil moisture anomalies on the atmospheric circulation and on remote surface meteorological fields during boreal summer: A comprehensive analysis over North America. *Journal of Climate*, 29(20), 7345–7364. <https://doi.org/10.1175/JCLI-D-16-0192.1>
- Kumar, P., Prasad, R., Choudhary, A., Gupta, D. K., Mishra, V. N., Vishwakarma, A. K., Singh, A. K., & Srivastava, P. K. (2019). Comprehensive evaluation of soil moisture retrieval models under different crop cover types using C-band synthetic aperture radar data. *Geocarto International*, 34(9), 1022–1041. <https://doi.org/10.1080/10106049.2018.1464601>
- Kumar, K., Suryanarayana Rao, H. P., & Arora, M. K. (2015). Study of water cloud model vegetation descriptors in estimating soil moisture in Solani catchment. *Hydrological Processes*, 29(9), 2137–2148. <https://doi.org/10.1002/hyp.10344>
- Lacombe, G., Cappelaere, B., & Leduc, C. (2008). Hydrological impact of water and soil conservation works in the Merguellil catchment of central Tunisia. *Journal of Hydrology*, 359(3–4), 210–224. <https://doi.org/10.1016/j.jhydrol.2008.07.001>
- Lawston, P. M., Santanello, J. A., & Kumar, S. V. (2017). Irrigation Signals Detected From SMAP Soil Moisture Retrievals. *Geophysical Research Letters*, 44(23), 11,860–11,867. <https://doi.org/10.1002/2017GL075733>
- Leduc, C., Ammar, S. B. E. N., Favreau, G., Beji, R., & Virrion, R. (2007). Impacts of hydrological changes in the Mediterranean zone: environmental modifications and rural development in the Merguellil catchment, central Tunisia. *Hydrological Sciences–Journal–des Sciences Hydrologiques, Special Section : Dryland Hydrology in Mediterranean Region*, 52(6), 1162–1178.
- Leduc, C., Pulido-Bosch, A., & Remini, B. (2017). Anthropisation des ressources en eaux souterraines en Méditerranée : processus et défis. *Hydrogeology Journal*, 25(6), 1529–1547. <https://doi.org/10.1007/s10040-017-1572-6>
- Lemordant, L., Gentine, P., Swann, A. S., Cook, B. I., & Scheff, J. (2018). Critical impact of vegetation physiology on the continental hydrologic cycle in response to increasing CO<sub>2</sub>. *Proceedings of the National Academy of Sciences of the United States of America*, 115(16), 4093–4098. <https://doi.org/10.1073/pnas.1720712115>
- Leng, P., Song, X., Duan, S. B., & Li, Z. L. (2016). A practical algorithm for estimating surface soil moisture using combined optical and thermal infrared data. *International Journal of Applied Earth Observation and Geoinformation*, 52, 338–348. <https://doi.org/10.1016/j.jag.2016.07.004>
- Le Page, M., Jarlan, L., El Hajj, M. M., Zribi, M., Baghdadi, N., & Boone, A. (2020). Potential for the detection of irrigation events on maize plots using Sentinel-1 soil moisture products. *Remote Sensing*, 12(10). <https://doi.org/10.3390/rs12101621>
- Le Page, M., Nguyen, T., Zribi, M., Boone, A., Dari, J., Modanesi, S., Zappa, L., Ouaadi, N., & Jarlan, L. (2023). Irrigation Timing Retrieval at the Plot Scale Using Surface Soil Moisture Derived from Sentinel Time Series in Europe. *Remote Sensing*, 15(5). <https://doi.org/10.3390/rs15051449>
- Lievens, H., & Verhoest, N. E. C. (2011). On the retrieval of soil moisture in wheat fields from L-band SAR based on water cloud modeling, the IEM, and effective roughness parameters. *IEEE Geoscience and Remote Sensing Letters*, 8(4), 740–744. <https://doi.org/10.1109/LGRS.2011.2106109>
- Lili Chabaane Z. (1993) Télédétection infrarouge thermique et quantification de stress hydriques d'origine pathologique : Validation sur blé infesté par *Heterodera avenae* Woll. *Thèse de doctorat de l'E.N.S.A. de Rennes*, France. 245.
- Lili Chabaane Z., Amri R., Zribi M., Shabou M., Chahbi A., Gorraab A., Dridi G., Ben Aissa N., Kotti F., Boulet G., Mougenot B et Simonneaux V. (2014). Les risques liés à l'eau verte : apport de la télédétection dans un contexte tunisien semi-aride. *3ème JS de Beit El Hekma Tunisie*.

- Liu, C., & Shi, J. (2016). Estimation of Vegetation Parameters of Water Cloud Model for Global Soil Moisture Retrieval Using Time-Series L-Band Aquarius Observations. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(12), 5621–5633. <https://doi.org/10.1109/JSTARS.2016.2596541>
- Ma, C., Li, X., & McCabe, M. F. (2020). Retrieval of high-resolution soil moisture through combination of Sentinel-1 and Sentinel-2 data. *Remote Sensing*, 12(14). <https://doi.org/10.3390/rs12142303>
- Ma, C., Li, X., Notarnicola, C., Wang, S., & Wang, W. (2017). Uncertainty Quantification of Soil Moisture Estimations Based on a Bayesian Probabilistic Inversion. *IEEE Transactions on Geoscience and Remote Sensing*, 55(6), 3194–3207. <https://doi.org/10.1109/TGRS.2017.2664078>
- Madelon, R., Rodríguez-Fernández, N. J., Bazzi, H., Baghdadi, N., Albergel, C., Dorigo, W., & Zribi, M. (2023). Soil moisture estimates at 1 km resolution making a synergistic use of Sentinel data. *Hydrology and Earth System Sciences*, 27(6), 1221–1242. <https://doi.org/10.5194/hess-27-1221-2023>
- Malbêteau, Y., Merlin, O., Molero, B., Rüdiger, C., & Bacon, S. (2016). DisPATCh as a tool to evaluate coarse-scale remotely sensed soil moisture using localized in situ measurements: Application to SMOS and AMSR-E data in Southeastern Australia. *International Journal of Applied Earth Observation and Geoinformation*, 45, 221–234. <https://doi.org/10.1016/j.jag.2015.10.002>
- Mankin, J. S., Seager, R., Smerdon, J. E., Cook, B. I., & Williams, A. P. (2019). Mid-latitude freshwater availability reduced by projected vegetation responses to climate change. *Nature Geoscience*, 12(12), 983–988. <https://doi.org/10.1038/s41561-019-0480-x>
- Masle-Meynard, J., Masle-meynard, J., Cedex, P., & Blé, R. (1981). Influence des conditions de nutrition. *Agronomie* (Vol. 1, Issue 5). <https://hal.science/hal-00884267>
- Massari, C., Brocca, L., Moramarco, T., Trambly, Y., & Didon Lescot, J. F. (2014). Potential of soil moisture observations in flood modelling: Estimating initial conditions and correcting rainfall. *Advances in Water Resources*, 74, 44–53. <https://doi.org/10.1016/j.advwatres.2014.08.004>
- Massuel, S., & Riaux, J. (2017). Surexploitation de l'eau souterraine : pourquoi agite-t-on le drapeau rouge? Etude de cas dans l'aquifère de la plaine de Kairouan (Tunisie centrale). *Hydrogeology Journal*, 25(6), 1607–1620. <https://doi.org/10.1007/s10040-017-1568-2>
- Matula, S., Bát'ková, K., & Legese, W. L. (2016). Laboratory performance of five selected soil moisture sensors applying factory and own calibration equations for two soil media of different bulk density and salinity levels. *Sensors (Switzerland)*, 16(11). <https://doi.org/10.3390/s16111912>
- McFeeters, S. K. (1996). The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, 17(7), 1425–1432. <https://doi.org/10.1080/01431169608948714>
- MedECC. (2020). MedECC (2020) Climate and Environmental Change in the Mediterranean Basin – Current Situation and Risks for the Future. First Mediterranean Assessment Report [Cramer, W., Guiot, J., Marini, K. (eds.)]. Union for the Mediterranean. <https://doi.org/10.5281/zenodo.7224821>
- Merlin, O., Escorihuela, M. J., Mayoral, M. A., Hagolle, O., Al Bitar, A., & Kerr, Y. (2013). Self-calibrated evaporation-based disaggregation of SMOS soil moisture: An evaluation study at 3km and 100m resolution in Catalunya, Spain. *Remote Sensing of Environment*, 130, 25–38. <https://doi.org/10.1016/j.rse.2012.11.008>
- Miller, J. D., & Gaskin, G. J. (1999). ThetaProbe ML2x Principles of operation and applications.
- Mirsoleimani, H. R., Sahebi, M. R., Baghdadi, N., & El Hajj, M. (2019). Bare soil surface moisture retrieval from sentinel-1 SAR data based on the calibrated IEM and Dubois models using neural networks. *Sensors (Switzerland)*, 19(14), 1–12. <https://doi.org/10.3390/s19143209>

- Mohanty, B. P., Cosh, M. H., Lakshmi, V., & Montzka, C. (2017). Soil Moisture Remote Sensing: State-of-the-Science. *Vadose Zone Journal*, 16(1). <https://doi.org/10.2136/vzj2016.10.0105>
- Mo, T., Choudhury, B. J., Schmugge, T. J., Wang, J. R., & Jackson, T. J. (1982). A model for microwave emission from vegetation-covered fields. *Journal of Geophysical Research*, 87(C13), 11229–11237. <https://doi.org/10.1029/JC087iC13p11229>
- Motohka, T., Kankaku, Y., Miura, S., & Suzuki, S. (2019). ALOS-4 L-band SAR mission and observation. *IEEE International Geoscience & Remote Sensing Symposium*.
- Motte, E., Zribi, M., Fanise, P., Egido, A., Darrozes, J., Al-Yaari, A., Baghdadi, N., Baup, F., Dayau, S., Fieuzal, R., Frison, P. L., Guyon, D., & Wigneron, J. P. (2016). GLORI: A GNSS-R dual polarization airborne instrument for land surface monitoring. *Sensors (Switzerland)*, 16(5). <https://doi.org/10.3390/s16050732>
- Nativel, S., Ayari, E., Rodriguez-Fernandez, N., Baghdadi, N., Madelon, R., Albergel, C., & Zribi, M. (2022). Hybrid Methodology Using Sentinel-1/Sentinel-2 for Soil Moisture Estimation. *Remote Sensing*, 14(10). <https://doi.org/10.3390/rs14102434>
- Nazoumou, Y., & Besbes, M. (2000). Simulation de la recharge artificielle de nappe en oued par un modèle à réservoirs. *Journal of Water Science*, 13(4), 379–404. <https://doi.org/10.7202/705399ar>
- Nicodemus, F., Richmond, J., Hsia, J., Ginsberg, I., & Limperis, T. (1977). *Geometrical Considerations and Nomenclature for Reflectance*.
- Nie, W., Kumar, S. V., Bindlish, R., Liu, P. W., & Wang, S. (2022). Remote sensing-based vegetation and soil moisture constraints reduce irrigation estimation uncertainty. *Environmental Research Letters*, 17(8). <https://doi.org/10.1088/1748-9326/ac7ed8>
- Oh, Y. (2004). Quantitative retrieval of soil moisture content and surface roughness from multipolarized radar observations of bare soil surfaces. *IEEE Transactions on Geoscience and Remote Sensing*, 42(3), 596–601. <https://doi.org/10.1109/TGRS.2003.821065>
- Oh, Y., Sarabandi, K., & Ulaby, F. T. (1992). An empirical model and an inversion technique for radar scattering from bare soil surfaces. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 30, no. 2, pp. 370–381, <https://doi.org/10.1109/36.134086>
- Oh, Y., Sarabandi, K., & Ulaby, F. T. (1994). Inversion algorithm for retrieving soil moisture and surface roughness from polarimetric radar observation. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 3, 1582–1584. <https://doi.org/10.1109/igarss.1994.399504>
- Oh, Y., Sarabandi, K., & Ulaby, F. T. (2002). Semi-empirical model of the ensemble-averaged differential Mueller matrix for microwave backscattering from bare soil surfaces. *IEEE Transactions on Geoscience and Remote Sensing*, 40(6), 1348–1355. <https://doi.org/10.1109/TGRS.2002.800232>
- Ojha N, Merlin O, Molero B, Suere C, Olivera-Guerra L, Ait Hssaine B, Amazirh A, Al Bitar A, Escorihuela MJ, Er-Raki S. Stepwise Disaggregation of SMAP Soil Moisture at 100 m Resolution Using Landsat-7/8 Data and a Varying Intermediate Resolution. *Remote Sensing*. 11(16):1863. <https://doi.org/10.3390/rs11161863>
- Orth, R., & Seneviratne, S. I. (2012). Analysis of soil moisture memory from observations in Europe. *Journal of Geophysical Research Atmospheres*, 117(15). <https://doi.org/10.1029/2011JD017366>
- 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 Sensing of Environment*, 251(August), 112050. <https://doi.org/10.1016/j.rse.2020.112050>

- Ouaadi, N., Jarlan, L., Khabba, S., Ezzahar, J., Page, M. Le, & Merlin, O. (2021). Irrigation Amounts and Timing Retrieval through Data Assimilation of Surface Soil Moisture into the FAO-56 Approach in the South Mediterranean Region. *Remote Sensing*, 1–26. <https://doi.org/10.3390/rs13142667>
- Owe, M., Chang, A., & Golus, R. E. (1988). Estimating Surface Soil Moisture from Satellite Microwave Measurements and a Satellite Derived Vegetation Index. *Remote Sensing of Environment*, Vol. 24.
- Paloscia, S., Pampaloni, P., Pettinato, S., & Santi, E. (2008). A comparison of algorithms for retrieving soil moisture from ENVIS AT/AS AR images. *IEEE Transactions on Geoscience and Remote Sensing*, 46(10), 3274–3284. <https://doi.org/10.1109/TGRS.2008.920370>
- Panciera, R., Tanase, M. A., Lowell, K., & Walker, J. P. (2014). Evaluation of IEM, Dubois, and oh radar backscatter models using airborne L-Band SAR. *IEEE Transactions on Geoscience and Remote Sensing*, 52(8), 4966–4979. <https://doi.org/10.1109/TGRS.2013.2286203>
- Pan, F. (2012). Estimating Daily Surface Soil Moisture Using a Daily Diagnostic Soil Moisture Equation. *Journal of Irrigation and Drainage Engineering*, 138(7), 625–631. [https://doi.org/10.1061/\(asce\)ir.1943-4774.0000450](https://doi.org/10.1061/(asce)ir.1943-4774.0000450)
- Paolini, G., Escorihuela, M. J., Merlin, O., Sans, M. P., & Bellvert, J. (2022). Classification of Different Irrigation Systems at Field Scale Using Time-Series of Remote Sensing Data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15, 10055–10072. <https://doi.org/10.1109/JSTARS.2022.3222884>
- Papy, F., & Douyer, C. (1991). Systèmes agraires et développement Influence des états de surface du territoire agricole sur le déclenchement des inondations catastrophiques.
- Parinussa, R. M., Holmes, T. R. H., Wanders, N., Dorigo, W. A., & De Jeu, R. A. M. (2015). A preliminary study toward consistent soil moisture from AMSR2. *Journal of Hydrometeorology*, 16(2), 932–947. <https://doi.org/10.1175/JHM-D-13-0200.1>
- Peng, J., Albergel, C., Balenzano, A., Brocca, L., Cartus, O., Cosh, M. H., Crow, W. T., Dabrowska-Zielinska, K., Dadson, S., Davidson, M. W. J., de Rosnay, P., Dorigo, W., Gruber, A., Hagemann, S., Hirschi, M., Kerr, Y. H., Lovergine, F., Mahecha, M. D., Marzahn, P., ... Loew, A. (2021). A roadmap for high-resolution satellite soil moisture applications – confronting product characteristics with user requirements. *Remote Sensing of Environment*, 252, 112162. <https://doi.org/10.1016/j.rse.2020.112162>
- Peng, J., Loew, A., Merlin, O., & Verhoest, N. E. C. (2017). A review of spatial downscaling of satellite remotely sensed soil moisture. *Reviews of Geophysics*, 55(2), 341–366. <https://doi.org/10.1002/2016RG000543>
- Periasamy, S. (2018). Significance of dual polarimetric synthetic aperture radar in biomass retrieval: An attempt on Sentinel-1. *Remote Sensing of Environment*, 217, 537–549. <https://doi.org/10.1016/j.rse.2018.09.003>
- Petropoulos, G. P., Ireland, G., & Barrett, B. (2015). Surface soil moisture retrievals from remote sensing: Current status, products & future trends. In *Physics and Chemistry of the Earth* (Vols. 83–84, pp. 36–56). Elsevier Ltd. <https://doi.org/10.1016/j.pce.2015.02.009>
- Piles, M., Camps, A., Vall-Llossera, M., Corbella, I., Panciera, R., Rudiger, C., Kerr, Y. H., & Walker, J. (2011). Downscaling SMOS-derived soil moisture using MODIS visible/infrared data. *IEEE Transactions on Geoscience and Remote Sensing*, 49(9), 3156–3166. <https://doi.org/10.1109/TGRS.2011.2120615>
- Polidori, L. (1997). Cartographie radar (Vol. 1). Taylor & Francis.
- Plummer, S., Lecomte, P., & Doherty, M. (2017). The ESA Climate Change Initiative (CCI): A European contribution to the generation of the Global Climate Observing System. *Remote Sensing of Environment*, 203, 2–8. <https://doi.org/10.1016/j.rse.2017.07.014>

- Poon, C. Y., & Bhushan, B. (1995). Comparison of surface roughness measurements by stylus profiler, AFM and non-contact optical profiler. In *Wear* (Vol. 190).
- Prakash, R., Singh, D., & Pathak, N. P. (2012). A fusion approach to retrieve soil moisture with SAR and optical data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(1), 196–206. <https://doi.org/10.1109/JSTARS.2011.2169236>
- Prévoit, L., Champion, I., & Guyot, G. (1993). Estimating surface soil moisture and leaf area index of a wheat canopy using a dual-frequency (C and X bands) scatterometer. *Remote Sensing of Environment*, 46(3), 331–339. [https://doi.org/10.1016/0034-4257\(93\)90053-Z](https://doi.org/10.1016/0034-4257(93)90053-Z)
- Prigent, C., Aires, F., Rossow, W. B., & Robock, A. (2005). Sensitivity of satellite microwave and infrared observations to soil moisture at a global scale: Relationship of satellite observations to in situ soil moisture measurements. *Journal of Geophysical Research Atmospheres*, 110(7), 1–15. <https://doi.org/10.1029/2004JD005087>
- Qiao, L., Zuo, Z., & Xiao, D. (2022). Evaluation of Soil Moisture in CMIP6 Simulations. *Journal of Climate*, 35(2), 779–800. <https://doi.org/10.1175/JCLI-D-20-0827.1>
- Rabus, B., Wehn, H., & Nolan, M. (2010). The importance of soil moisture and soil structure for InSAR phase and backscatter, as determined by FDTD modeling. *IEEE Transactions on Geoscience and Remote Sensing*, 48(5), 2421–2429. <https://doi.org/10.1109/TGRS.2009.2039353>
- Rahman, M. M., Moran, M. S., Thoma, D. P., Bryant, R., Sano, E. E., Collins, C. D. H., Skirvin, S., Kershner, C., & Orr, B. J. (2007). A derivation of roughness correlation length for parameterizing radar backscatter models. *International Journal of Remote Sensing*, 28(18), 3995–4012. <https://doi.org/10.1080/01431160601075533>
- Reynolds, S. G. (1970). the gravimetric method of soil moisture determination part i a study of equipment, and methodological problems. In *Journal of Hydrology* (Vol. 11).
- Robinson, D. A., Campbell, C. S., Hopmans, J. W., Hornbuckle, B. K., Jones, S. B., Knight, R., Ogden, F., Selker, J., & Wendroth, O. (2008). Soil Moisture Measurement for Ecological and Hydrological Watershed-Scale Observatories: A Review. *Vadose Zone Journal*, 7(1), 358–389. <https://doi.org/10.2136/vzj2007.0143>
- Robinson, D. A., Gardner, C. M. K., & Cooper, J. D. (1999). Measurement of relative permittivity in sandy soils using TDR, capacitance and theta probes: comparison, including the effects of bulk soil electrical conductivity. [www.elsevier.com/locate/jhydrol](http://www.elsevier.com/locate/jhydrol)
- Roose. (1996). Méthodes de mesure des états de surface du sol, de la rugosité et des autres caractéristiques qui peuvent aider au diagnostic de terrain des risques de ruissellement et d'érosion, en particulier sur les versants cultivés des montagnes.
- Rosenqvist, A., Shimada, M., Suzuki, S., Ohgushi, F., Tadono, T., Watanabe, M., Tsuzuku, K., Watanabe, T., Kamijo, S., & Aoki, E. (2014). Operational performance of the ALOS global systematic acquisition strategy and observation plans for ALOS-2 PALSAR-2. *Remote Sensing of Environment*, 155, 3–12. <https://doi.org/10.1016/j.rse.2014.04.011>
- Roussel, N., Frappart, F., Ramillien, G., Darrozes, J., Baup, F., Lestarquit, L., & Ha, M. C. (2016). Detection of Soil Moisture Variations Using GPS and GLONASS SNR Data for Elevation Angles Ranging from 2° to 70°. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(10), 4781–4794. <https://doi.org/10.1109/JSTARS.2016.2537847>
- Saadi, S., Simonneaux, V., Boulet, G., Raimbault, B., Mougenot, B., Fanise, P., Ayari, H., Lili-Chabaane, Z. (2015). Monitoring Irrigation Consumption Using High-resolution NDVI Image Time Series: Calibration and Validation in the Kairouan Plain (Tunisia). *Remote Sensing*, 7, 13005.

- Sabaghy, S., Walker, J. P., Renzullo, L. J., Akbar, R., Chan, S., Chaubell, J., Das, N., Dunbar, R. S., Entekhabi, D., Gevaert, A., Jackson, T. J., Loew, A., Merlin, O., Moghaddam, M., Peng, J., Peng, J., Piepmeyer, J., Rüdiger, C., Stefan, V., ... Yueh, S. (2020). Comprehensive analysis of alternative downscaled soil moisture products. *Remote Sensing of Environment*, 239. <https://doi.org/10.1016/j.rse.2019.111586>
- Sadeghi, M., Jones, S. B., & Philpot, W. D. (2015). A linear physically-based model for remote sensing of soil moisture using short wave infrared bands. *Remote Sensing of Environment*, 164, 66–76. <https://doi.org/10.1016/j.rse.2015.04.007>
- Saleh, A. (1997). Reply to “Comments on Chain Method for Measuring Soil Roughness”, *Soil Science Society of America Journal*, 61(5), 1533–1535. <https://doi.org/10.2136/sssaj1997.03615995006100050035x>
- Schilling, J., Hertig, E., Trambly, Y., & Scheffran, J. (2020). Climate change vulnerability, water resources and social implications in North Africa. *Regional Environmental Change*, 20(1). <https://doi.org/10.1007/s10113-020-01597-7>
- Schlüter, S., Albrecht, L., Schwärzel, K., & Kreiselmeyer, J. (2020). Long-term effects of conventional tillage and no-tillage on saturated and near-saturated hydraulic conductivity – Can their prediction be improved by pore metrics obtained with X-ray CT? *Geoderma*, 361. <https://doi.org/10.1016/j.geoderma.2019.114082>
- Schumann, G.J.P., Bates, P.D., Di Baldassarre, G., Mason, D.C. (2012). The Use of Radar Imagery in Riverine Flood Inundation Studies, *Fluvial Remote Sensing for Science and Management*. John Wiley & Sons, Ltd, pp. 115-140.
- Seager, R., Osborn, T. J., Kushnir, Y., Simpson, I. R., Nakamura, J., & Liu, H. (2019). Climate variability and change of mediterranean-type climates. *Journal of Climate*, 32(10), 2887–2915. <https://doi.org/10.1175/JCLI-D-18-0472.1>
- Shabou, M., Mougénot, B., Lili Chabaane, Z., Walter, C., Boulet, G., Aissa, N. Ben, & Zribi, M. (2015). Soil clay content mapping using a time series of Landsat TM data in semi-arid lands. *Remote Sensing*, 7(5), 6059–6078. <https://doi.org/10.3390/rs70506059>
- Shao, M. qi, Xu, D., Li, S. yi, Zuo, X. gang, Chen, C. ke, Peng, G. zhuang, Zhang, J. min, Wang, X. chen, & Yang, Q. (2023). A review of surface roughness measurements based on laser speckle method. In *Journal of Iron and Steel Research International*. Springer. <https://doi.org/10.1007/s42243-023-00930-8>
- Shi, J., Wang, J., Hsu, A., O’Neill, P., & Engman, E. T. (1995). Estimation of soil moisture and surface roughness parameters using L-band SAR measurements. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 1, 507–509. <https://doi.org/10.1109/igarss.1995.520322>
- Shi, J., Wang, J., Hsu, A. Y., O’Neill, P. E., & Engman, E. T. (1997). Estimation of bare surface soil moisture and surface roughness parameter using L-band SAR image data. *IEEE Transactions on Geoscience and Remote Sensing*, 35(5), 1254–1266. <https://doi.org/10.1109/36.628792>
- Short Gianotti, D. J., Akbar, R., Feldman, A. F., Salvucci, G. D., & Entekhabi, D. (2020). Terrestrial Evaporation and Moisture Drainage in a Warmer Climate. *Geophysical Research Letters*, 47(5). <https://doi.org/10.1029/2019GL086498>
- Singh, K. V., Setia, R., Sahoo, S., Prasad, A., & Pateriya, B. (2014). Evaluation of NDWI and MNDWI for assessment of waterlogging by integrating digital elevation model and groundwater level. *Geocarto International*, 30(6), 650–661. <https://doi.org/10.1080/10106049.2014.965757>
- Slama, A., Salem, M. Ben, Barek, M., Naceur, B., Zid, E., Rue, H., Karray, A., T. (2005). Les céréales en Tunisie : Production, effet de la sécheresse et mécanismes de résistance. <https://www.researchgate.net/publication/288194942>



- Slimani, M., Cudennec, C., & Feki, H. (2007). Structure du gradient pluviométrique de la transition Méditerranée-Sahara en Tunisie : Déterminants géographiques et saisonnalité. *Hydrological Sciences Journal*, 52(6), 1088–1102. <https://doi.org/10.1623/hysj.52.6.1088>
- Snoussi, M., Jerbi, H., & Tarhouni, J. (2022). Integrated Groundwater Flow Modeling for Managing a Complex Alluvial Aquifer Case of Study Mio-Plio-Quaternary Plain of Kairouan (Central Tunisia). *Water (Switzerland)*, 14(4). <https://doi.org/10.3390/w14040668>
- Steele-Dunne, S. C., McNairn, H., Monsivais-Huertero, A., Judge, J., Liu, P. W., & Papathanassiou, K. (2017). Radar Remote Sensing of Agricultural Canopies: A Review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(5), 2249–2273. <https://doi.org/10.1109/JSTARS.2016.2639043>
- Sun, H., Zhang, X., & Zhao, X. (2022). Series or Parallel? An Exploration in Coupling Physical Model and Machine Learning Method for Disaggregating Satellite Microwave Soil Moisture. *IEEE Transactions on Geoscience and Remote Sensing*, 60. <https://doi.org/10.1109/TGRS.2022.3216343>
- Susha Lekshmi, S. U., Singh, D. N., & Shojaei Baghini, M. (2014). A critical review of soil moisture measurement. In *Measurement: Journal of the International Measurement Confederation* (Vol. 54, pp. 92–105). Elsevier B.V. <https://doi.org/10.1016/j.measurement.2014.04.007>
- Suzuki, S., Kankaku, Y., & Osawa, Y. (2012). ALOS-2 development status and draft acquisition strategy. *Sensors, Systems, and Next-Generation Satellites XVI*, 8533, 85330A. <https://doi.org/10.1117/12.973708>
- Talla Tankam, N., Tonye, E., & Dipanda, A. (2010). *Traitement numérique d'images et applications : Méthodes statistiques optimisées pour le traitement numérique des images de grandes tailles*. <https://www.researchgate.net/publication/279258244>
- Tomer, S. K., Bitar, A. Al, Sekhar, M., Zribi, M., Bandyopadhyay, S., & Kerr, Y. (2016). MAPSM: A spatio-temporal algorithm for merging soil moisture from active and passive microwave remote sensing. *Remote Sensing*, 8(12), 1–23. <https://doi.org/10.3390/rs8120990>
- Torres, R., Davidson, M., & Geudtner, D. (2020). Copernicus Sentinel Mission at C- and L-Band: Current Status and Future Perspectives. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 4055–4058. <https://doi.org/10.1109/IGARSS39084.2020.9323149>
- Tour&, A., Thomson, K. P. B., Edwards, G., Brown, R. J., & Brisco, B. G. (1994). Adaptation of the MIMICS Backscattering Model to the Agricultural Context-Wheat and Canola at L and C Bands. In *IEEE Transactions on Geoscience and Remote sensing* (Vol. 32, Issue 1).
- 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., ... Polcher, J. (2020). Challenges for drought assessment in the Mediterranean region under future climate scenarios. In *Earth-Science Reviews* (Vol. 210). Elsevier B.V. <https://doi.org/10.1016/j.earscirev.2020.103348>
- Ulaby, F. T. (1975). Radar Response to Vegetation. *IEEE Transactions on Antennas and Propagation*, 23(1), 36–45. <https://doi.org/10.1109/TAP.1975.1140999>
- Ulaby, F. T., Aslam, A., & Dobson, M. C. (1982). Effects of Vegetation Cover on the Radar Sensitivity to Soil Moisture. In *IEEE Transactions on Geoscience and Remote sensing* (Vol. 20, Issue 4).
- Ulaby, F. T., & El-Rayes, M. A. (1987). Microwave Dielectric Spectrum of Vegetation Part II: Dual-Dispersion Model. In *IEEE IEEE Transactions on Geoscience and Remote sensing* (Issue 5).
- Ulaby, F. T., & Jedlicka, R. P. (1984). Microwave Dielectric Properties of Plant Materials. In *IEEE IEEE Transactions on Geoscience and Remote sensing* (Issue 4).

- Ulaby, F. T., Moore, R. K., & Fung, A. K. (1986). Microwave remote sensing: Active and passive. Volume 3 - From theory to applications.
- Ulaby, F. T., Sarabandi, K., McDonald, K., Whitt, M., & Craig Dobson, M. (1990). Michigan microwave canopy scattering model. *International Journal of Remote Sensing*, 11(7), 1223–1253. <https://doi.org/10.1080/01431169008955090>
- Valentin, C. (1981). Organisations pelliculaires superficielles de quelques sols de région subdésertique (Agadez-République du Niger) : dynamique de formation et co M-TROPICS Critical Zone Observatory View project MSEC / MultiScale Environmental Changes View project. <https://www.researchgate.net/publication/40439443>
- Van Zyl, J. J., Zebker, H. A., & Elachi, C. (1987). Imaging radar polarization signatures: Theory and observation. *Radio Science*, 22(4), 529–543. <https://doi.org/10.1029/RS022i004p00529>
- Vereecken, H., Huisman, J. A., Bogaen, H., Vanderborght, J., Vrugt, J. A., & Hopmans, J. W. (2008). On the value of soil moisture measurements in vadose zone hydrology: A review. *Water Resources Research*, 46(4). <https://doi.org/10.1029/2008WR006829>
- Wagner, W., Blöschl, G., Pampaloni, P., Calvet, J. C., Bizzarri, B., Wigneron, J. P., & Kerr, Y. (2007). Operational readiness of microwave remote sensing of soil moisture for hydrologic applications. In *Nordic Hydrology* (Vol. 38, Issue 1, pp. 1–20). <https://doi.org/10.2166/nh.2007.029>
- Wagner, W., Hahn, S., Kidd, R., Melzer, T., Bartalis, Z., Hasenauer, S., Figa-Saldaña, J., De Rosnay, P., Jann, A., Schneider, S., Komma, J., Kubu, G., Brugger, K., Aubrecht, C., Züger, J., Gangkofner, U., Kienberger, S., Brocca, L., Wang, Y., ... Rubel, F. (2013). The ASCAT soil moisture product: A review of its specifications, validation results, and emerging applications. In *Meteorologische Zeitschrift* (Vol. 22, Issue 1, pp. 5–33). <https://doi.org/10.1127/0941-2948/2013/0399>
- Wagner, W., Naeimi, V., Scipal, K., Jeu, R., & Martínez-Fernández, J. (2007). Soil moisture from operational meteorological satellites. *Hydrogeology Journal*, 15(1), 121–131. <https://doi.org/10.1007/s10040-006-0104-6>
- Walker, J. P., Willgoose, G. R., & Kalma, J. D. (2004). In situ measurement of soil moisture: A comparison of techniques. *Journal of Hydrology*, 293(1–4), 85–99. <https://doi.org/10.1016/j.jhydrol.2004.01.008>
- Wang, L., He, B., Bai, X., & Xing, M. (2019). Assessment of Different Vegetation Parameters for Parameterizing the Coupled Water Cloud Model and Advanced Integral Equation Model for Soil Moisture Retrieval Using Time Series Sentinel-1A Data. *Photogrammetric Engineering & Remote Sensing*, vol.85, No.1, <https://doi.org/http://doi.org/10.14358/PERS.85.1.xxx>
- Wang, S., Rao, Y., Chen, J., Liu, L., & Wang, W. (2021). Adopting “difference-in-differences” method to monitor crop response to agrometeorological hazards with satellite data: A case study of dry-hot wind. *Remote Sensing*, 13(3), 1–22. <https://doi.org/10.3390/rs13030482>
- Watson, D. J. (1947a). Comparative Physiological Studies on the Growth of Field Crops: II. The Effect of Varying Nutrient Supply on Net Assimilation Rate and Leaf Area. In *Annals of Botany*, Vol. 11, Issue 44. <https://www.jstor.org/stable/42907023>
- Watson, D. J. (1947b). Comparative Physiological Studies on the Growth of Field Crops: I. Variation in Net Assimilation Rate and Leaf Area between Species and Varieties, and within and between Years. In *Annals of Botany*, Vol. 11, Issue 41. <https://www.jstor.org/stable/42907002>
- Weiss, M., Baret, F., Smith, G. J., Jonckheere, I., & Coppin, P. (2004). Review of methods for in situ leaf area index (LAI) determination Part II. Estimation of LAI, errors and sampling. *Agricultural and Forest Meteorology*, 121(1–2), 37–53. <https://doi.org/10.1016/j.agrformet.2003.08.001>
- Weiss, M., Jacob, F., & Duveiller, G. (2020). Remote sensing for agricultural applications: A meta-review. *Remote Sensing of Environment*, 236. <https://doi.org/10.1016/j.rse.2019.111402>

- Whitt, M. W., & Ulaby, F. T. (1994). Radar response of periodic vegetation canopies. *International Journal of Remote Sensing*, Vol. 15, Issue 9. <https://doi.org/10.1080/01431169408954211>
- Wigneron, J. P., Jackson, T. J., O'Neill, P., De Lannoy, G., de Rosnay, P., Walker, J. P., Ferrazzoli, P., Mironov, V., Bircher, S., Grant, J. P., Kurum, M., Schwank, M., Munoz-Sabater, J., Das, N., Royer, A., Al-Yaari, A., Al Bitar, A., Fernandez-Moran, R., Lawrence, H., ... Kerr, Y. (2017). Modelling the passive microwave signature from land surfaces: A review of recent results and application to the L-band SMOS & SMAP soil moisture retrieval algorithms. In *Remote Sensing of Environment*, Vol. 192, 238–262. Elsevier Inc. <https://doi.org/10.1016/j.rse.2017.01.024>
- Xiao, X., Boles, S., Liu, J., Zhuang, D., & Liu, M. (2002). Characterization of forest in Northeastern CHine, using multi-temporal SPOT-4 vegetation sensor data. *Remote Sensing of Environment*, 335–348.
- Yao, P., Lu, H., Shi, J., Zhao, T., Yang, K., Cosh, M. H., Gianotti, D. J. S., & Entekhabi, D. (2021). A long term global daily soil moisture dataset derived from AMSR-E and AMSR2 (2002–2019). *Scientific Data*, 8(1). <https://doi.org/10.1038/s41597-021-00925-8>
- Zazueta, F. S., & Xin, J. (1994). Soil Moisture Sensors 1.
- Zayani, Hayfa, (2023). Caractérisation des pratiques agricoles et prédiction de leurs impacts sur les propriétés fonctionnelles du sol par couplage proxi-détection et télédétection spatiale, *Thèse en cotutelle entre Université de Carthage-INAT/ AgroCampus Ouest*.
- Zayani, Hayfa, (2019). Suivi des itinéraires techniques sur sols nus ou peu couverts par satellite pour la détection précoce des cycles culturels des céréales et des maraichages dans la plaine du Merguellil, *Mastère Gestion Durable des Ressources en Eau*, 112p.
- Zhao, T., & Dai, A. (2015). The magnitude and causes of global drought changes in the twenty-first century under a low-moderate emissions scenario. *Journal of Climate*, 28(11), 4490–4512. <https://doi.org/10.1175/JCLI-D-14-00363.1>
- Zhang, K., Li, X., Zheng, D., Zhang, L., & Zhu, G. (2022). Estimation of Global Irrigation Water Use by the Integration of Multiple Satellite Observations. *Water Resources Research*, 58(3). <https://doi.org/10.1029/2021WR030031>
- Zhang, L., Lv, X., Chen, Q., Sun, G., & Yao, J. (2020). Estimation of surface soil moisture during corn growth stage from SAR and optical data using a combined scattering model. *Remote Sensing*, 12(11), 1–23. <https://doi.org/10.3390/rs12111844>
- Zhang, S., Calvet, J. C., Darrozes, J., Roussel, N., Frappart, F., & Bouhours, G. (2018). Deriving surface soil moisture from reflected GNSS signal observations from a grassland site in southwestern France. *Hydrology and Earth System Sciences*, 22(3), 1931–1946. <https://doi.org/10.5194/hess-22-1931-2018>
- Zhang, S., Roussel, N., Boniface, K., Cuong Ha, M., Frappart, F., Darrozes, J., Baup, F., & Calvet, J. C. (2017). Use of reflected GNSS SNR data to retrieve either soil moisture or vegetation height from a wheat crop. *Hydrology and Earth System Sciences*, 21(9), 4767–4784. <https://doi.org/10.5194/hess-21-4767-2017>
- Zhao, W., Li, Z. L., Wu, H., Tang, B. H., Zhang, X., Song, X., & Zhou, G. (2013). Determination of bare surface soil moisture from combined temporal evolution of land surface temperature and net surface shortwave radiation. *Hydrological Processes*, 27(19), 2825–2833. <https://doi.org/10.1002/hyp.9410>
- Zribi, M., Chahbi, A., Shabou, M., Lili-Chabaane, Z., Duchemin, B., Baghdadi, N., Amri, R., & Chehbouni, A. (2011). Soil surface moisture estimation over a semi-arid region using ENVISAT ASAR radar data for soil evaporation evaluation. *Hydrology and Earth System Sciences*, 15(1), 345–358. <https://doi.org/10.5194/hess-15-345-2011>

- Zribi, M., Dassas, K., Dehaye, V., Fanise, P., Ayari, E., & Le Page, M. (2023). Analysis of Polarimetric GNSS-R Airborne Data as a Function of Land Use. *IEEE Geoscience and Remote Sensing Letters*, 20. <https://doi.org/10.1109/LGRS.2023.3270730>
- Zribi, M., & Dechambre, M. (2003). A new empirical model to retrieve soil moisture and roughness from C-band radar data. *Remote Sensing of Environment*, 84(1), 42–52. [https://doi.org/10.1016/S0034-4257\(02\)00069-X](https://doi.org/10.1016/S0034-4257(02)00069-X)
- Zribi, M., Foucras, M., Baghdadi, N., Demarty, J., & Muddu, S. (2021). A New Reflectivity Index for the Retrieval of Surface Soil Moisture from Radar Data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 818–826. <https://doi.org/10.1109/JSTARS.2020.3033132>
- Zribi, M., Gorraab, A., & Baghdadi, N. (2014). A new soil roughness parameter for the modelling of radar backscattering over bare soil. *Remote Sensing of Environment*, 152, 62–73. <https://doi.org/10.1016/J.RSE.2014.05.009>
- Zribi, M., Kotti, F., Lili-Chabaane, Z., Baghdadi, N., Ben Issa, N., Amri, R., Duchemin, B., & Chehbouni, A. (2012). Soil texture estimation over a semiarid area using TerraSAR-X radar data. *IEEE Geoscience and Remote Sensing Letters*, 9(3), 353–357. <https://doi.org/10.1109/LGRS.2011.2168379>
- Zribi, M., Motte, E., Baghdadi, N., Baup, F., Dayau, S., Fanise, P., Guyon, D., Huc, M., & Wigneron, J. P. (2018). Potential applications of GNSS-R observations over agricultural areas: Results from the GLORI airborne campaign. *Remote Sensing*, 10(8). <https://doi.org/10.3390/rs10081245>
- Zribi, M., Muddu, S., Bousbih, S., al Bitar, A., Tomer, S. K., Baghdadi, N., & Bandyopadhyay, S. (2019). Analysis of L-band SAR data for soil moisture estimations over agricultural areas in the tropics. *Remote Sensing*, 11(9). <https://doi.org/10.3390/rs11091122>
- Zribi, M., Taconet, O., Hégarat-Masclé, S. Le, Vidal-Madjar, D., Emblanch, C., Loumagne, C., & Normand, M. (1997). Backscattering behavior and simulation comparison over bare soils using SIR-C/X-SAR and ERASME 1994 data over Orgeval. *Remote Sensing of Environment*, 59(2), 256–266. [https://doi.org/10.1016/S0034-4257\(96\)00158-7](https://doi.org/10.1016/S0034-4257(96)00158-7)