



**HAL**  
open science

# Synergie optique-radar pour l'estimation des états de surface continentale

Safa Bousbih

► **To cite this version:**

Safa Bousbih. Synergie optique-radar pour l'estimation des états de surface continentale. Interfaces continentales, environnement. Université Paul Sabatier - Toulouse III; Institut national agronomique de Tunisie, 2019. Français. NNT : 2019TOU30278 . tel-02972558

**HAL Id: tel-02972558**

**<https://theses.hal.science/tel-02972558>**

Submitted on 20 Oct 2020

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

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



# THÈSE

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

Délivré par l'Université Toulouse 3 - Paul Sabatier  
Cotutelle internationale : Institut National Agronomique de Tunisie

Présentée et soutenue par  
**Safa BOUSBIH**

Le 16 décembre 2019

**Synergie Optique/radar pour l'estimation des états de surface  
continentale**

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 Chabaane Lili**

Jury

**Mme Simonetta PALOSCIA**, Rapporteur  
**Mme Sihem BEN ABDALLAH**, Rapporteur  
**M. Hamadi HABAEIB**, Examineur  
**M. Nicolas BAGHDADI**, Examineur  
**M. Laurent POLIDORI**, Examineur  
**M. Christian WALTER**, Examineur  
**M. Mehrez ZRIBI**, Directeur de thèse  
**Mme Zohra LILI-CHABAANE**, Co-directrice de thèse

---

## Résumé

L'agriculture en Tunisie fait partie des secteurs importants sur lesquels reposent l'économie du pays. Elle revêt également son importance par sa contribution à la sécurité alimentaire. Dans un contexte de gestion des ressources naturelles, la caractérisation et le suivi des états de surface est indispensable, particulièrement dans les régions semi-arides où plusieurs contraintes freinent le développement agricole (période de sécheresse, conflits sur le partage des eaux, manque de ressources, surexploitations des nappes, etc.). En Tunisie, près de 80 % des ressources en eau disponibles sont utilisées par l'agriculture avec une efficacité limitée. Là, où les ressources en eau sont très limitées, l'estimation de l'état hydrique de surface est particulièrement nécessaire pour établir les décisions adéquates pour une meilleure gestion de cette ressource. Dans ce contexte, la télédétection fournit une base fondamentale de données pour l'observation de la surface et constitue un outil majeur pour l'acquisition d'informations à distance.

Les travaux réalisés au cours de cette thèse sur la plaine de Kairouan, au Centre de la Tunisie et caractérisée par un climat semi aride, contribuent à l'évaluation du potentiel des nouveaux capteurs satellitaires Sentinel-1 (S-1) et Sentinel-2 (S-2) pour la caractérisation des états de surface, spécifiquement l'humidité du sol dans un contexte de gestion durable des ressources en eau et en sol. En effet, ces nouveaux systèmes offrent aujourd'hui des produits opérationnels avec une forte répétitivité temporelle et des résolutions spatiales métriques permettant un suivi régulier. Dans notre contexte, les données radars sont particulièrement sensibles aux conditions de surface, précisément à l'humidité du sol, à la rugosité de surface et à la végétation. Ils se dévoilent comme les outils les plus prometteurs pour un suivi précis à l'échelle de la parcelle ou régionale. Ce travail comprend deux principales parties qui relient directement l'humidité du sol (variable clé pour différents processus) à l'irrigation dans un premier temps, puis à la texture du sol. L'approche adoptée combine les mesures expérimentales à l'utilisation de données de la télédétection multi-capteurs en synergie, ainsi à la modélisation et à la cartographie.

La thèse se structure en trois volets. Le premier volet de ce travail évalue le potentiel des données radars en bande C pour une large base de données. Les résultats ont montré à travers des études du comportement et de modélisation que le signal radar permet de suivre la dynamique temporelle et spatiale de l'humidité du sol sur des parcelles de céréales. Le second volet, consiste à évaluer l'utilisation conjointe de données optiques et radars afin de pouvoir prédire l'état hydrique de surface sur une couverture végétale. Avec une précision de l'ordre de 6 vols. %, une cartographie de l'humidité du sol est alors proposée à haute résolution spatiale, en inversant le modèle de rétrodiffusion « Water Cloud Model » (WCM). Ensuite, nos recherches se sont progressivement orientées vers une cartographie des zones irriguées et non-irriguées en utilisant des paramètres statistiques (moyennes et variances) à partir de séries temporelles d'indice de la végétation (Normalized Difference Vegetation Index, NDVI) et des produits d'humidité du sol. La cartographie des zones irriguées s'est

---

basée sur des algorithmes de classification, qui ont permis de déduire que l'humidité du sol était le meilleur indicateur pour l'irrigation avec une précision globale de 77%. Le troisième volet de la thèse repose sur un deuxième produit dérivé également de l'humidité du sol et des données du moyen infrarouge dérivé des images S-2: la teneur en argile du sol. Des algorithmes de classifications tels que les Random Forest (RF) ou les Support Vector Machine (SVM) ont permis de prédire des classes de texture du sol sur toute la zone d'étude. Les résultats de cette étude ont permis de comparer la performance des algorithmes et la pertinence des indicateurs utilisés.

Les résultats obtenus au cours de ce travail mettent en évidence l'intérêt des données multi-capteurs et la pertinence des informations satellitaires pour le suivi des surfaces dédiées à l'agriculture, offrant la possibilité de les appliquer dans des modèles de prévision agricole pour différents usages.

**Mots clés :** Etats de surface, humidité du sol, télédétection, radar, optique, modélisation, synergies de données.

---

## Abstract

Agriculture is considered as one of the most important sectors in Tunisia on which the country's economy is predominately based. It is also important because of its contribution to food security. In the context of natural resource management, the characterization and monitoring of surface states is essential, particularly in semi-arid regions where several constraints hamper agricultural development (period of drought, conflicts over water sharing, lack of resources, overpumping of groundwater, etc.). In Tunisia, nearly 80% of available water resources are used by agriculture with limited efficiency. Here, with very limited water resources, the estimation of the surface water state is necessary to establish the appropriate decisions for a better sustainable management. In this context, remote sensing provides a fundamental database for surface observation. It is a major tool for remote sensing data acquisition.

The work carried out during this thesis contributes to evaluate the potential of the new Sentinel-1 (S-1) and Sentinel-2 (S-2) satellite for the characterization of surface states, specifically soil moisture in a context of sustainable management of water and soil resources. Indeed, these new systems offer operational products with a high temporal repeatability and metric spatial resolutions allowing regular monitoring. In our context, radar data is particularly sensitive to surface conditions, specifically soil moisture, surface roughness and vegetation cover. They are unveiled as the most promising tools for accurate monitoring at the field or regional scale. This work includes two main parts that directly relate soil moisture (key variable for different processes) to irrigation first, and then to soil texture. The approach adopted combines experimental measurements with the use of different remote sensing data in synergy, modeling and mapping.

The thesis is structured in three parts. The first part of this work evaluates the potential of C-band radar data for a large database. The results showed through behavioral and modeling studies that the radar signal could retrieve temporal and spatial dynamics of soil moisture on cereal plots. The second component consists of evaluating the combined use of optical and radar data in order to predict surface water conditions over vegetative cover. With a precision of about 6 vol. %, soil moisture mapping is then proposed at high spatial resolution, by inverting the Water Cloud Model (WCM), a backscattering model for vegetation cover. Then, our research progressively moved towards a mapping of irrigated and non-irrigated areas using statistical parameters (means and variances) from time series of vegetation index (Normalized Difference Vegetation Index, NDVI) and soil moisture products. The mapping of irrigated areas was based on classification algorithms, which led to the conclusion that soil moisture was the most performed indicator for irrigation with an overall accuracy of 77 %. The third part of the thesis is based on a second product also derived from soil moisture and mid-infrared band derived from S-2: the clay content of the soil. Classification algorithms such as Random Forest (RF) or Support Vector Machine (SVM) have predicted soil texture classes across the study area. The results of

---

this study allowed comparing the performance of the algorithms and the relevance of the indicators used.

The results obtained during this work highlight the interest of multi-sensor data and the relevance of satellite information for monitoring areas dedicated to agriculture, offering the possibility of applying them in agricultural forecasting models for different uses.

**Key words:** Surface states, soil moisture, remote sensing, radar, optic, modeling, data synergies.

## الخلاصة

تعتبر الزراعة في تونس أحد القطاعات المهمة التي يعتمد عليها اقتصاد البلاد. كما أنه مهم بسبب مساهمته في الأمن الغذائي. في سياق إدارة الموارد الطبيعية يعتبر توصيف الظروف السطحية ورصدها أمراً ضرورياً لا سيما في المناطق شبه القاحلة حيث تعوق العديد من القيود التنمية الزراعية (فترة الجفاف، والصراعات على تقاسم المياه، ونقص الموارد، والإفراط في استغلال المياه الجوفية، وما إلى ذلك). في تونس، تستخدم الزراعة ما يقرب 80 ٪ من موارد المياه المتاحة بكفاءة محدودة. هنا، حيث تكون موارد المياه محدودة للغاية، يعد تقدير حالة المياه السطحية ضرورياً بشكل خاص لوضع القرارات المناسبة لإدارة أفضل لهذا المورد. في هذا السياق، يوفر الاستشعار عن بُعد قاعدة بيانات أساسية لمراقبة السطح، وهو أداة رئيسية لاكتساب المعلومات عن بُعد.

إن العمل المنجز خلال هذه الأطروحة على سهل القيروان في وسط البلاد التونسية والذي يتميز بمناخ شبه جاف، يساهم في تقييم إمكانيات أجهزة استشعار الأقمار الصناعية الجديدة. لتوصيف الحالات السطحية، وتحديد رطوبة التربة في سياق الإدارة المستدامة للموارد المائية والتربة. في الواقع، تقدم هذه الأنظمة الجديدة الآن منتجات تشغيلية ذات إمكانية تكرار عالية و استبانة مكانية عالية يسمح بمراقبة منتظمة. في سياقنا، بيانات الرادار حساسة بشكل خاص لظروف سطح الأرض، وتحديد رطوبة التربة وخشونة السطح والغطاء النباتي. يتم كشف النفاذ عنها كأكثر الأدوات الواعدة للمراقبة الدقيقة على الأرض أو النطاق الإقليمي. يتضمن هذا العمل جزأين رئيسيين يرتبطان بشكل مباشر برطوبة التربة بالري أولاً، ثم إلى نسيج التربة. يجمع النهج المعتمد بين القياسات التجريبية مع استخدام بيانات الاستشعار عن بُعد متعددة المستشعرات في التأزر والنمذجة ورسم الخرائط.

هذه الأطروحة مبنية على ثلاثة أجزاء. الجزء الأول من هذا العمل يقيم إمكانيات بيانات رادار النطاق C الترددي لقاعدة بيانات كبيرة. أظهرت النتائج من خلال الدراسات السلوكية والنمذجة أن إشارة الرادار يمكنها تتبع الديناميات الزمنية والمكانية لرطوبة التربة على قطع الحبوب. يتكون المكون الثاني من تقييم الاستخدام المشترك للبيانات الضوئية والرادارية من أجل التنبؤ بظروف المياه السطحية على الغطاء النباتي بدقة حوالي 6 vol. ٪ ، يُقترح رسم خرائط لرطوبة التربة بدقة مكانية عالية، مما يؤدي إلى عكس نموذج الارتداد المائي (WCM) Water Cloud Model بعد ذلك، انتقل بحثنا تدريجياً نحو رسم خرائط للمناطق المروية وغير المروية باستخدام المعلمات الإحصائية من السلاسل الزمنية لمؤشر الغطاء النباتي الطبيعي (NDVI) والمنتجات. رطوبة التربة. استندت تخطيط المناطق المروية إلى خوارزميات التصنيف ، مما أدى إلى استنتاج مفاده أن رطوبة التربة كانت أفضل مؤشر للري بدقة 77 ٪. يعتمد الجزء الثالث من الرسالة على منتج ثان مشتق أيضاً من رطوبة التربة وبيانات الأشعة تحت الحمراء المستمدة من صور S-2 وهو المحتوى الطيني للتربة. تنبأت خوارزميات التصنيف مثل Random Forest (RF) أو Support Vector Machine (SVM) بفصول نسيج التربة عبر منطقة الدراسة. مكنت نتائج هذه الدراسة من مقارنة أداء الخوارزميات وأهمية المؤشرات المستخدمة.

تبرز النتائج التي تم الحصول عليها خلال هذا العمل اهتمام بيانات أجهزة الاستشعار المتعددة وأهمية المعلومات الساتلية لمناطق الرصد المخصصة لزراعة مما يتيح إمكانية تطبيقها في نماذج التنبؤ الزراعي لمختلف يستخدم.

**الكلمات المفتاحية:** حالة سطح الأرض ، رطوبة التربة ، الاستشعار عن بعد ، الرادار ، الترددات البصرية ، النمذجة ، تأزر البيانات

# Remerciements

J'ai eu beaucoup de plaisir à écrire ces quelques lignes où j'ai pu remémorer tous les souvenirs de quatre années de thèse avec tous les bons moments passés, et parfois aussi les plus difficiles. La réussite n'est pas une chose facile. Et comme le dit mon père, personne ne réussit dans un domaine qui ne lui plaît pas et que le succès est obtenue par ceux qui essaient et continuent d'essayer.

Ces années de thèse ont été l'une des plus belles aventures de ma vie, une excellente expérience dans le domaine du radar, riche en apprentissage mais également en rencontres, et un aboutissement à de nombreux défis.

Ce travail de longue haleine a nécessité l'aide, le soutien et la collaboration de plusieurs personnes que j'ai eu la chance de rencontrer. C'est alors dans ces quelques lignes que j'exprime ma gratitude envers toutes ces personnes qui ont contribué implicitement ou explicitement à l'ensemble de ce travail.

Ainsi, mes plus vifs remerciements sont dédiés à mon directeur de thèse M. Mehrez Zribi et ma co-directrice Mme Zohra Lili Chabaane pour la confiance et le soutien qu'ils m'ont accordés et pour l'opportunité de pouvoir travailler au sein de cette équipe. Ils m'ont permis d'aller jusqu'au bout, malgré parfois le travail à distance. Leur disponibilité, leurs conseils et leur grande expérience scientifique ont apporté des valeurs sûres à ce travail. Je tiens également à exprimer mon admiration pour leurs qualités humaines, leur gentillesse et leur dévouement.

Je suis très honorée que les différents membres du jury aient accepté d'être les rapporteurs et les examinateurs de mon travail de thèse. Je les remercie vivement pour le temps qu'ils ont consacré à la lecture et l'évaluation de mon manuscrit.

Ces travaux de thèse sont le fruit d'une collaboration entre l'Institut National Agronomique de Tunisie (INAT) et le CESBIO. Je remercie M. Laurent Polidori pour les accueils toujours chaleureux lors de mes séjours à Toulouse, ainsi que M. Fayçal Ben Jeddi, directeur de l'INAT.

Mes remerciements vont aussi aux membres des comités de thèse: M. Hamadi Habaied et M. Nicolas Baghdadi qui ont suivi mes travaux durant ces quatre années pour évaluer et enrichir ce sujet de thèse.

Par ailleurs, je tiens à remercier l'ensemble de tous nos collaborateurs : M. Nicolas Baghdadi, M. Mohammad El-Hajj, M. Hassen Bazzi, Mme Nadhira Ben Aissa, Vos remarques, commentaires et suggestions m'ont permis d'avoir un nouveau regard sur l'ensemble de mes publications scientifiques. Je tiens à remercier particulièrement M. Gilles Boulet pour mon initiation à la recherche, M. Bernard Mougnot pour nos longues discussions et son incroyable expérience sur le terrain, M. Hassan Ayari, M. Gaspard Nougaret et M. Mohamed Jeridi qui ont rendu les campagnes sur le terrain si agréables, Mme Charlotte Pelletier pour tous les Week-end qu'on a passé à travailler ensemble en décalage horaire.

Je remercie également tout le personnel de l'INAT, l'IRD et le CESBIO : Mme Zeineb Kassouk, Mme Aicha Chahbi, Mme Azza Gorrab, M. Pascal Fanise, Mme

Dominique Tarrise, Mme Laurence Keppel, Mme Valérie Le Dantec, M. Olivier Pringaut Mme Anne-Marie Ouertani, Mme Rim Ouannes, M. Walid Braiki et M. Ahmed Messouaf.

Sans oublier mes compagnons de route : Ma très chère Wafa Chebbi, Amal Sebai, Nesrine Ferhani, Sameh Saadi, Nissaf Boudhina, Raja Mabrouki, Hayfa Zayani, Fajr Fradi, Ghofrane Dridi, Ons Mustapha, Abdel Hakim Amazirh, Bouchra Ait hssaine, Luis Enrique Olivera, Nitu Ojha. La thèse est aussi une grande aventure humaine, merci à tous mes amis et collègues. Votre présence a permis de fêter les réussites, mais aussi d'adoucir les périodes les plus difficiles.

Je vais finalement conclure en exprimant toute ma gratitude à ma famille, en particulier mon père, ma mère, mon frère, ma sœur et mon époux. Merci pour vos encouragements, votre enthousiasme et surtout votre soutien dans l'ensemble de mes choix professionnels, mais également personnels. Votre bienveillance et votre optimisme ont grandement contribué à l'accomplissement et la réussite de ces travaux. Je compte encore sur vous pour les prochaines aventures.



# Table de matière

<b>INTRODUCTION GENERALE.....</b>	<b>16</b>
CONTEXTE SCIENTIFIQUE ET PROBLEMATIQUE DE RECHERCHE.....	17
OBJECTIFS ET AXES DE RECHERCHE.....	19
<b>CHAPITRE 1: ETATS DE SURFACE ET TELEDETECTION .....</b>	<b>23</b>
2.1 LES ETATS DE SURFACE : L'ETAT HYDRIQUE DE SURFACE.....	24
2.1.1 <i>Définition du terme « Humidité du sol »</i> .....	24
2.1.2 <i>Processus liés à l'humidité du sol</i> .....	24
2.1.2.1 Les processus météorologiques .....	25
2.1.2.2 Les processus climatiques .....	26
2.1.2.3 La gestion des catastrophes naturelles (suivi et prévision des sécheresses et inondations) .....	27
2.1.2.4 Les processus hydrologiques.....	28
2.1.2.5 Les processus agronomiques .....	28
2.1.3 <i>Estimation de l'humidité du sol</i> .....	29
2.1.3.1 Les mesures ponctuelles de l'humidité du sol.....	29
2.1.3.2 Les mesures directes de l'humidité du sol par satellites.....	30
2.2 APPORT DE LA TELEDETECTION POUR L'ESTIMATION DE L'ETAT HYDRIQUE DE SURFACE .....	30
2.2.1 <i>Bref historique de la télédétection</i> .....	31
2.2.2 <i>Potentiel des données optiques pour le suivi de l'état hydrique de surface</i> .....	31
2.2.3 <i>Potentiel des données micro-ondes pour le suivi de l'état hydrique de surface</i> .....	32
2.2.3.1 Principe de l'outil RSO .....	32
2.2.3.2 Modélisations de la rétrodiffusion et approches d'inversions .....	34
<b>CHAPITRE 2: SITE D'ETUDE ET BASE DE DONNEES.....</b>	<b>46</b>
2.1. SITE D'ETUDE : LA PLAINE DE KAIROUAN .....	47
2.1.1. <i>Situation géographique</i> .....	47
2.1.2. <i>Contexte climatique</i> .....	48
2.1.2.1. Pluviométrie .....	48
2.1.2.2. Température .....	50
2.1.3. <i>Contexte hydrique</i> .....	51
2.1.4. <i>Nature des sols</i> .....	52
2.1.5. <i>Occupation des sols et pratiques agricoles</i> .....	52
2.2. LA BASE DE DONNEES.....	54
2.2.1. <i>Données satellitaires</i> .....	55
2.2.1.1. Données radars .....	55
2.2.1.2. Données optiques.....	60
2.2.1.3. Comparaison entre les images Landsat-8 et les images Sentinel-2.....	64
2.2.2. <i>Campagnes expérimentales et mesures sur le terrain</i> .....	64
2.2.2.1. Paramètres du sol.....	65
2.2.2.2. Paramètres de la végétation .....	68
2.2.2.3. Collecte de données sur l'irrigation.....	70
2.2.2.4. Stations agro-météorologiques et stations de mesures de l'humidité du sol .....	71
2.3. CONCLUSION PARTIELLE .....	72
<b>CHAPITRE 3: ANALYSES DE SENSIBILITE ET MODELISATION DE LA RETRODIFFUSION.....</b>	<b>73</b>
3.1. INTRODUCTION .....	74
3.2. ANALYSES DE SENSIBILITE ET COMPORTEMENT DU SIGNAL RADAR .....	74
3.3. MODELISATION DE LA RETRODIFFUSION .....	75
3.3.1. <i>Modélisation sur sols nus</i> .....	75
3.3.2. <i>Modélisation sur un couvert végétal</i> .....	76
3.4. ARTICLE .....	77
3.5. ANALYSES SUPPLEMENTAIRES ET RESULTATS NON-PUBLIES .....	85
3.5.1. <i>Analyses de sensibilité du signal radar au contenu en eau de la végétation</i> .....	85
3.5.2. <i>Comparaison des résultats de la modélisation sur sols nus avec d'autres approches</i> .....	85

---

3.5.3.	<i>Comparaison des résultats de la modélisation sur la végétation avec d'autres approches</i>	87
3.6.	SYNTHÈSE ET CONCLUSION PARTIELLE.....	88
<b>CHAPITRE 4: ESTIMATION DE L'HUMIDITE DU SOL ET CARTOGRAPHIE DES ZONES IRRIGUEES ET NON-IRRIGUEES.....</b>		<b>90</b>
4.1.	INTRODUCTION .....	91
4.2.	INVERSION DE LA RETRODIFFUSION ET CARTOGRAPHIE DE L'HUMIDITE DU SOL.....	92
4.3.	CARTOGRAPHIE DES ZONES IRRIGUEES ET NON-IRRIGUEES .....	92
4.4.	ARTICLE .....	92
4.5.	SYNTHESE ET CONCLUSION PARTIELLE.....	113
<b>CHAPITRE 5: ESTIMATION DE LA TEXTURE DU SOL .....</b>		<b>114</b>
5.1.	INTRODUCTION .....	115
5.2.	METHODOLOGIE.....	115
5.3.	ARTICLE .....	116
5.4.	SYNTHÈSE ET CONCLUSION PARTIELLE.....	136
<b>CONCLUSION GENERALE ET PERSPECTIVES.....</b>		<b>137</b>
	SYNTHESE ET CONCLUSION.....	138
	PERSPECTIVES .....	139
<b>RÉFÉRENCES .....</b>		<b>143</b>

# Liste des figures

## **INTROCUCTION**

<b>FIGURE 1 :</b> CARTE DE LA REPARTITION MONDIALE DE L'ARIDITE, PREPAREE EN UTILISANT LES DONNEES SPATIALES DE PNUE–WCMC (2007) (SOURCE: FAO, 2019).....	18
---	----

## **CHAPITRE 1. ETATS DE SURFACE ET TELEDETECTION**

<b>FIGURE 1. 1:</b> HISTORIQUE DES CAPTEURS RADAR DE 1991 JUSQU'À 2020 (SOURCE : UNAVCO, 2018) .....	34
--	----

## **CHAPITRE 2. SITE D'ETUDE ET BASE DE DONNEES**

<b>FIGURE 2. 1:</b> LOCALISATION DU GOUVERNERAT DE KAIROUAN, AU CENTRE DE LA TUNISIE .....	48
<b>FIGURE 2. 2:</b> VARIATION INTERANNUELLE DE LA PLUVIOMETRIE DE LA PLAINE DE KAIROUAN ENTRE LES ANNEES HYDROLOGIQUES 1986 ET 2018 (SOURCE: INM, 2018) .....	49
<b>FIGURE 2. 3:</b> VARIATION MENSUELLE DE LA PLUVIOMETRIE DE LA PLAINE DE KAIROUAN ENTRE LES ANNEES HYDROLOGIQUES 1986 ET 2018 (SOURCE: INM, 2018) .....	49
<b>FIGURE 2. 4:</b> VARIATION MENSUELLE DE LA TEMPERATURE ENTRE DES ANNEES 1986 ET 2018 DE LA PLAINE DE KAIROUAN (SOURCE: INM) .....	50
<b>FIGURE 2. 5:</b> CARTE DES OCCUPATIONS DES SOLS DE LA PLAINE DE KAIROUAN POUR L'ANNEE AGRICOLE 2016-2017 (SOURCE: KASSOUK, 2017) .....	53
<b>FIGURE 2. 6:</b> LES QUATRES MODES D'ACQUISITIONS DU CAPTEUR SENTINEL-1: SM, IW, EW ET WV (SOURCE : ESA, 2018) ..	57
<b>FIGURE 2. 7:</b> DIFFERENCE ENTRE: A) UNE IMAGE OPTIQUE ISSUE D'UNE BANDE SPETRALE DU CAPTEUR S-2 ET B) UNE IMAGE RADAR ISSUE DU CAPTEUR S-1, SELON LA MEME RESOLUTION SPATIALE (10 M .....	63
<b>FIGURE 2. 8:</b> COMPARAISON ENTRE LE NDVI DERIVE DES IMAGES S-2 ET LE NDVI DERIVE DES IMAGES L-8.....	64
<b>FIGURE 2. 9:</b> LOCALISATION DES PARCELLES DE REFERENCE (DE SOL NU ET DE CEREALE) SUR LA PLAINE DE KAIROUAN.....	65
<b>FIGURE 2. 10:</b> UN THETAPROBE ML2X POUR LA MESURE DE L'HUMIDITE DU SOL .....	67
<b>FIGURE 2. 11:</b> EXEMPLE DE PROFIL DE RUGOSITE ELABLORE PAR UN RUGOSIMETRE DE 1 M: A) POUR DES SOLS LISSES ET B) DES SOLS EN LABOUR .....	68
<b>FIGURE 2. 12:</b> PHOTOS HEMISPHERIQUES POUR DES MEASURES DE LAI: A) LORS DU SEMIS ET B) LORS L'ÉPIAISON.....	69
<b>FIGURE 2. 13:</b> RELATION ENTRE LA HAUTEUR DE LA VEGETATION, LE CONTENU EN EAU ET LE LAI ETABLIE SUR LES PARCELLES DE REFERENCE.....	70
<b>FIGURE 2. 14:</b> A) LA STATION DE MEASURE DE L'HUMIDITE DU SOL ET B) LA STATION METEOROLOGIQUE INGC, IMPLEMENTEES SUR LA PLAINE DE KAIROUAN .....	71

## **CHAPITRE 3. ANALYSES DE SENSIBILITE ET MODELISATION DE LA RETRODIFFUSION**

<b>FIGURE 3. 1:</b> LE COEFFICIENT DE RETRODIFFUSION (S1) EN dB EN FONCTION DU CONTENU EN EAU DE LA VEGETATION : A) POUR LA POLARISATION VV ET B) POUR LA POLARISATION VH .....	85
<b>FIGURE 3. 2:</b> SIMULATION DU SIGNAL RADAR PAR: A) LE MODELE IEM SELON LA POLARISATION VV; B) LE MODELE IEM SELON LA POLARISATION VH; A) LE MODELE DUBOIS SELON LA POLARISATION VV ET A) LE MODELE DUBOIS SELON LA POLARISATION VH.....	86
<b>FIGURE 3. 3:</b> LES COEFFICIENTS DE RETRODIFFUSION OBSERVES A PARTIR D'IMAGES S-1 PAR RAPPORT AUX VALEURS DE RETRODIFFUSION MODELISEES A PARTIR DE WCM : A,B) POUR LA PHASE CALIBRATION ET C,D) POUR LA PHASE VALIDATION (SOURCE : BAGHDADI ET AL., 2017) .....	88

## Liste des tableaux

### **CHAPITRE 1. ETATS DE SURFACE ET TELEDETECTION**

<b>TABLEAU 1. 1:</b> LES PRINCIPALES BANDES DE FREQUENCE EN TELEDETECTION RADAR LES PLUS UTILISEES EN AGRICULTURE.....	33
--	----

### **CHAPITRE 2. SITE D'ETUDE ET BASE DE DONNEES**

<b>TABLEAU 2. 1:</b> CARACTERISTIQUES DU CAPTEUR RADAR SENTINEL-1 .....	56
---	----

<b>TABLEAU 2. 2:</b> DATES D'ACQUISITION ET CONFIGURATIONS DES IMAGES RADAR S-1A ET S-1B ENTRE LES DEUX ANNEES AGRICOLES 2015-2016 ET 2016-2017 .....	57
---	----

<b>TABLEAU 2. 3:</b> CARACTERISTIQUES DES BANDES SPECTRALES DU CAPTEUR SENTINEL-2 .....	61
---	----

<b>TABLEAU 2. 4:</b> BREVE DESCRIPTION DES PARCELLES DE REFERENCE SELECTIONNEES SUR LES DEUX ANNEES AGRICOLES 2015-2016 ET 2016-2017 .....	65
--	----

# Préface

Cette thèse a été réalisée dans le cadre d'une cotutelle internationale entre l'Université Toulouse 3 Paul Sabatier (UPS), sous la direction de M. Mehrez Zribi Directeur de recherche au Centre National de la Recherche Scientifique (CNRS), et l'Université de Carthage (UCAR)/Institut National d'Agronomie de Tunisie (INAT), sous la direction de Mme Zohra Lili Chabaane, Professeure à l'INAT, dans le cadre d'une collaboration entre l'Institut National Agronomique de Tunisie et le Centre d'Etudes Spatiales de BIOSphère (CESBIO).

L'étude avait été réalisée dans le cadre de plusieurs projets dédiés au suivi de l'évolution des ressources en eau dans le bassin du Merguellil (plaine de Kairouan, centre de la Tunisie), et fondés sur le couplage entre télédétection, modélisation de la surface terrestre et observations in situ :

- Le projet ANR/AMETHYST (2013-2017) : Évaluation de l'évolution des ressources hydroélectriques méditerranéennes dans le sud: Trajectoires de bassins hydrographiques: Développement conjoint des ressources en eau et des utilisations en Méditerranée, coordonné par M. Mehrez Zribi ;

- Le projet PHC Maghreb 14 MAG 22 (2014-2016) coordonné du côté tunisien par Mme Zohra Lili Chabaane (INAT) et du côté français par Mme Valérie Ledantec (UPS) ;

- Le projet ERANET-MED CHAAMS (2018-2021) : Global Change : Assessment and adaptation to mediterranean Region Water Scarcity, coordonné par M. Lionel Jarlan, Mme Hedia Chakroun et M. Mehrez Zribi ;

- Le projet H2020 ACCWA (2019): Accounting for Climate Change in Water and Agriculture management, coordonné par Mme Maria José Escorihuela et Mme Zohra Lili Chabaane ;

Cette thèse a aussi bénéficié d'une année de financement (2017-2018) par l'Institut de Recherche pour le Développement (IRD), des compléments de bourses par le laboratoire GREENTEAM, ainsi que des supports de mobilité sur le programme de bourses d'alternance de l'Université de Carthage.

Au cours de la thèse, trois comités de suivi ont eu lieu; M. Hamdi Habaieb (Professeur à l'INAT/Directeur Général du Bureau de la Planification et des Equilibres Hydraulique) et M. Nicolas Baghdadi (Directeur de Recherche à l'Institut National de

Recherche en Sciences et Technologies pour l'environnement et l'agriculture) étaient membres de ces comités.



# Introduction générale

## Contexte scientifique et problématique de recherche


L'eau est une ressource naturelle inestimable pour la terre et les êtres vivants. Sur le globe, elle recouvre près de 71 % de sa surface, soit près de 1400 millions de km<sup>3</sup> de volume total estimé (USGS, 2016). Cette quantité pourrait représenter un chiffre rassurant. Bien entendu, la réalité est tout autre. En 1970, la prise de conscience de la rareté de l'eau, et notamment la mobilisation des ressources hydriques, a commencé à surgir. Les mots tels que « Aridité », « Pénurie » et « Sécheresse » ont pris leur place dans les débats internationaux sur le sujet.

Au cours des derniers siècles, le monde moderne, les dernières technologies, l'homme (en résumé) ont largement contribué au dysfonctionnement de l'équilibre environnemental. Le régime des ressources naturelles a été forcé et transformé à cause de ce déséquilibre. Ceci est induit principalement à la modification durable et irréparable du climat, faisant naître le terme de « changements climatiques ». Modifiant ainsi la composition atmosphérique de la planète, ces changements ont perturbé principalement le cycle naturel de l'eau. Les ressources en eau se voient alors diminuer de plus en plus, outre la demande croissante en eau due à l'augmentation de la population mondiale.

Alors où sommes-nous aujourd'hui ?

Selon la Banque mondiale et la Convention des Nation Unies sur la Lutte Contre la Désertification (UNCCD), d'ici 2050, 1.8 milliard de personnes vivront dans des pays ou régions où la pénurie d'eau sera absolue et les deux tiers de la population mondiale pourraient vivre dans des conditions de stress hydrique. Les statistiques prévoient aussi que les prélèvements de l'eau vont augmenter de 15 % (La Banque Mondiale, 2018). Selon ces rapports, ces organismes soulignent dans leurs principales conclusions que la pénurie d'eau est principalement liée aux changements climatiques, et que si des mesures et des actions ne sont pas prises rapidement, la production agricole va chuter, entraînant des risques de conflits nationaux et internationaux.

Les zones caractérisées par un climat semi-aride à aride, comme les pays de d'Afrique du Nord, sont les plus touchées par ce déficit hydrique croissant sous l'effet conjugué de la croissance démographique (surexploitation et gaspillage) et la diminution des ressources (liée aux changements climatiques). De plus ces zones sont caractérisées par un climat chaud où les périodes de sécheresse sont longues et fréquentes. En 2007, le Programme des Nations Unies pour l'Environnement (PNUE) a permis de détecter ces zones à partir d'un indice d'aridité (IA). Les terres arides sont représentées alors par plus de 41 % de la superficie terrestre (UNEP-WCMC, 2007).



**Figure 1 :** Carte de la répartition mondiale de l'aridité, préparée en utilisant les données spatiales de PNUE–WCMC (2007) (Source: FAO, 2015).

Ces régions sont particulièrement répandues au nord et au centre de l'Afrique, comme le montre la Figure 1. Dans ces régions, la disponibilité de l'eau représente un facteur limitant dans tous les secteurs : industriel, économique, touristique et en particulier dans le secteur agricole. En effet, l'agriculture est très consommatrice en eau et doit faire face à l'augmentation de la production, liée à l'intensification des zones irriguées et aux besoins de la demande. Suite aux développements des systèmes irrigués, les pertes par prélèvements de l'eau destinés à l'irrigation sont de plus en plus croissantes.

Ce facteur contraignant pour le développement durable des régions arides a nécessité la mise en place de différentes stratégies de gestion pour mobiliser les ressources en eau visant la « durabilité » et « l'économie d'eau ». Ces stratégies se sont basées essentiellement sur des actions pour réduire d'abord les pertes d'eau par la mise en place d'aménagements et de structures de conservation. D'autres stratégies se sont focalisées sur des programmes de prise de conscience collective et de mobilisation des différents consommateurs pour anticiper les risques de catastrophes et développer des mesures d'adaptation à ces impacts. Ces mesures reposent notamment sur une meilleure compréhension des processus régissant la distribution de l'eau à l'échelle locale et régionale.

Dans ce contexte de gestion durable des ressources en eau, la caractérisation des états de surface, principalement des propriétés hydriques du sol, représente un enjeu primordial. En effet, l'humidité du sol est un paramètre clé de la répartition des eaux de précipitation entre infiltration, ruissellement et évapotranspiration. Une gestion efficace repose alors sur la connaissance et le suivi de ce paramètre. Le suivi global de l'état hydrique sur la base de mesures ponctuelles régulières sur le terrain n'est pas envisageable, surtout à l'échelle régionale ou globale. Ces méthodes sont beaucoup trop coûteuses et consommatrices de temps. Pour pallier à cet obstacle, l'observation spatiale fournit différentes informations pour la surveillance des terres agricoles, et s'avère être un outil indispensable pour la gestion des problèmes environnementaux. Son intérêt réside en sa

capacité à fournir une vision spatialisée et répétitive à une échelle globale et de façon permanente.

C'est vers les années 90 que la télédétection micro-onde active, précisément les Radars à Synthèse d'Ouverture (RSO) ont été lancés, avec les capteurs ALMAZ (en Mars 1991) et ERS-1 (en Juillet 1991) comme première génération. La télédétection radar a alors montré un fort potentiel pour la caractérisation des états de surface. D'abord, différents travaux ont analysé le potentiel des données multi-configurations (fréquence, polarisation et angle d'incidence) pour le suivi des états de surface (Aubert et al., 2011 ; Holah et al., 2005 ; Zribi et al., 1997). De nouvelles perspectives ont vu le jour avec les nouveaux capteurs RSO grâce à des améliorations au niveau de la résolution spatiale, de la répétitivité temporelle et des modes d'acquisitions tels que les capteurs TerraSAR-X, Cosmo-SkyMED avec des résolutions métriques (Aubert et al., 2013 ; El Hajj et al., 2016 ; Gorrab et al., 2015 ; Anguela et al., 2010). Pour le suivi des états de surface, nous avons besoin d'une estimation correcte des paramètres du sol et de la végétation. Il est donc essentiel d'utiliser les données adéquates qui permettent un suivi régulier. Dans le même temps, les technologies spatiales d'observation de la terre sont arrivées à un niveau de maturité permettant de proposer des applications spatiales à usage des métiers de l'aménagement et de l'environnement.

Avec l'arrivée de la nouvelle famille de capteurs Sentinel, des synergies entre les données ont bouleversé le monde de la recherche, offrant la capacité de fusionner plusieurs types de données pour une estimation plus fine et continue à grande échelle. Le suivi spatial des états de surface va permettre d'aller plus loin dans l'assimilation opérationnelle des produits satellitaires dans différents modèles de simulations.

## Objectifs et axes de recherche

Le potentiel des données radars pour l'estimation des états de surface a été mentionné dans la partie précédente pour la cartographie de différents paramètres liés au sol et à la végétation. Cependant, ces données dépendent des conditions du milieu, et de nombreux défis restent à relever.

Cette section décrit les objectifs abordés dans ce travail, ainsi que l'organisation des différents chapitres est détaillée.

- Objectifs de la thèse

Dans ce cadre de gestion des ressources en eau et en sol, l'objectif général de ce travail est de proposer une stratégie pour l'estimation spatialisée des états de surface. L'état hydrique est particulièrement nécessaire pour une gestion agricole précise. Plusieurs approches ont été développées ces dernières années pour une cartographie de l'humidité du sol avec différents capteurs dans le domaine micro-onde et infrarouge thermique.

Cependant, en dehors des approches globales basées sur des données micro-ondes passives à basse résolution spatiale, rien n'est proposé en mode opérationnel à haute résolution à l'échelle locale ou régionale. Cela est lié particulièrement à l'absence dans le passé de capteurs à forte répétitivité temporelle. En outre, l'accès aux sources de données reste cependant critique pour les gestionnaires et les scientifiques, spécifiquement pour des données à fine résolution spatiale et temporelles continues, compatibles aux besoins

de ces derniers. Avec l'arrivée des nouvelles constellations Sentinel, l'accès aux données d'observation par satellite vit une véritable révolution. Depuis l'année 2015, l'Agence Spatiale Européenne (ESA) a lancé cette mission pour donner libre accès et de manière gratuite à des observations fréquentes et systématiques à de hautes résolutions spatiales de toute la surface terrestre.

Le site d'étude sélectionné est la plaine de Kairouan, située au centre de la Tunisie. Ce site a déjà fait l'objet de plusieurs projets scientifiques autour des problématiques de ressources naturelles et de gestion des catastrophes.

C'est dans ce contexte riche déjà par différents travaux scientifiques sur ce site d'étude et au sein de l'équipe, que ce travail a pris naissance. Cette thèse s'inscrit alors dans le cadre de l'évaluation du potentiel des satellites de la télédétection (avec une approche multi-capteurs) pour la caractérisation des états de surface et une meilleure gestion des ressources en eau et en sol.

Ce travail a donc pour objectifs : 1/ de démontrer l'apport des données Sentinel-1 et Sentinel-2 particulièrement pour la caractérisation de l'état hydrique de surface, un enjeu majeur pour la gestion des ressources en eau à l'échelle de la parcelle dans un contexte semi-aride, 2/ de pouvoir réutiliser ces produits dérivés d'une synergie optique et radar pour la caractérisation des paramètres de surface particulièrement de la texture du sol, détecter l'irrigation et dénouer ainsi les verrous liés à l'utilité et l'apport de ces produits dans différents contextes.

Les approches proposées présentent des améliorations par rapport aux approches existantes en termes d'applications, et qui consiste à générer d'autres produits et fournir des outils pour la gestion des sols et le pilotage de l'irrigation, deux facteurs déterminant pour le cycle de l'eau et pour un bon développement agricole. En effet, l'eau disponible est fortement dépendante de la nature des sols. Ainsi, une bonne gestion et une optimisation de son usage est étroitement liées à l'aptitude et la manière dont le sol absorbe et conserve l'eau. L'évaluation des sols ainsi que l'irrigation a pour principal objectif de prédire également les conditions futures et de lutter contre les inondations ou les sécheresses.

- Axes de recherche

Quatre axes de recherche sont proposés sous forme de problématiques et de résultats, articulés dans ce manuscrit autour des chapitres suivants : 1/ acquisition de la base de données satellitaires et de mesures ponctuelles expérimentales sur le site d'étude, 2/ étude de sensibilité des données satellitaires aux paramètres de surface et modélisation de la rétrodiffusion sur les sols agricoles, 3/ estimation spatialisée de l'humidité du sol et cartographie des zones irriguées et non-irriguées, 4/ cartographie de la texture du sol, précisément des teneurs en argile sur la plaine de Kairouan.

- **Base de données et campagnes de mesure**

Le premier axe est expérimental, propose une revue sur les paramètres de surface et les protocoles de mesures établies sur le terrain. En effet, les mesures effectuées concernent l'humidité du sol, la rugosité et des paramètres de la végétation à savoir l'indice foliaire « LAI », la hauteur du couvert et le contenu en eau de la végétation. Ces mesures *in situ*

sont accompagnées par des acquisitions multi-capteurs (Sentinel-1, Landsat-8 et Sentinel-2). Le traitement des données satellitaires est aussi présenté.

Cette collecte de données a été effectuée sur des parcelles agricoles de céréale et des parcelles de sol nu, au sein d'un village agricole de la plaine de Kairouan. Réaliser une base de données représentative de toutes les conditions physiques possibles de la surface aux différentes configurations radars durant deux saisons agricoles a nécessité un investissement très important.

- **Sensibilité du signal radar aux paramètres de surface et modélisation de la rétrodiffusion**

Afin de modéliser un signal radar, il est indispensable d'étudier le comportement de ce dernier lié aux différents paramètres physiques du milieu (paramètres liés au sol et à la végétation) à travers des analyses de sensibilité. Cette étude va permettre de réaliser une première estimation du potentiel de discrimination de la rugosité, de l'humidité et du couvert végétal. L'analyse servira aussi à définir des seuils pour lesquels le modèle de rétrodiffusion utilisé n'arrive plus à reproduire correctement des simulations proches de la réalité. Dans un second temps, il est nécessaire de disposer d'un modèle approprié selon le site d'étude et les conditions du milieu afin d'inverser correctement le signal et reproduire l'humidité du sol, ce qui représente l'un des objectifs principaux de ce travail. Pour ce faire, des étapes de calibration et de validation sur le site d'étude sont primordiales pour la réalisation de l'inversion.

Ce chapitre est centré dans un article scientifique publié dans le journal *Sensors*, intitulé « Potentiel of Sentinel-1 radar data for the assessment of soil and cereal cover parameters ».

- **Estimation de l'humidité du sol et cartographie des zones irriguées et non-irriguées**

L'estimation des paramètres physiques tels que l'humidité du sol et la cartographie des zones irriguées et non-irriguées, à partir de données radars (Sentinel-1) et des données optiques (Sentinel-2), représentent des enjeux essentiels dans les processus hydrologiques de surface, agronomiques et climatiques. Une approche d'inversion directe d'un modèle semi-empirique est proposée. Afin de prouver la robustesse des paramètres estimés et valider cette approche, une comparaison a été établie avec une autre méthode basée sur la technique des réseaux de neurones.

Les premiers produits de cette modélisation sont des cartes d'humidité du sol à haute résolution spatiale, élaborés à chaque acquisition radar sur toute la plaine de Kairouan. Une série temporelle de ces produits est alors constituée et utilisée par la suite pour détecter les zones irriguées. Un processus de classification est développé pour distinguer entre les zones irriguées et pluviales en comparant les produits optiques et radars utilisés comme entrée dans ces algorithmes.

Cette approche est présentée à travers l'article publié et intitulé : « Soil moisture and irrigation mapping in a semi-arid region, based on the synergetic use of Sentinel-1 and Sentinel-2 data ».

- **Cartographie de la texture du sol**

Ce chapitre est dédié à la caractérisation de la texture du sol à travers la cartographie de la teneur en argile. En effet la teneur en argile est l'une des propriétés les plus importantes du sol. Cependant, peu d'études scientifiques se sont intéressées à la cartographie de la texture du sol en utilisant des données radars. De plus, sur la plaine de Kairouan, les cartes existantes ne sont ni exhaustives ni suffisamment précises pour des modélisations agronomiques et hydrologiques. L'objectif à travers de ce chapitre est de comparer la sensibilité des données optiques et radars pour restituer la teneur en argile du sol. En outre, ce travail tend à relier les données en bandes moyen-infrarouge et l'humidité du sol aux fractions de sable et d'argile. Les relations établies, des algorithmes de classification ont été mis en place pour la cartographie des classes d'argiles. Tout les détails de la méthodologie utilisée sont développés dans l'article « Soil texture estimations using radar and optical Sentinel-1 and Sentinel-2 data ».

Le dernier chapitre présentera la conclusion générale de ce travail, qui sera axée sur les méthodes utilisées et les principaux résultats des différentes approches proposées. Les perspectives sont également discutées.

# Chapitre 1: Etats de surface et télédétection

*Le chapitre suivant décrit l'état de l'art. Il va permettre de passer en revue les bases du travail et les différentes méthodologies existantes dans la littérature ainsi que les études récentes et les thématiques innovantes, liées à ce travail.*

*Dans ce cas d'étude, ce chapitre fera une brève description des états de surface, particulièrement l'état hydrique du sol et décrira le rôle de la télédétection pour estimer ce paramètre à travers différentes approches. A travers ceci, le processus évolutif de chaque méthode est décrit avec les différentes améliorations apportées afin de retracer les progressions constatées au cours du temps.*

## Sommaire

---

<b>CHAPITRE 1: ETATS DE SURFACE ET TELEDETECTION .....</b>	<b>23</b>
1.1 LES ETATS DE SURFACE : L'ETAT HYDRIQUE DE SURFACE .....	24
1.1.1 Définition du terme « Humidité du sol » .....	24
1.1.2 Processus liés à l'humidité du sol .....	24
1.1.2.1 Les processus météorologiques .....	25
1.1.2.2 Les processus climatiques .....	26
1.1.2.3 La gestion des catastrophes naturelles (suivi et prévision des sécheresses et inondations) .....	27
1.1.2.4 Les processus hydrologiques .....	28
1.1.2.5 Les processus agronomiques .....	28
1.1.3 Estimation de l'humidité du sol .....	29
1.1.3.1 Les mesures ponctuelles de l'humidité du sol .....	29
1.1.3.2 Les mesures directes de l'humidité du sol par satellites .....	30
1.2 APPORT DE LA TELEDETECTION POUR L'ESTIMATION DE L'ETAT HYDRIQUE DE SURFACE .....	30
1.2.1 Bref historique de la télédétection .....	31
1.2.2 Potentiel des données optiques pour le suivi de l'état hydrique de surface .....	31
1.2.3 Potentiel des données micro-ondes pour le suivi de l'état hydrique de surface .....	32
1.2.3.1 Principe de l'outil RSO .....	32
1.2.3.2 Modélisations de la rétrodiffusion et approches d'inversions .....	34

---

## 1.1 Les états de surface : l'état hydrique de surface

### 1.1.1 Définition du terme « Humidité du sol »

Le terme humidité du sol (ou de surface) se rapporte à la quantité d'eau disponible dans les premiers centimètres (0 à 5 cm) du sol, stockée dans la zone non saturée et se distingue de l'humidité dans la zone racinaire qui atteint plusieurs mètres de profondeur. Cette variable géophysique joue un rôle fondamental dans le cycle de l'eau et les différents processus hydrologiques (ruissellement, infiltration et érosion), agronomiques (rendements et production), biophysiques (développement des cultures), météorologiques (précipitations et sécheresse) et les échanges sol-plante-atmosphère (évaporation, transpiration et bilan d'énergie).

L'humidité du sol est alors gouvernée par les apports d'eau naturels ou contrôlés (par les précipitations ou par l'irrigation), ce qui provoque une augmentation du ruissellement et donc une saturation du sol. Ces valeurs maximales d'humidité demeurent constantes durant les premiers jours, conformément à la nature du sol, sa porosité ou aux pratiques agricoles. La teneur en eau d'un sol peut atteindre des valeurs minimales et se rapprocher de zéro, dans le cas des sols extrêmement secs et des valeurs maximales correspondant à la capacité au champ.

L'humidité du sol va donc dépendre de plusieurs composantes comme la texture du sol (composante principale de cette dernière) qui aura une influence directe sur la capacité de rétention en eau plus faible que les sols à texture argileuse. Elle dépendra aussi du sol s'il est couvert ou non par la végétation, ceci influencera les échanges entre la plante, le sol et l'atmosphère par les processus de l'évaporation et de la transpiration. D'autres facteurs conditionnent l'humidité du sol tel que les conditions météorologiques (température, vent et précipitation) et les pratiques agricoles particulièrement en ce qui concerne le type de labour et l'irrigation.

Malgré sa faible quantité, l'humidité du sol joue un rôle très important dans le contrôle et la régulation de l'interaction entre la surface du sol et l'atmosphère. La quantification de l'humidité du sol peut ouvrir un tout nouveau spectre d'interprétation et d'analyse de données, ce qui permettra une modélisation précise des différents processus hydrologiques, agronomiques ou météorologiques.

### 1.1.2 Processus liés à l'humidité du sol

Les échanges d'eau et d'énergie se font principalement par le biais de l'humidité du sol, à l'interface surface-atmosphère. L'humidité du sol est alors contrôlée par les différents apports d'eau augmentant et diminuant sous l'effet du haussement de la température, du drainage et de l'infiltration, de l'irrigation et de la précipitation. Les mobilités de l'eau sont donc régies par les différences d'énergies potentielles afin d'atteindre un certain équilibre. Ces flux d'énergies sont principalement liés à l'évaporation du sol et la transpiration des végétaux, ce qui conditionne les transferts de masse et de chaleur entre la Terre et l'atmosphère.

L'humidité du sol constitue alors une variable d'état fondamentale dans plusieurs disciplines telles que l'hydrologie, l'agronomie, la météorologie et la gestion des

catastrophes naturelles. Une bonne description des processus de surface, c'est-à-dire des échanges entre la surface superficielle et l'atmosphère, est essentielle pour les applications météorologiques ou climatiques par exemple.

### 1.1.2.1 Les processus météorologiques

Les modèles de prévision météorologiques sont conditionnés tant par les variables climatiques que par l'humidité du sol, puisqu'elle participe dans le parcours du cycle de l'eau. En météorologie, l'humidité du sol est importante pour prévoir la température de surface et les précipitations, elle est notamment utilisée comme paramètre dans le bilan hydrique et le bilan d'énergie (Koster et al., 2004 ; Seneviratne et al., 2010 ; Sun et al., 2011). D'autre part, elle influence les variables géophysiques comme l'humidité relative et la température de l'air (Brocca et al., 2017 ; Whan et al., 2015).

Plusieurs études ont montré que l'humidité du sol est fortement liée à la température (Al-Kayssi et al., 1990 ; Cochran, 2010 ; Lakshmi et al., 2003 ; Miralles et al., 2012). Lorsque l'humidité du sol atteint des niveaux élevés accompagnée d'une hausse de température, le taux d'évaporation augmente. Bien que la température croisse au cours de la journée, l'évapotranspiration la maintient en baisse. Des valeurs élevées d'humidité du sol auront tendance à augmenter le point de rosée. La condensation (processus de réchauffement) se produit alors lorsque la température tente de descendre en dessous du point de rosée, la nuit.

Il existe également de fortes corrélations entre l'humidité du sol et les précipitations (Guilod et al., 2015 ; Koster et al., 2016 ; Koster et al., 2004 ; Pellarin et al., 2013 ; Tuttle & Salvucci, 2014). Outre, les précipitations sont très affectées par la variabilité de l'humidité du sol. S'il y a de l'humidité dans l'air en raison de l'évaporation du sol, des systèmes à basse pression condenseront l'humidité et des précipitations se produiront. Si le sol est très sec, il y aura moins d'humidité disponible dans l'air et il est moins probable que des précipitations se produisent.

Il existe plusieurs façons de déduire l'humidité du sol dans une région de prévision. L'une des méthodes consiste à étudier chaque jour les cartes de précipitations sur un laps de temps précis. À partir de ceux-ci, il est possible de déterminer quels endroits ont des sols humides ou secs. D'autres méthodes sont basées sur l'inversion de l'équation du bilan hydrique, utilisant des observations de l'humidité du sol pour estimer directement les précipitations (Brocca et al., 2014). Les mesures de l'humidité du sol sont alors d'une valeur inestimable pour d'innombrables modèles environnementaux (Eltahir, 1998 ; Lorenz et al., 2015 ; Whan et al., 2015).

D'autre part, l'humidité du sol se libère dans l'atmosphère sous l'effet de l'évaporation du sol et de la transpiration de la végétation, qui résulte des processus d'interaction sol-végétation-atmosphère. Cette variable est donc utilisée dans différents modèles Soil Vegetation Atmosphere Transfer (SVAT) (SURface EXternalisée (SURFEX), Interaction Sol-Biosphère-Atmosphère (ISBA), Simple Soil Plant Atmosphere Transfer (SiSPAT), etc.), qui sont généralement couplés avec des modèles météorologiques dans le cadre de prévisions climatiques (Martens et al., 2015 ; Miralles et al., 2011 ; Seneviratne et al., 2006).

En termes globaux annuels, plus de 60% des précipitations sur les terres résultent de l'évapotranspiration des terres, qui résulte (à son tour) des interactions de l'humidité du sol, des plantes et de l'atmosphère (Brocca et al., 2017). Une surveillance opérationnelle constitue une étape importante de l'assimilation des données pour les applications de prévisions numériques au cours du temps. Cependant l'utilisation de ces données pour ce genre d'applications nécessite une représentation spatiale des hétérogénéités pour des estimations à grande échelle. Influencée par les conditions atmosphériques du milieu, elle dépend également des conditions de surface (type de sol, végétation, rugosité de surface, etc.)

D'autre part, l'humidité du sol est l'un des principaux facteurs contrôlant l'évapotranspiration. En effet, la transpiration est le processus physiologique naturel par lequel l'eau stockée sous forme d'humidité du sol est extraite par les racines des plantes, passe à travers leur corps et est évaporée par les stomates de leurs feuilles. Pour l'évaporation, l'eau stockée dans le sol se diffuse dans l'atmosphère sous l'effet de la température. Néanmoins, ces flux sont potentiellement importants car ils modifient le profil d'humidité du sol, agissant sur l'infiltration et les prélèvements racinaires, et déterminent les quantités de remontées capillaires.

### 1.1.2.2 Les processus climatiques

Avec un suivi à long terme, l'humidité du sol donne un aperçu sur des modifications éventuelles du climat. L'effet de serre est par exemple, responsable en grande partie du changement climatique actuel, où les niveaux de la température globale sont de plus en plus élevés du à l'augmentation du dioxyde de carbone (CO<sub>2</sub>). En outre, le cycle global du carbone, la météo et le climat sont fortement influencés par l'humidité du sol. En effet, le sol peut être à la fois une source majeure de CO<sub>2</sub> atmosphérique et un important réservoir de stockage de carbone, l'humidité y jouant un rôle moteur.

En fait, la quantité d'émission de CO<sub>2</sub> du sol est dix fois supérieure à celle des émissions de combustibles fossiles d'origine humaine. Une grande partie du CO<sub>2</sub> généré se diffuse du sol (la respiration du sol) dans l'atmosphère et dans les eaux. La respiration du sol et donc la production de CO<sub>2</sub> est alors affectée par la texture, la température et l'humidité du sol. Par conséquent, ces principaux facteurs jouent un rôle important dans le transport du CO<sub>2</sub> dans l'environnement, leurs mesures est d'une valeur inestimables pour d'innombrables modèles de prévisions climatiques et environnementales (Seneviratne et al., 2010).

Pour les applications climatiques, les interactions entre les variables climatiques, les flux et l'humidité du sol ont fait l'objet de plusieurs études (Bisselink et al., 2011 ; Koster & Suarez, 2001 ; Seneviratne et al., 2010 ; Whan et al., 2015). L'une des tendances futures des changements climatiques est l'intensification du cycle hydrologique. La hausse des températures à long termes augmentera l'évaporation du sol et la transpiration des végétaux, augmentant de ce fait la probabilité de sécheresse, ainsi que des feux de forêts dans certaines régions du globe. Cette intensification du cycle de l'eau touchera principalement les zones semi-arides et arides, où cette évaporation accrue réduira la disponibilité de l'eau et prolongera les périodes de sécheresse. D'autre part, l'augmentation de la vapeur d'eau entraînera des pluies intenses et donc des inondations dans d'autres parties du globe. En moins de 100 ans, l'humidité du sol devrait provoquer

une redistribution globale avec des changements très importants impliquant plusieurs variations (Seneviratne et al., 2010).

### **1.1.2.3 La gestion des catastrophes naturelles (suivi et prévision des sécheresses et inondations)**

D'autre part, l'humidité du sol intervient pour améliorer les prévisions des catastrophes naturelles (sécheresse, inondation, incendies, érosion, etc.). Si les sols sont saturés par les eaux de ruissellements trop importants par exemple, une dégradation des sols peut avoir lieu par érosion ou par lessivage. Vu les ravages que les inondations peuvent provoquer, l'observation et la mesure des eaux contenues dans les sols sont donc essentiels aux études hydrogéologiques. En effet, les inondations sont les catastrophes les plus dangereuses et les plus coûteuses avec d'importants dommages agricoles et économiques. Des hausses de précipitations extrêmes engendrent une saturation des sols, ce qui induit à des inondations. L'humidité du sol est une variable clé dans la répartition des précipitations en infiltration et ruissellement, jouant par conséquent un rôle fondamental dans la prévision des inondations (Massari et al., 2014 ; Temimi et al., 2011 ; Wanders et al., 2014). En effet, le suivi de l'humidité du sol peut atténuer les risques des inondations, notamment à travers les modèles pluie-ruissellement. La disponibilité de mesures d'humidité du sol, également pour une longue période, permet de mettre en œuvre des procédures robustes et fiables pour fournir des directives générales ou des règles permettant une assimilation correcte des données dans les différents modèles hydrologiques et des modèles de prévision.

En ce qui concerne les sécheresses, le phénomène est croissant, il est du au réchauffement climatique planétaire. L'humidité du sol obtenue par satellite peut jouer un rôle multiple dans la gestion des sécheresses en raison de son importance dans le cycle hydrologique globale et sa valeur ajoutée pour l'estimation du début, de la gravité, de la durée et de la fréquence de la sécheresse (Amri et al., 2012 ; Narasimhan and Srinivasan, 2005). L'humidité de surface peut aider également à anticiper un stress hydrique, qui touche principalement les rendements et les productions.

L'humidité du sol est alors assimilée dans des modèles pour améliorer la surveillance de la sécheresse agricole. Elle est notamment utilisée en tant qu'outil pour les prises de décisions et en tant que source d'informations pour lutter contre cette catastrophe. Par exemple, inverser l'équation du bilan hydrique pour estimer et valider les quantités de précipitations via des observations satellites de l'humidité du sol est une approche prometteuse pour tenter de combler les déficits pluviométriques critiques en début de saison. En outre, le suivi de la sécheresse agricole nécessite des informations sur la réponse des cultures (par exemple, via des indices de végétation dérivés de satellites) avant et pendant la saison agricole. Les travaux de Qiu et al. (2014) soulignent l'importance de l'humidité de surface pour surveiller la sécheresse, utilisant l'indice SWI « Soil Water Index » et démontrent que l'humidité superficielle mesurée à l'aide de données micro-ondes (à 5 cm de profondeur) peut tout aussi être utilisée pour des applications de surveillance de la sécheresse, comparée à l'humidité mesurée en profondeur (entre 0 et 60 cm). Paredes-trejo et Barbosa (2017) ont basé leurs prévisions de la sécheresse sur des séries historiques du SWDI « Soil Water Deficit Index », un indice uniquement dépendant de l'humidité du sol et de la profondeur du sol.

#### 1.1.2.4 Les processus hydrologiques

La gestion des bassins versants nécessite la mise au point de stratégies pour la préservation de la quantité d'eau et la gestion des apports d'eau et des problèmes de recharge. La connaissance de la distribution spatiale de l'humidité du sol est un préalable indispensable à la modélisation de nombreux processus hydrologiques et dans la partition de l'eau en infiltration et ruissellement, et donc dans la prévision des inondations et des érosions. L'assimilation de l'humidité de surface dans des modèles hydrologiques est utile pour diverses applications (Lievens et al., 2015). Les mesures de ce paramètre sont utilisées afin d'améliorer les prévisions des modèles de ruissellement et les modèles pluie-ruissellement à l'échelle du bassin versant (Brocca et al., 2010 ; Trambly et al., 2010). D'autres applications comme la prévision des crues bénéficient aussi de prévisions améliorées grâce à l'assimilation de l'humidité de surface (Massari et al., 2014). L'humidité du sol sert de substitut à la quantité d'eau en excès et en déficit car elle partitionne la précipitation entre infiltration, ruissellement et évapotranspiration (Seneviratne et al., 2010).

Les observations d'humidité du sol jouent un rôle important dans l'atténuation de nombreux risques naturels autres que les inondations, comme la prévision des glissements de terrain et de l'érosion. Afin de comprendre les causes de l'érosion et de prévoir le moment et le lieu de l'érosion, les hydrologues enregistrent les précipitations, les sédiments et l'humidité du sol. Le taux d'infiltration d'eau dans le sol est alors fonction de son humidité. Si le sol est sec, le taux d'infiltration sera par conséquent suffisant pour empêcher le ruissellement. Un écoulement d'eau en surface peut se produire si la pluie survient à un moment où le sol est saturé. Par conséquent, des glissements de terrain sont obtenus lorsque les conditions de l'humidité du sol sont maximales (Hawke & Mcconchie, 2011 ; Ponziani et al., 2012 ; Todisco et al., 2015).

#### 1.1.2.5 Les processus agronomiques

En agronomie, l'eau dans le sol est un élément déterminant dans le maintien de la vie végétale et dans la production agricole. En effet, cette ressource contribue fortement à la germination et la croissance des cultures, aux rendements accrus avec des produits de meilleure qualité, à la réduction des maladies et la lutte contre les ravageurs. Dans ces diverses applications, elle est utilisée pour la prévision des rendements agricoles, et la détection et le pilotage de l'irrigation pour la gestion des ressources en eau (Aguilar et al., 2015 ; Helman et al., 2019 ; Lecerf et al., 2019).

En effet, l'efficacité de l'utilisation de l'eau est optimale quand l'irrigation ou l'eau de pluie fournissent à la culture la quantité dont elle a besoin. Surveiller le taux d'humidité du sol revient à optimiser les décisions d'irrigation, car il est effectivement nécessaire d'apporter la quantité d'eau adéquate au moment opportun. Pour optimiser les rendements des cultures et favoriser une récolte de qualité, le dosage en eau est tout aussi important, car au-delà d'un certain seuil la culture peut souffrir d'un stress hydrique qui aura de sévères répercussions sur la production. Un excès d'eau peut provoquer l'asphyxie du sol et perturbe le système racinaire de la plante. Il est donc essentiel de miser sur la valorisation de l'eau avec une diminution des coûts d'irrigation pour une bonne gestion des ressources en eau à l'échelle de la parcelle ou du périmètre irrigué. Pour ce faire, le

suivi de l'humidité du sol est donc déterminant en matière agronomique : en fonction de la texture des sols, la capacité de rétention d'eau peut être déterminée.

L'agriculture consomme énormément d'eau, particulièrement dans les régions où les ressources en eau sont très limitées. L'irrigation peut alors représenter plus de 80 % de l'eau utilisée dans l'agriculture (FAO, 2015). Les avantages de l'optimisation et de la planification de l'irrigation avec des capteurs d'humidité du sol visent l'augmentation du rendement des cultures, la préservation de l'eau, la protection des ressources en eau locales contre le ruissellement, la réduction des coûts énergétiques, la réduction des coûts d'engrais et l'augmentation de la rentabilité des agriculteurs. Plusieurs méthodes sont basées sur le suivi des parcelles agricoles selon la relation entre l'humidité du sol et les paramètres de la végétation (De Wit & Diepen, 2007 ; Liu et al., 2016 ; Zribi et al., 2010).

### 1.1.3 Estimation de l'humidité du sol

#### 1.1.3.1 Les mesures ponctuelles de l'humidité du sol

##### *a. Les mesures gravimétriques*

La mesure par gravimétrie est la méthode la plus classique mais également la plus précise pour déterminer la teneur en eau des sols. Cette méthode consiste à prélever des échantillons du sol et à mesurer leur poids avant et après séchage dans une étuve à 100°C pendant 24 h. Ces mesures sont ensuite utilisées pour calculer une humidité pondérale qui s'exprime selon l'équation suivante :

$$Mv (\%) = \left( \frac{Ph - Ps}{Ps} \right) * 100 \quad (1)$$

Où Ps est le poids du sol sec et Ph le poids du sol humide.

Cette méthode reste la plus précise, néanmoins elle est fastidieuse et très consommatrice en temps et en effort, particulièrement pour un suivi spatio-temporel. Il faut compter plusieurs jours pour l'appliquer sur plusieurs échantillons. Cette méthode est très utilisée, par exemple, pour calibrer d'autres méthodes d'estimations de l'humidité du sol.

##### *b. Les mesures par sonde TDR (Time Domain Reflectometry)*

Les sondes TDR mesurent la vitesse de propagation d'un signal micro-onde le long de guides d'ondes enfoncés dans le sol. Cette vitesse est généralement liée à la permittivité diélectrique du sol qui est liée à la teneur en eau. La méthode capacitive est basée sur les propriétés diélectriques des sols et le contraste entre la permittivité de l'eau et celle des autres constituants (air et particules solides). Cette méthode est très délicate surtout pour la mise en place des sondes.

##### *c. Les mesures par sonde Thetaprobe*

Les mesures par sonde Thetaprobe sont basées sur des changements fréquentiels de signaux émis. Ces changements sont directement liés à la constante diélectrique du sol. Ceux sont des mesures effectuées par une sonde munie de tiges pénétrant dans le sol à une profondeur de l'ordre de 5 cm. La sonde Thetaprobe est conçue pour mesurer une teneur en eau volumétrique du sol, compatible aux méthodes TDR. Le processus est

simple et manuel, il permet d'avoir plusieurs mesures ponctuelles et de gagner beaucoup plus de temps par rapport aux mesures gravimétriques.

### 1.1.3.2 Les mesures directes de l'humidité du sol par satellites

Le suivi de l'humidité du sol est souvent établi avec des mesures *in situ* par des échantillons ou par des sondes. Cependant, un paramètre tel que l'humidité du sol nécessite une observation à grande échelle pour un suivi global régulier. En agriculture par exemple la distribution de l'humidité du sol a un impact sur les terres agricoles puisqu'elle conditionne la disponibilité de l'eau dans le sol, essentielle pour la production végétale (Baghdadi et al., 2008).

Le suivi avec des instruments à bord de satellites permet de pallier à ces difficultés. Ce type d'instruments permet de balayer la couverture mondiale en quelques jours et la surface est alors échantillonnée de façon complète et régulière. Dans un premier temps, le support des observations satellitaires va dépendre du type de capteur. L'humidité de surface peut alors être obtenue par le biais de capteurs optiques. Cependant, ces capteurs sont conditionnés par les phénomènes surfaciques (ombre, pluie, vent, etc.) et ne sont pas donc opérationnels pour un suivi régulier. En outre, les observations optiques ne peuvent pas être acquises en conditions nuageuses ou nocturnes car elles sont sensibles à l'atmosphère terrestre et à différents éléments de la surface tels que la végétation ou les reliefs (Petropoulos et al., 2015).

L'ensemble de ces éléments a incité au développement d'approches plus prometteuses, basées sur les capteurs micro-ondes qui vont permettre d'évaluer l'humidité du sol de façon directe, et qui seront définis dans les sections suivantes. Bien qu'ils ne souffrent pas des mêmes inconvénients que les capteurs optiques (liés aux conditions météorologiques), les capteurs micro-ondes (radars ou radiomètres) peuvent être particulièrement sensibles aux éléments de surface comme la végétation et la rugosité de la surface, en fonction des caractéristiques du capteur. Ils sont aussi fortement liés au contenu en eau dans le sol et dans la végétation (Schmugge et al., 2002). Les capteurs passifs et actifs ont déjà démontré leur capacité à fournir des mesures fiables d'humidité du sol. Les missions satellitaires, spécifiquement dédiés à la mesure de l'humidité du sol ont été développées au cours de la dernière décennie. Les radiomètres tels que SMOS (Soil Moisture and Ocean Salinity) ou SMAP (Soil Moisture Active Passive) ont été lancés par les agences spatiales ESA (Européen Space Agency) et NASA (National Aeronautics and Space Administration) afin de prendre en compte cette variable dans le temps et l'espace. Ces produits offrent des acquisitions tous les 3 jours avec une résolution spatiale entre 40 et 50 km, en bande L (Entekhabi et al., 2010 ; Kerr et al., 2010 ; Wigneron et al., 2001).

## 1.2 Apport de la télédétection pour l'estimation de l'état hydrique de surface

Les données de la télédétection sont de plus en plus utilisées dans les sciences agronomiques, météorologiques et environnementales. Leur intégration dans des programmes opérationnels peut générer des avantages économiques et prévisionnels. Les pressions actuelles sur les ressources en eau devraient augmenter de plus en plus dans un proche avenir et le secteur agricole en bénéficiera si l'utilisation de l'eau peut être ciblée

avec prudence. Des approches pour la surveillance de l'eau dans le sol sont nécessaires à mettre en œuvre. Dans cette section, les outils de la télédétection, précisément les capteurs radars, sont détaillés en raison de leur sensibilité à l'humidité du sol et aux paramètres de surface tels que la rugosité du sol ou la végétation. Les modèles de rétrodiffusion électromagnétique des surfaces sont également décrits afin de pouvoir comprendre le comportement du signal radar et son aptitude à restituer l'état hydrique de surface.

### 1.2.1 **Bref historique de la télédétection**

La télédétection est une approche adaptée pour acquérir des informations sur la surface terrestre à une échelle globale. Elle englobe tout le processus qui consiste à capter et enregistrer l'énergie du rayonnement électromagnétique émis ou réfléchi. Ces informations subissent une chaîne de traitement afin de les rendre utilisables, pour les analyser et les mettre par la suite en application. La télédétection utilise les propriétés du rayonnement électromagnétique pour analyser à distance la surface du sol, de l'océan et de l'atmosphère.

Les premières photographies aériennes ont vu le jour à partir de ballons captifs, vers les années 1859 pour des plans topographiques et hydrographiques. L'arrivée de l'aviation a favorisé le développement de technologies plus sophistiquées avec les différents porteurs (hélicoptères, avions et drones), capteurs (thermiques, optiques, imageurs et micro-ondes, etc.) et instruments de visualisations (caméras). Ce n'est que vers les années 60 que les satellites ont commencé à se développer avec comme premier satellite artificiel dans l'espace Spoutnik 1, suivi de TIROS-1, un satellite météorologique. A partir de ces satellites, la télédétection aura profité grandement avec le développement de différents capteurs mono et multi-bandes pour l'observation de la Terre. Les années 70 sont marquées par le lancement de plusieurs missions et le développement de la télédétection avec les satellites ERTS-1 (Earth Resource Technology Satellite) rebaptisé Landsat-1, suivi de Météosat-I et Landsat-2 pour des applications météorologiques, topographiques et hydrogéologiques. Jusqu'aujourd'hui la télédétection spatiale n'a cessé de se développer avec l'amélioration au niveau de la résolution spatiale des produits, la diversification des capteurs plus perfectionnés et les nouvelles méthodes traitement des données.

La diversité des radars imageurs s'est alors considérablement accrue. Ces techniques révèlent jusqu'aujourd'hui une source d'informations fiables pour la surveillance de la pollution, la prévention des catastrophes naturelles, le suivi des océans, la production agricole, l'aménagement du territoire, etc.

### 1.2.2 **Potentiel des données optiques pour le suivi de l'état hydrique de surface**

Les progrès technologiques en matière de télédétection offrent une alternative pour le suivi de l'humidité du sol à des résolutions temporelles et spatiales très élevées. Depuis les années 70, plusieurs méthodes basées sur les données de la télédétection, ont été mises au point pour étudier cette variable dans différents domaines spectraux allant de l'optique aux hyperfréquences (Albergel et al., 2012 ; Baghdadi et al., 2006 ; Barrett et al., 2009 ; El Hajj et al., 2016 ; Gillies & Carlson, 1995 ; Jackson et al., 1976 ; Le Morvan et al., 2008 ; Saha et al., 2019 ; Sandholt et al., 2002 ; Zhang & Zhou, 2016). En effet, l'humidité du

sol possède une influence importante sur la réflectance spectrale. Dans ces domaines, la température de surface, les indices de végétation, ainsi que l'albédo sont de bons indicateurs de la dynamique de l'humidité du sol (Amazirh et al., 2018 ; Jackson et al., 1976).

D'autres méthodes se sont basées sur des indices dérivés des données de télédétection, utilisant principalement la réflectance : le Basist Wetness Index (BWI) est un indice semi-empirique relié au pourcentage de l'eau à la surface, déterminé à partir des températures de brillance mesurées par le satellite Special Sensor Microwave/Imager (SSM/I) (Basist et al., 1997). Le Perpendicular Drought Index (PDI) est établi à partir des réflectances ETM. Conçu pour le suivi de la sécheresse, cet indice permet notamment la description de la distribution de l'humidité du sol dans le rouge et le proche infrarouge. Le PDI convient plus aux sols nus qu'aux surfaces couvertes par la végétation (Ghulam et al., 2007). Le Normalized Difference Water Index (NDWI) est développé à partir de deux bandes du proche infrarouge (Gao, 1996). Il permet de détecter le stress hydrique, d'évaluer les conditions des cultures et reflète la teneur en humidité dans le sol. Des valeurs NDWI plus élevées indiquent une humidité suffisante, tandis qu'une valeur faible indique un stress hydrique. Le Soil water Index (SWI) est basé sur la relation empirique entre la température de surface et l'indice de végétation NDVI (Potić et al., 2017 ; Weng et al., 2003). Zhang et al. (2014) se sont basés par exemple sur un indice de température de surface (TVDI : Temperature Vegetation Dryness Index) dérivé des produits MODIS pour étudier les variations de la température en fonction de l'humidité du sol. Yang et al. (2015) ont proposé un algorithme basé sur la méthode trapézoïdale pour l'estimation de l'humidité sur des sols couverts par la végétation en utilisant les produits de température de surface du capteur TERRA-MODIS (LST) et des mesures de fraction de couverture (Fc).

Cependant, l'estimation de l'humidité de surface à partir des données optiques et infrarouge thermique reste limitée en raison des effets atmosphériques et des aérosols ; contrairement aux données micro-ondes qui sont indépendantes des conditions météorologiques et fournissent des données de jour comme de nuit.

### **1.2.3 Potentiel des données micro-ondes pour le suivi de l'état hydrique de surface**

Cette thèse est consacrée à l'étude de l'humidité du sol contenue dans les premiers centimètres du sol, soit la profondeur de pénétration moyenne de la mission satellitaire Sentinel-1, dédiée à l'observation de la surface terrestre.

#### **1.2.3.1 Principe de l'outil RSO**


Depuis ces trente dernières années, le RADAR (RADio Detection And Ranging) a conquis le monde de la recherche et le potentiel des données radars a été démontré à travers plusieurs approches comme un outil approprié pour estimer les paramètres de surface (Attema and Ulaby, 1978 ; Baghdadi et al., 2015 ; Gorrab et al., 2015 ; Prévot et al., 1993 ; Wagner et al., 2013 ; Wagner et al., 1999 ; Zribi et al., 2011). Le principe des techniques radars repose sur l'émission d'une onde électromagnétique dans une polarisation et une fréquence bien déterminée. L'onde est alors réfléchiée dans la direction du capteur. Les capteurs radars font alors partie de la télédétection micro-onde active,

puisqu'ils sont dotés d'un émetteur et d'un récepteur. Ils opèrent dans le domaine de fréquence micro-onde du spectre électromagnétique de 0.3 à 300 GHz (Tableau 1.1).

**Tableau 1. 1:** Les principales bandes de fréquence en télédétection radar les plus utilisées en agriculture

Bandes	Longueurs d'onde	Fréquence
Bande Ka	0.75 - 1.13 cm	26.5 – 40 GHz
Bande K	1.13 – 1.67 cm	18 – 26.5 GHz
Bande Ku	1.67 – 2.5 cm	12 - 18 GHz
Bande X	2,5 - 3,75 cm	8-12 GHz
Bande C	3,75 - 7,5 cm	4-8 GHz
Bande S	7,5 - 15 cm	2-4 GHz
Bande L	15 - 30 cm	1-2 GHz
Bande P	30 - 100 cm	300 MHz – 1 GHz

Les premiers capteurs ERS-1 et JERS-1 ont été lancés en 1991 et 1992, respectivement en bandes C et L. Ils sont suivis par RADARSAT, Envisat-ASAR, ALOS, jusqu'aux satellites TerraSAR-X et CosmoSky-Med offrant des produits à très hautes résolutions (quelques mètres). Les missions Sentinel sont la toute nouvelle génération de capteurs radars, mis en orbite en 2014.



**Figure 1. 1:** Historique des capteurs radar de 1991 jusqu'à 2020 (Source : UNAVCO, 2018)

L'utilisation du Radar à Synthèse d'Ouverture (RSO) pour le suivi de la surface terrestre est de plus en plus courante. En effet, les RSO, encore appelés radars imageurs, fournissent des mesures à des échelles très fines, pratiques pour un suivi à l'échelle de la parcelle. Ces systèmes sont alors très sensibles aux propriétés du sol, principalement à l'humidité de surface et à la rugosité du sol. En effet, le signal radar est sensible à la constante diélectrique qui est liée au contenu en eau dans le sol ou dans la végétation. La rugosité du sol conditionne la réflexion de l'onde qui est soit spéculaire (réflexion presque totale) si la surface est lisse, soit diffuse (réflexion dans toutes les directions) lorsque la surface est rugueuse. Les mesures de l'humidité à partir du signal radar reposent alors sur les propriétés diélectriques de l'eau.

Le coefficient de rétrodiffusion ( $\sigma^\circ$ ) est alors la fraction qui décrit la quantité d'énergie rétrodiffusée par rapport à l'énergie incidente émise par le capteur. L'intensité de  $\sigma^\circ$  est une fonction des propriétés physiques et électriques de la cible, ainsi que la longueur d'onde ( $\lambda$ ), la polarisation et l'angle d'incidence ( $\theta$ ) du radar.

### 1.2.3.2 Modélisations de la rétrodiffusion et approches d'inversions

Les modèles de rétrodiffusion se sont développés vers les années 60, pour la compréhension des interactions entre les ondes électromagnétiques et la surface. L'évolution de la technologie RSO a accompagné l'évaluation et la diversification des modèles de rétrodiffusion. Deux approches se distinguent alors selon la nature de la surface :

- Les modèles de sol
- Les modèles de végétation

### **2.2.3.2.1. Modélisation du signal radar sur les sols nus**

La modélisation de la rétrodiffusion permet non seulement d'étudier le comportement du signal radar et les mécanismes physiques de la rétrodiffusion, mais devrait éventuellement permettre de mesurer les variables décrivant les états de surface (humidité du sol, rugosité et présence de végétation) par inversion du signal et restitution des paramètres de surface. Cependant le comportement du signal sur une surface de sol nu est différent de celui d'une surface couverte par la végétation. En effet, indépendamment des propriétés diélectriques (contenu en eau des diffuseurs et humidité du sol) et géophysiques (rugosité, texture du sol, etc.) du milieu, d'autres paramètres interviennent pour modifier les interactions entre l'onde et le milieu.

Pour le cas des sols nus, de nombreux modèles de rétrodiffusion ont été développés, en particulier dans la volonté de comprendre le signal et de démontrer les capacités des capteurs pour une meilleure utilisation de leurs configurations. Se basant sur les analyses physiques et empiriques des données expérimentales, ainsi que sur les paramètres instrumentaux (polarisation, longueur d'onde et incidence), les modèles simulent une rétrodiffusion sur la surface du sol. La pertinence de chaque modèle repose sur son domaine de validité. Ces approches ont été développées, fondées sur des études soit théoriques, soit expérimentales, selon deux catégories : les modèles analytiques ou physiques et les modèles semi-empiriques.

#### **a. Les modèles physiques**

- Les modèles POM (Physical Optics Model) et GOM (Geometrical Optics Model)

Les modèles POM et GOM sont des modèles basés sur les approximations de Kirchhoff et adaptés aux surfaces rugueuses. L'hypothèse de base des modèles de Kirchhoff est de considérer une réflexion sur un plan (tangent) en tout point de la surface (Nieto-Vesperinas and Sanchez-Gil, 1992 ; Papa and Lennon, 1988 ; Ripoll et al., 2001). Le modèle POM est utilisé pour des surfaces moyennement rugueuses, tandis que le modèle GOM n'est validé que sur des surfaces très rugueuses avec un écart-type des hauteurs très important.

Le modèle GOM repose sur l'hypothèse majeure que chaque point de la surface diffuse dans la direction spéculaire (Barrick, 1968). La diffusion est essentiellement due à la réflexion de l'onde par un grand nombre de petites facettes normales à la direction de propagation de l'onde. La phase de l'onde diffusée est alors stationnaire car une seule onde est réfléchi en chaque point. Le rayon de courbure doit aussi être plus grand que la longueur d'onde.

- Les modèles de petites perturbations SPM (Small Perturbation Model)

Le modèle SPM est adapté aux surfaces faiblement rugueuses (les surfaces lisses). Rice (1951) a développé l'expression du champ diffusé pour des surfaces lisses. L'écart type de la variation des hauteurs, paramètre caractéristique de la rugosité, doit être largement inférieure à la longueur d'onde incidente (Dobson and Ulaby, 1986). La méthode est alors contrainte par son domaine de validité très restreint.

- Le modèle IEM (Integral Equation Model) et des différentes versions

Le modèle IEM est le modèle physique le plus utilisé, développé par Fung et al. (1992). Ce modèle décrit le signal en fonction des caractéristiques physiques du sol tel que la constante diélectrique, l'écart type des hauteurs (Hrms), de la fonction d'auto-corrélation ( $\rho$ ) et la longueur de corrélation (L). Il tient compte aussi des paramètres du capteur tels que l'angle d'incidence, la polarisation et la fréquence. C'est l'un des modèles physiques les plus utilisés, vu qu'il couvre une large gamme de validité par rapport aux configurations radars et aux paramètres de surface. Le coefficient de rétrodiffusion est alors exprimé comme suit:

$$\sigma_{pq}^0 = \frac{k^2}{2} e^{-2(k.Hrms.\cos\theta)^2} \sum_{n=1}^{\infty} Hrms^{2n} |I_{pq}^n|^2 \frac{W^n(-2k\sin\theta, 0)}{n!} \quad (2)$$

Où

$$I_{pq}^n = (2 \cdot k \cdot \cos\theta)^n \cdot f_{pq} \cdot e^{-Hrms^2 k^2 \cos^2\theta} + k^n \cdot \cos^n\theta \cdot [F_{pq}(-k\sin\theta, 0) + F_{pq}(k\sin\theta, 0)]/2$$

$$f_{hh} = -2R_h/\cos\theta$$

$$f_{vv} = -2R_v/\cos\theta$$

$R_h, R_v$  sont les coefficients de Fresnel

$$R_h = \frac{\varepsilon \cos\theta - \sqrt{\varepsilon - \sin^2\theta}}{\varepsilon \cos\theta + \sqrt{\varepsilon - \sin^2\theta}}$$

$$R_v = \frac{\cos\theta - \sqrt{\varepsilon - \sin^2\theta}}{\cos\theta + \sqrt{\varepsilon - \sin^2\theta}}$$

$$F_{hh}(-k\sin\theta, 0) + F_{hh}(k\sin\theta, 0) = \frac{2\sin^2\theta(1 + R_h)^2}{\cos\theta} \cdot \left[ \left(1 - \frac{1}{\mu}\right) + \frac{\mu\varepsilon - \sin^2\theta - \mu\cos^2\theta}{\mu^2\cos^2\theta} \right]$$

$$F_{vv}(-k\sin\theta, 0) + F_{vv}(k\sin\theta, 0) = \frac{2\sin^2\theta(1 + R_v)^2}{\cos\theta} \cdot \left[ \left(1 - \frac{1}{\varepsilon}\right) + \frac{\mu\varepsilon - \sin^2\theta - \varepsilon\cos^2\theta}{\varepsilon^2\cos^2\theta} \right]$$

$\mu$  : Permittivité

$W^n(a, b)$  : Transformation de Fourier d'ordre n de la fonction d'autocorrélation

$$W^n(a, b) = \frac{1}{2\pi} \iint \rho^n(x, y) e^{-i(ax+by)} dx dy$$

Dans une première version modifié de ce modèle, Baghdadi et al. (2006) ont proposé de remplacer la valeur mesurée de la longueur de corrélation (L) par un paramètre optimal (Lopt), qui dépendra de la rugosité de surface (écart-type des hauteurs, Hrms) et des paramètres de configuration du capteur (angle d'incidence), afin d'améliorer les résultats entre les mesures du capteur et les sorties du modèle. Selon chaque bande de fréquence (X, C et L), une calibration des modèles doit être établie. Plusieurs études ont montré que l'utilisation de ce paramètre d'ajustement a permis de corriger les estimations par rapport

aux mesures réelles (Baghdadi et al., 2006 ; Baghdadi et al., 2011 ; Baghdadi et al., 2015 ; Dong et al., 2012).

Dans une autre version, le modèle AIEM (Advanced Integral Equation Model) a été développé par Chen et al. (1995). Les mêmes paramètres que le modèle original IEM sont utilisés dans cette version. Les améliorations appliquées dans ce dernier se sont appuyées sur l'utilisation d'un coefficient de Fresnel de réflexion et l'ajout des expressions complètes dans le coefficient de Kirchhoff. Ces améliorations ont permis un calcul plus précis avec un domaine de validité plus large selon la fréquence (Fr) et l'angle d'incidence ( $\theta$ ) ( $1.5 \text{ Ghz} < \text{Fr} < 9.5 \text{ Ghz}$  ;  $10^\circ < \theta < 50^\circ$ ).

### ***b. Les modèles empiriques et semi-empiriques***

Les plus connus des modèles empiriques sont les modèles Oh et Dubois. (Dubois et al., 1995 ; Oh et al., 1992). Dans ces modèles, la rugosité du sol n'est modélisée que par l'écart-type des hauteurs (Hrms). En outre, ces modèles couvrent des gammes de validité beaucoup plus importantes que celles des modèles physiques. Cependant, leurs limites résident dans leur faible transposabilité d'un site d'étude à un autre et nécessitent à chaque fois des étapes de calibration et de validation. Dans ce contexte, de nombreuses études ont essayé de reprendre ces modèles avec plusieurs améliorations afin de reproduire une rétrodiffusion proche de la réalité en fonction des paramètres de surface.

- Le modèle Oh

Dans ces nombreuses versions (Oh, 2004 ; Oh et al., 1992), les coefficients de rétrodiffusion, en fonction des polarisations, sont définis selon un rapport p et q en fonctions de la longueur d'onde ( $\lambda=2\pi/k$ , en cm), l'angle d'incidence, l'écart-type des hauteurs et l'humidité du sol.

$$p = \frac{\sigma_{hh}^0}{\sigma_{vv}^0} = [1 - (\frac{\theta}{90^\circ})^{1/3} \Gamma_0 e^{-k.Hrms}]^2 \quad (3)$$

$$q = \frac{\sigma_{hv}^0}{\sigma_{vv}^0} = 0.23 \sqrt{\Gamma_0} (1 - e^{-k.Hrms}) \quad (4)$$

Où

$$\Gamma_0 = \left| \frac{1 - \sqrt{\epsilon_r}}{1 + \sqrt{\epsilon_r}} \right|^2$$

Dans une seconde version du modèle, Oh et al. (1994) ont proposé une nouvelle expression de q, comprenant un coefficient avec une polarisation croisée, et en prenant en compte l'effet de l'incidence :

$$q = \frac{\sigma_{hv}^0}{\sigma_{vv}^0} = 0.25 \sqrt{\Gamma_0} (0.1 + \sin^{0.9} \theta) (1 - e^{-(1.4-1.6\Gamma_0)k.Hrms}) \quad (5)$$

Dans sa dernière version, Oh (2004) a optimisé le modèle pour un domaine de validité très large avec des incidences entre 10 et 70°, des valeurs de k.Hrms entre 0.13 et 6.98 et des conditions d'humidité du sol entre 4 et 29 vol. %. Le rapport q a été encore une fois

modifié, de manière empirique, sans prise en compte de l'effet hydrique du sol, selon l'expression suivante :

$$q = \frac{\sigma_{hv}^0}{\sigma_{vv}^0} = 0.095(0.13 + \sin^{1.5}\theta)(1 - e^{-1.3.(k.Hrms^{0.9})}) \quad (6)$$

- Le modèle Dubois

En fonction de l'angle d'incidence radar, la constante diélectrique du sol, l'écart-type de hauteur, l'angle d'incidence et la longueur d'onde ( $\lambda=2\pi/k$ , en cm), le modèle Dubois définit un coefficient de rétrodiffusion selon la polarisation VV et HH (Dubois et al., 1995).

$$\sigma_{hh}^0 = 10^{-2.75} \frac{\cos^{1.5}\theta}{\sin^5\theta} 10^{0.028.\epsilon_r.\tan\theta} (k.Hrms.\sin\theta)^{1.4} \lambda^{0.7} \quad (7)$$

$$\sigma_{vv}^0 = 10^{-2.35} \frac{\cos^3\theta}{\sin^3\theta} 10^{0.046.\epsilon_r.\tan\theta} (k.Hrms.\sin\theta)^{1.1} \lambda^{0.7} \quad (8)$$

L'algorithme est optimisé pour des valeurs de k.Hrms inférieures à 2.5, d'humidité du sol inférieures à 35 vols. % et des incidences inférieures à 30°.

Une nouvelle version a été développée récemment par Baghdadi et al. (2016) avec des valeurs d'angles d'incidence entre 18 et 57° et pour différentes bandes de fréquences (X, C et L). Cette version a été validée sur plusieurs sites d'étude, avec des conditions climatiques différentes. Les expressions des coefficients de rétrodiffusion s'expriment alors selon leur polarisation :

$$\sigma_{hh}^0 = 10^{-1.287} \cos\theta^{1.227} 10^{0.009.mv.\cotan\theta} (k.Hrms)^{0.86.\sin\theta} \quad (9)$$

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

$$\sigma_{hv}^0 = 10^{-2.325} \cos\theta^{-0.01} 10^{0.011.mv.\cotan\theta} (k.Hrms)^{0.44.\sin\theta} \quad (11)$$

Cette amélioration est très significative précisément pour la bande C et X avec des RMSE de l'ordre de 1.9 dB. Pour la bande L, les résultats sont similaires aux simulations par le modèle original.

### *c. Evaluation des différents modèles de rétrodiffusion*

Les modèles physiques se basent essentiellement sur des approches théoriques qui prédisent un coefficient de rétrodiffusion à partir des paramètres de l'instrument et des caractéristiques de la surface. Ils fournissent des relations indépendamment du site d'étude, mais conformément à des domaines de validité très limités dépendant de la rugosité de la surface.

Les modèles empiriques sont plus simples à utiliser et sont reconnus pour leur aptitude à être inversés afin d'estimer les paramètres de surface. Ils couvrent une plus large gamme de validité par rapport aux modèles physiques.

Des études approfondies ont évalué ces modèles de rétrodiffusion et comparé leurs performances. Toutefois, des résultats contradictoires sont obtenus. Dans certains cas, un bon accord existe entre les mesures et les simulations (Gorrab et al., 2015 ; Le Morvan et al., 2008 ; Zribi et al., 2014), tandis que de nombreuses études ont mis en évidence de fortes disparités entre les résultats de la modélisation et le signal mesuré (Baghdadi et al., 2004 ; Baghdadi et al., 2016 ; Bindlish & Barros, 2000 ; Mattia et al., 1997 ; Merzouki et al., 2010 ; Zribi et al., 1997).

D'autres investigations se sont intéressées à la comparaison entre les différents modèles pour évaluer la performance de ces derniers, en utilisant des configurations radars variées en polarisation, en angle d'incidence et en longueur d'onde.

Baghdadi et Zribi (2006) ont évalué les modèles semi-empiriques Oh et Dubois et le modèle physique IEM en utilisant des données en bande C. Le modèle Oh simule correctement le rapport  $p$  mais surestime le rapport  $q$ . L'évaluation du modèle Oh a montré que quelque soit sa version, le modèle a tendance à surestimer le rapport  $c$  (défini par  $c = p/q = \sigma^{0}_{HH}/\sigma^{0}_{HV}$ ). Ces erreurs ne dépendent pas de l'humidité du sol, de la rugosité ou de l'incidence du signal. Pour le modèle Dubois, le coefficient de rétrodiffusion n'est reproduit correctement que pour des surfaces moyennement rugueuses (Hrms entre 0.6 et 1.6 cm). Les simulations montrent une sous-estimation des coefficients de rétrodiffusion pour les surfaces faiblement rugueuses et une surestimation pour les surfaces rugueuses (Hrms supérieur à 1.6 cm). Ils ont démontré également que cette source d'erreur est fortement liée à l'humidité du sol, l'angle d'incidence et la polarisation du signal. Les erreurs obtenues pour les simulations effectuées par le modèle IEM, qui surestime fréquemment le coefficient de rétrodiffusion, impliquent l'humidité, la rugosité, l'angle d'incidence et la polarisation (avec des RMSE entre 5 et 14 dB).

Khabazan et al. (2013) ont aussi analysé la performance de ces modèles (IEM, Oh et Dubois), en utilisant des données radars en bande L et C. Les résultats obtenus montrent que le modèle Dubois a tendance à surestimer la réponse radar pour les bandes L et C, alors que les modèles IEM et Oh surestiment fréquemment la réponse radar dans la bande L avec une erreur quadratique moyenne (RMSE) de 6 dB et la sous-estiment en bande C avec des erreurs pouvant atteindre plusieurs décibels (approximativement 8.5 dB). Ces modèles ont été également testés sur des sols couverts par la végétation. Toutefois, une faible corrélation existe entre les mesures du signal et les estimations, vu que ces modèles n'utilisent aucun paramètre permettant de modéliser l'impact de la végétation.

La rétrodiffusion simulée par les mêmes trois modèles a été encore évaluée par Panciera et al. (2014) pour des données en bande L. Les modèles ont d'abord été testés sans passer par des étapes de calibration, ce qui a permis de révéler que le modèle Oh était le plus précis avec des erreurs inférieures à 1.2 dB pour les polarisations HH et VV, contre des erreurs pouvant atteindre 4 dB pour les modèles IEM et Dubois. Il a été observé que les erreurs de rétrodiffusion étaient liées à la rugosité de la surface, un autre facteur important déterminant la diffusion électromagnétique à la surface du sol. Une calibration du modèle était alors appliquée afin d'améliorer la disparité entre la modélisation et les mesures, ce qui a permis d'obtenir de très bons résultats avec des erreurs moyennes de l'ordre de -0.3 et -0.2 dB, respectivement pour les polarisations HH et VV.

Des études plus récentes (Choker et al., 2017) ont prouvé que le modèle IEM modifié par Baghdadi fournissait les simulations les plus précises avec des performances légèrement meilleures en bande X que en bandes C et L. Le modèle Dubois simule un coefficient de rétrodiffusion avec un RMSE de 2.9 dB et 4 dB pour la polarisation VV et HH respectivement. Enfin, toutes les versions du modèle Oh montrent de bons accords (un RMSE inférieur à 3 dB) avec une performance légèrement supérieure à celle de la version Oh 1992 (un biais inférieur à 1 dB et un RMSE inférieur à 2.6 dB) pour les deux polarisations HH et VV. Cette évaluation a été effectuée sur plusieurs sites d'étude.

### **2.2.3.2.2. Modélisation du signal radar sur les sols couverts par la végétation**

#### **a. Les modèles pour les couverts végétaux**

Certes la rétrodiffusion sur une surface couverte par la végétation est différente de celle d'un sol nu. En effet, la végétation influence largement le signal radar (les caractéristiques du couvert végétal confèrent de nombreux effets sur la rétrodiffusion radar). Plusieurs mécanismes entrent alors en jeu, tels que les diffuseurs de la plante (feuilles, tiges, branches, etc.) et les caractéristiques électromagnétiques du sol. Les diffuseurs de la végétation vont avoir un effet perturbateur sur le signal radar qui va dépendre principalement des propriétés géométriques et structurales du couvert (tels que la taille, la forme, l'orientation, la densité, etc.) et du contenu en eau étroitement lié aux caractéristiques électromagnétiques des radars.

Une meilleure compréhension du signal radar est alors nécessaire afin d'explicitier l'interaction entre le signal et les paramètres de la végétation. Des problématiques sont généralement liées à la complexité de la description du couvert, aux calculs de la rétrodiffusion et à la relation entre le signal et les paramètres du milieu. *Comment et dans quel cas alors ces paramètres entrent en jeu pour interagir avec le signal ? Et pour quels domaines d'applications ?*

Différentes approches ont été développées pour répondre à ces questions. Ces méthodes se scindent en deux : d'un côté, il y a les modèles exactes qui reposent sur la résolution des équations de Maxwell et permettent un calcul exact de la diffusion. Cependant, ils nécessitent des temps de calculs laborieux et sont très complexes pour pouvoir être inversés. De l'autre, il y a les modèles approchés qui consistent à appliquer une série d'approximations qui interviennent au niveau de la description du milieu par simplification des composants et au niveau électromagnétique (phénomène d'interaction). Ils sont basés soit sur la théorie du transfert radiatif, soit sur les approximations de Born (Tsang et al., 1985 ; Ulaby et al., 1984).

Entretemps, les approches courantes, adoptées pour la modélisation de la rétrodiffusion sur un couvert végétal, consistent à développer des modèles directs simulant un coefficient de rétrodiffusion, susceptibles d'être inversés pour restituer les paramètres de surface et les caractéristiques de la végétation. Des exemples de modèles sont passés en revue dans les sections suivantes.

Les théories électromagnétiques et les modèles de rétrodiffusion sur des couverts végétaux ont été développés vers la fin des années 70. Et c'est par une approche très simple que Attema et Ulaby (1978) ont mis au point le premier modèle Water Cloud Model (WCM), appelé aussi le modèle de nuage d'eau. Ce modèle s'est essentiellement

basé sur la résolution des équations du transfert radiatif et représente la canopée comme un nuage uniforme de gouttelettes d'eau sphériques et identiques, réparties de façon homogène sur une couche horizontale. Plusieurs modèles ont été dérivés par la suite à partir du modèle originel (Bindlish & Barros, 2001 ; Chauhan et al., 2017 ; Kweon et al., 2015 ; Paris, 1986 ; Ulaby et al., 1984). Dans ces modèles, les descripteurs de la végétation sont très variés et utilisent des paramètres tels que le LAI, le NDVI, la hauteur du couvert, la fraction de couverture ou la teneur en eau, selon la complexité de la structure du couvert. Néanmoins, il n'existe aucune base théorique générale permettant de définir le meilleur ensemble de descripteurs de couvert. Le modèle WCM est qualifié de semi-empirique car les paramètres du modèle doivent être dérivés de données expérimentales (ajustées).

L'onde rétrodiffusée est alors modélisée comme l'ensemble de la diffusion par le sol (diffusion de la surface) atténué par le couvert végétal, la diffusion par la végétation (diffusion de volume) et l'interaction sol-végétation, selon l'expression suivante :

$$\sigma^0 = \sigma_{\text{vég}}^0 + \sigma_{\text{vég-sol}}^0 + \tau^2 \sigma_{\text{sol}}^0 \quad (12)$$

Où  $\sigma_{\text{vég}}^0$  Le coefficient de rétrodiffusion du couvert végétal représenté par l'équation suivante :

$$\sigma_{\text{vég}}^0 = A \cdot V \cdot \cos \theta \cdot (1 - \tau^2) \quad (13)$$

$\sigma_{\text{vég-sol}}^0$  Le coefficient de rétrodiffusion dû à l'interaction entre le couvert et le sol. Ce terme est souvent négligé dans les interactions Co-polarisées (Dobson & Ulaby, 1986 ; Kweon, et al., 2015 ; Prévot et al., 1993).

$\sigma_{\text{sol}}^0$  Le coefficient de rétrodiffusion du sol, qui dépend de l'humidité du sol, de la rugosité et des paramètres du capteur radar (angle d'incidence, longueur d'onde et polarisation). Le coefficient de rétrodiffusion est généralement dérivé des modèles physiques ou semi-empiriques (IEM, Dubois, Oh, etc.) ou par une fonction linéaire qui relie le signal à l'humidité du sol.

$\tau^2$  La transmissivité de la végétation qui représente le facteur d'atténuation et s'exprime selon l'équation suivante :

$$\tau^2 = \exp(-2 \cdot B \cdot V \cdot \sec \theta) \quad (14)$$

A et B sont des paramètres empiriques dépendant du type de culture, le terme V représente le descripteur de la végétation (mesuré à partir de données expérimentales ou dérivé des données satellitaires) et  $\theta$  est l'angle d'incidence. Le modèle nécessite donc d'être ajusté selon le site d'étude et les conditions du milieu. Grâce à sa formulation simplifiée et intuitive, le modèle WCM est le plus utilisé dans le cadre des modèles semi-empiriques inversibles. Il a été utilisé pour reproduire un signal radar pour différents types de cultures et à partir de plusieurs configurations de différents capteurs (Baghdadi et al., 2017 ; Beriaux et al., 2013 ; Dabrowska-Zielinska et al., 2007 ; Fascetti et al., 2017 ; Fieuzal & Baup, 2016 ; Jiao et al., 2010 ; Kumar et al., 2012 ; Prévot et al., 1993 ; Yang et al., 2016).

Les modèles empiriques sont généralement développés pour un type de structure végétal unique, basés sur l'augmentation du coefficient de rétrodiffusion en fonction de la biomasse (Ulaby et al., 1986). La rétrodiffusion devient alors insensible aux augmentations de la biomasse à un certain seuil, qui s'adapte à la longueur d'onde (ou la fréquence) de chaque espèce de culture.

D'autres modèles comme le modèle MICHigan MICrowave Canopy Scattering (MIMICS) ou le modèle de Karam, représentent la végétation avec des couches horizontales où les diffuseurs sont répartis de manière aléatoire.

Dans sa version originale, le modèle MIMICS a été proposé pour caractériser la réponse d'un signal radar à un couvert forestier (Ulaby et al., 1990), comprenant une couche de couronne, une couche de tronc et la frontière d'une surface rugueuse. Il prend donc en compte les propriétés géométriques de la végétation (feuilles, tronc, tige, etc.) sous des formes coniques (ellipsoïdes, disques et cylindres) avec une description très détaillée de la végétation, ainsi que des propriétés physiques liées à la surface du sol. En tant que modèle semi-empirique, MIMICS est aussi basé sur la résolution de l'équation du transfert radiatif. Le modèle a été ensuite repris pour être adapté à des surfaces agricoles, soit combiné avec d'autres modèles de rétrodiffusions, soit simplifié. Ce dernier nécessite beaucoup de paramètres, ce qui peut être contraignant, malgré le fait qu'il permet de mieux quantifier la contribution de la végétation.

Touré et al. (1994) ont adapté le modèle MIMICS pour des couverts agricoles, sur des champs de blé et de canola, utilisant des données en bande L et C. La couche couronne n'a pas été prise en compte lors de la modélisation. Les résultats de cette approche montrent que le modèle simule correctement le signal radar en polarisation HH avec des erreurs moyennes inférieures à 2 dB dans les deux cas de culture. Entre autre, l'approche proposée a permis de prédire l'humidité du sol avec une précision de l'ordre de 0.04 g/cm<sup>3</sup> pour les deux cultures.

Yu et Zhao (2011) ont développé une approche plus simplifiée du modèle MIMICS, utilisant une synergie de données Envisat-ASAR et Landsat-TM. La surface est alors divisée en une couche de sol et une couche de la canopée. Ce modèle est couplé à un modèle optique PROSAIL, qui permet d'obtenir le LAI, paramètre en entrée au modèle MIMICS. Conformément au travail proposé par Touré et al. (1994), l'approche a permis d'estimer l'humidité du sol à partir de ce modèle modifié avec un RMSE de 0.03 g/cm<sup>3</sup>. Cette inversion est applicable pour un seuil bien déterminé de LAI (LAI < 3).

Le modèle MIMICS a été aussi adopté par Bao et al. (2014) avec une nouvelle méthode sur des champs de blé pour différentes incidences. Une synergie de données radars dérivées du capteur Envisat-ASAR et de données optiques Landsat-TM est aussi utilisée pour estimer l'humidité du sol. Le RMSE entre l'humidité mesurée et estimée est de l'ordre de 0.04 m<sup>3</sup>/m<sup>3</sup>, avec un coefficient de rétrodiffusion de 0.84.

Des modèles comme Crop (De Roo et al., 2001), Karam (Karam et al., 1992) et Sun et Ranson (Sun et Ranson, 1995), se sont inspirés du modèle MIMICS, permettant de décomposer la réponse du signal radar selon les différentes contributions (sol et végétation). Ils sont souvent couplés à des modèles physiques ou semi-empiriques pour représenter la rétrodiffusion sur le sol nu.

D'autre part, les polarisations en horizontale (HH ou HV) se révèlent être les plus sensibles à la végétation et produisent les corrélations les plus élevées, tandis que les polarisations en verticale ont tendance à saturer à des niveaux inférieurs de NDVI par exemple. Pour prédire la sensibilité du signal à la végétation, Le Toan et al. (1989) ont prouvé que la réponse de la polarisation HH est supérieure à VV à un certain stade de développement des cultures sur des sites de blé, de tourne sol, de riz, de vignes et de maïs. Dans des travaux sur le maïs et le soja, Hosseini et al. (2015) ont démontré similairement que de meilleures simulations pour reproduire le LAI à partir du Water Cloud Model (WCM) en utilisant des produits en HH et HV qu'en VV et VH.

### ***b. Les approches d'inversion pour l'estimation de l'humidité du sol***

La réponse du signal radar dépend fortement des paramètres liés au sol (rugosité et humidité du sol), à la végétation (type de culture, stade de développement, orientation, géométrie, densité et contenu en eau) et aux configurations du capteur (polarisation, longueur d'onde et polarisation). L'intérêt de la modélisation de la rétrodiffusion sur les sols nus ou sur les couverts végétaux réside dans la compréhension du comportement du signal radar. L'autre enjeu majeur de la modélisation s'appuie sur la restitution des paramètres de surface à partir de l'inversion de ces modèles. Afin de faciliter l'inversion, la plupart des approches reposent sur des modèles empiriques et semi-empiriques.

L'onde radar est très sensible aux propriétés diélectriques (la constante diélectrique) de surface, directement liées à l'humidité du sol. La détection de la variation de l'humidité nécessite alors la mise au point d'un algorithme d'inversion opérationnel. Pour les zones couvertes par la végétation, les algorithmes d'inversion seront basés sur des modèles intégrant l'effet d'atténuation du signal dû à la végétation et en tenant compte de la contribution de la végétation (Srivastava et al., 2009).

A cause de la complexité de certains modèles qui tiennent compte de la géométrie de la culture, la méthode d'inversion la plus utilisée dans la littérature et la plus simple repose sur l'utilisation du modèle Water Cloud Model (WCM). Avec un nombre restreint de paramètres à optimiser et un temps de calcul minime, le modèle WCM a été développé et repris dans plusieurs versions afin d'être adapté dans différents contextes d'étude (Attema & Ulaby, 1978 ; De Roo et al., 2001 ; El Hajj et al., 2017 ; Gherboudj et al., 2011 ; Prévot et al., 1993 ; Zribi et al., 2011).

Nous allons passer en revue les différentes méthodes d'inversion pour l'estimation de l'humidité du sol selon les différentes configurations des capteurs RSO et selon les types de cultures ainsi que les conditions du milieu.

Dans cette optique, la restitution quantitative de l'humidité repose sur ces méthodes qui permettent de mieux comprendre la diffusion sur des surfaces agricoles en bandes X et C avec différents algorithmes basés sur le modèle WCM avec une simple approche d'inversion ou avec des techniques de réseaux de neurones. Bien que la bande X ait un potentiel pour le suivi de l'humidité du sol, elle se révèle plus sensible aux sols nus qu'aux couverts végétaux en raison de sa pénétration dans la surface (Aubert et al., 2011 ; Gorraeb et al., 2015). Les travaux en bande X sont aussi peu nombreux, probablement parce que ces données sont assez récentes et ne sont pas gratuites, en effet les produits TerraSAR-X ou COSMO-SkyMed offrent des produits payants, et que les bandes C et L sont plus adaptées aux surfaces agricoles vu leur degré de pénétration. Toutefois, les applications en

bande L sont encore limitées, bien qu'elle pénètre en profondeur dans la couverture végétale (Fascetti et al., 2017 ; Lievens & Verhoest, 2011 ; Liu & Shi, 2016 ; Zribi et al., 2019).

Prévoit et al. (1993) ont utilisé des données en bandes C (en polarisation HH) et X (en polarisation VV) sur des parcelles de blé. Une inversion du modèle a été établie afin d'estimer le LAI et l'humidité du sol avec des précisions de l'ordre de  $0.64 \text{ m}^2/\text{m}^2$  et  $0.065 \text{ m}^3/\text{m}^3$  respectivement. Dans Bindlish & Barros (2001), le WCM a été repris afin de restituer l'humidité du sol. Le modèle a été modifié en introduisant un paramètre qui prend en compte l'effet d'ombre dans les données radars. Par rapport aux autres travaux, les auteurs ont amélioré les résultats de la modélisation en prenant en compte des classes d'occupation du sol dans la paramétrisation de la végétation. En effet, ce travail a été conduit sur des parcelles de blé, de prairies et de pâturages, où chaque type de culture a une influence spécifique sur le signal radar et sur le paramétrage du modèle. Le coefficient de corrélation entre l'humidité mesurée et estimée passe alors de 0.84 à 0.95 avec cette amélioration. D'autres travaux d'améliorations ont été effectués par Graham & Harris (2003) sur le WCM avec des données en bande C afin de générer des profils temporels d'humidité du sol sur les cultures de pomme de terre. Les sorties de ce modèle seront assimilées pour le calcul de l'évapotranspiration et du potentiel hydrique. Les travaux en bande X sont peu nombreux mais se révèlent assez robustes, notamment les travaux de El Hajj et al. (2016) sur des prairies en irrigué, utilisant des séries temporelles de données TerraSAR-X et COSMO-SkyMed. Les données radars ont été combinées à plusieurs produits dérivés des données optiques (NDVI, LAI, fraction du couvert et Fraction Photosynthétiquement Actif Absorbé) afin de décrire la végétation. L'inversion du modèle utilise des techniques basées sur les réseaux de neurones. Selon le développement de la végétation, les RMSE de l'humidité du sol varient entre 3.6 et 6.1 vol. %. Le RMSE augmente lorsque la végétation se développe et atteint une certaine hauteur. Les meilleurs résultats ont été obtenus en utilisant le NDVI comme indicateur de la végétation et la polarisation HH du signal radar. Plusieurs travaux ont été portés sur les techniques des réseaux de neurones pour estimer l'humidité du sol (Alexakis et al., 2017 ; Hassan-Esfahani, et al., 2015 ; Kseneman et al., 2012 ; Paloscia et al., 2010 ; Paloscia et al., 2013). Par exemple, les travaux de Kseneman & Gleich (2013) se sont basés sur la comparaison entre les produits d'humidité issus des réseaux de neurones et ceux issus de l'inversion du WCM. D'après les résultats statistiques, pour comparer les deux approches, les auteurs ont conclu que le modèle neuronal est beaucoup plus performant que le modèle WCM pour estimer les paramètres du sol.

Gherboudj et al. (2011) ont combiné les modèles "WCM" et "Oh" pour estimer l'humidité du sol avec végétation (blé, pois, lentilles, jachères, pâturages et canola) à partir des données radars en bande C. L'humidité du sol a été estimée avec une précision de 6 vol. % pour des hauteurs de végétation entre 11 et 97 cm. D'autres auteurs proposent une approche basée sur une synergie de données radars et optiques. He et al. (2014) ont combinés des données radars (C-HH et L-VV) et optiques pour estimer l'humidité du sol. Les résultats démontrent une précision d'environ 3 vol. %. Les données optiques sont toutefois nécessaires pour inverser le signal radar en utilisant le modèle WCM. En effet ces données sont complémentaires aux données radars et leur intérêt réside dans leur sensibilité aux paramètres physiques de la végétation. Dans le modèle WCM, ces paramètres permettent d'évaluer la contribution de la végétation sur le signal radar, afin de

pouvoir ensuite inverser la contribution du sol et estimer l'humidité du sol. D'où l'importance du couplage entre les données optiques et radars pour une meilleure estimation de l'humidité du sol (Baghdadi et al., 2017 ; Fieuzal et al., 2011 ; Fieuzal et al., 2013 ; He et al., 2014).

# Chapitre 2: Site d'étude et base de données

*Le chapitre suivant se scinde en deux parties principales : la première s'articule sur la description du cadre général de la zone d'étude. Elle est consacrée à la caractérisation des différents contextes géographiques, climatiques, hydrologiques et agricoles avec une présentation des occupations des sols du site. Ces connaissances sont nécessaires pour la compréhension des états de surface. En effet la plaine de Kairouan est une région pilote pour étudier la gestion intégrée des ressources en eau en zones semi-arides, elle a fait l'objet de plusieurs projets et études scientifiques. La deuxième partie du chapitre détaille la base de données élaborée durant la thèse, constituée d'une partie expérimentale (collecte de données sur le terrain pour la caractérisation des états de surface) et d'images satellitaires (optiques et radars), acquises sur les parcelles de références. Ces acquisitions se sont déroulées sur deux années agricoles durant les deux premières années de thèse (saisons agricoles : 2015-2016 et 2016-2017). Ces données expérimentales vont servir à l'évaluation des résultats obtenus au cours de ce travail, à l'aide de campagnes de collecte, de traitements en laboratoire, d'observations et d'enquêtes sur le terrain. Enfin, les séries d'images satellitaires et les prétraitements associés sont aussi détaillés.*

## Sommaire

---

<b>CHAPITRE 2: SITE D'ETUDE ET BASE DE DONNEES .....</b>	<b>46</b>
2.1. SITE D'ETUDE : LA PLAINE DE KAIROUAN.....	47
2.1.1. Situation géographique .....	47
2.1.2. Contexte climatique .....	48
2.1.2.1. Pluviométrie .....	48
2.1.3. Contexte hydrique.....	51
2.1.4. Nature des sols .....	52
2.1.5. Occupation des sols et pratiques agricoles.....	52
2.2. LA BASE DE DONNEES.....	54
2.2.1. Données satellitaires.....	55
2.2.1.1. Données radars.....	55
2.2.1.2. Données optiques.....	60
2.2.1.3. Comparaison entre les images Landsat-8 et les images Sentinel-2 .....	64
2.2.2. Campagnes expérimentales et mesures sur le terrain .....	64
2.2.2.1. Paramètres du sol .....	65
2.2.2.2. Paramètres de la végétation .....	68
2.2.2.3. Collecte de données sur l'irrigation .....	70
2.2.2.4. Stations agro-météorologiques et stations de mesures de l'humidité du sol .....	71
2.3. CONCLUSION PARTIELLE .....	72

---

## 2.1. Site d'étude : La plaine de Kairouan


### 2.1.1. Situation géographique

Dans ce présent travail, nous avons considéré un site expérimental spécifique, qui se localise au niveau du gouvernorat de Kairouan. La plaine de Kairouan est, tout d'abord, une région agricole en Tunisie centrale, couvrant une superficie de 3000 km<sup>2</sup> (centrée sur les coordonnées 9°53'57"E et 35°4'51"N ; Figure 2.1). Le site expérimental se situe dans la zone orientale de l'Atlas Tunisien. Il appartient à la région naturelle des steppes à l'aval du bassin versant de Merguellil, et caractérisé par un bioclimat semi-aride, faisant face à de fortes irrégularités pluviométriques et de grandes amplitudes thermiques avec des étés très secs et des hivers humides.

La plaine de Kairouan forme une vaste cuvette, qui s'étend sur environ 100 km de long et 40 km de large. Le relief est peu marqué, le terrain est majoritairement plat et peu affecté par l'érosion. La plaine est dédiée à l'agriculture et constituée de terres fertiles où se concentrent plusieurs périmètres irrigués. A l'amont du bassin, la région comprend une partie relativement montagneuse, entourée à l'Est par les collines du Sahel et les Djebels à l'Ouest.

Malgré ces handicaps, l'agriculture et l'élevage constituent la principale activité économique de la région où les cultures dominantes reposent principalement sur les oliveraies et les grandes cultures (principalement céréalières) avec une progression notable de la polyculture et l'arboriculture qui s'appuient sur des systèmes d'irrigation de plus en plus performants. La région se caractérise aussi par une importante production de légumes (piments et tomates) et de fruits de saison (pastèques, melon, abricots et olives). Avec des cultures majoritairement en irrigué, l'intensité et les fréquences d'irrigation affectent de plus en plus la disponibilité de l'eau. La population active est concentrée essentiellement dans le secteur agricole avec plus de 40 %.

La problématique majeure des régions semi-arides se focalise sur le déficit hydrique qui résulte de l'effet conjugué de la croissance des besoins en eau (extensions des réseaux d'irrigation par exemple) et de la rareté des ressources (sécheresse et changements climatiques). De plus les prélèvements d'eau ne cessent d'augmenter face à l'augmentation de la production agricole. Confrontée à de vives tensions sur l'accès et le partage des eaux et en raison des ressources extrêmement limitées (des précipitations annuelles de 300 mm et un taux d'évaporation très élevé) qui augmentent de plus en plus, une gestion rationnelle de ces ressources est essentielle surtout dans le domaine agricole qui apporte une contribution majeure à la sécurité alimentaire et limitent les risques probables liés aux changements climatiques.




**Figure 2. 1:** Localisation du gouvernorat de Kairouan, au centre de la Tunisie

### 2.1.2. Contexte climatique

D'un point de vue climatique, la région est soumise à un climat de type semi-aride, caractérisé par des saisonnalités marquées. En effet, la Tunisie centrale se situe entre le bassin occidental de la méditerranée et le désert. De ce fait, la plaine de Kairouan se trouve dans une zone de transition, soumise aux influences simultanées, d'une part, de la zone à tendance humide caractérisée par le climat de la méditerranée à vents humides (le Nord), et d'autre part, de la zone présaharienne caractérisée par le climat saharien sec et humide (le Sud) (Amri et al., 2011). Les paramètres climatiques peuvent être caractérisés comme suit :


#### 2.1.2.1. Pluviométrie

La plaine de Kairouan se caractérise par une forte irrégularité spatiale et temporelle de pluviométrie avec une moyenne annuelle de l'ordre de 300 mm. La région se situe entre les isohyètes 200 et 400 mm par an. La Figure 2.2 illustre la variation de la pluviométrie annuelle entre les années hydrologiques 1986 et 2018, enregistrée par l'Institut National Météorologique (INM). Cette variation oscille entre 158 et 577 mm. Les totaux sont calculés pour les années hydrologiques, du mois de Septembre jusqu'au mois d'Août. Les précipitations annuelles moyennes sont d'environ 308 mm, durant ces 32 dernières années. Elle est aussi caractérisée par une forte variabilité interannuelle avec plusieurs périodes de sécheresse. Selon l'illustration, les années les plus sèches sont 1987-1988, 2000-2001 et 2012-2013 avec des valeurs inférieures à 160 mm. Tandis que les années hydrologiques, les plus humides, se limitent aux années 1989-1990 et 1995-1996, avec plus de 560 mm de précipitations annuelles.



**Figure 2. 2:** Variation interannuelle de la pluviométrie de la plaine de Kairouan entre les années hydrologiques 1986 et 2018 (Source: INM, 2018)


Les analyses des données de la pluviométrie mensuelle au cours des 32 dernières années révèlent que les pluies hivernales sont de faible intensité par rapport aux pluies automnales (Figure 2.3). Les précipitations inter-mensuelles montrent également des irrégularités significatives tout au long de l'année. La saison des pluies s'étend généralement entre le mois de Septembre et le mois d'Avril avec des précipitations qui peuvent atteindre une moyenne de 50 mm. Cette pluviométrie est très variable dans le temps et dans l'espace : les valeurs extrêmes des précipitations sont enregistrées durant le mois de Septembre. Les pluies les moins intenses sont enregistrées durant le mois de Juillet.



**Figure 2. 3:** Variation mensuelle de la pluviométrie de la plaine de Kairouan entre les années hydrologiques 1986 et 2018 (Source: INM, 2018)

### 2.1.2.2. Température

La Figure 2.4, réalisée pour la zone de Kairouan à partir des données de l'INM entre les années 1986 et 2018, montre la répartition des moyennes mensuelles de la température, qui oscillent entre les valeurs 12°C et 30°C. D'après la Figure 2.4, la température la plus élevée est enregistrée pour le mois de Juillet avec des températures de l'ordre de 30°C. Généralement les mois les plus froids sont Décembre, Janvier et Février avec des températures moyennes mensuelles inférieures à 15°C. Cette variation de la température justifie l'aridité du climat. Le réchauffement à Kairouan au cours des 50 dernières années (1951-2002) est statistiquement significatif (0,29°C/10 ans), les températures minimales ont également augmenté de manière significative (Mougou et al., 2010).



**Figure 2. 4:** Variation mensuelle de la température entre des années 1986 et 2018 de la plaine de Kairouan (Source: INM)

L'hiver est froid dans le Nord-ouest de la plaine et modéré ailleurs. L'humidité relative varie entre 55 % et 70 % en hiver et entre 40 % et 55 % en été. L'évapotranspiration potentielle annuelle est proche de 1600 mm. Les vents dominants les plus fréquents viennent du Nord-ouest et du Nord en hiver et du Nord-est et du Sud en été. Les vents froids d'hiver proviennent généralement du Nord-ouest tandis que les vents chauds et secs d'été (Sirocco) soufflent du Sud vers l'Ouest (Amri et al., 2014).

Le développement et la gestion durable de la région sont fortement tributaires du régime climatique, et en premier lieu des précipitations qui connaissent une forte variabilité intra- et interannuelle. L'examen de la répartition moyenne de données de la température et de la pluviométrie montre l'existence de deux saisons nettement différenciées:

- Entre le mois d'Octobre et Avril, une saison humide où interviennent la quasi-totalité des épisodes pluvieux, soit près de 80 % de la pluviométrie annuelle

- Entre le mois de Mai et Septembre, une saison sèche avec seulement 20 % de la pluviométrie annuelle.

### 2.1.3. Contexte hydrique

Les terres agricoles de la plaine de Kairouan sont traversées par les Oueds « Zerroud » et « Merguellil ». D'autres affluents comme les Oueds Nebhana, El Alam, Zahem et Boghal ont été recueillis par la plaine. Le bassin versant de Merguellil a une superficie de 1540 km<sup>2</sup>. Sa partie amont s'étend sur environ 1200 km<sup>2</sup> et la partie aval est constituée d'une vaste plaine agricole. Comme moyen de gestion des ressources de la région, divers travaux de conservation des eaux et des sols ont été réalisés à partir des années 80, notamment la construction et l'aménagement de retenues de lacs collinaires et essentiellement de deux barrages, celui de Sidi Saad sur le lit de l'Oued Zerroud en 1981 et celui d'El Houareb sur le lit de l'Oued Merguellil en 1989, pour réduire le ruissellement, lutter contre les inondations et l'érosion et approvisionner les périmètres irrigués (Leduc et al., 2007).

Les ressources en eau du bassin de Merguellil sont caractérisées par une grande hétérogénéité liée notamment à la disparité spatiale et temporelle de la pluviométrie, à l'interconnexion des écoulements superficiels et souterrains et aux prélèvements d'eau pour divers usages. Par ailleurs les apports hydriques ne peuvent quitter le bassin que par évapotranspiration ou par infiltration, ainsi que par transfert vers les villes côtières pour l'alimentation en eau potable.

Néanmoins, le bassin est caractérisé par des crues très violentes (avec des précipitations de l'ordre de 100 à 200 mm) et de courtes durées. Notamment à cause des pluies torrentielles, les grandes crues de 1969 ont eu des conséquences humaines et économiques dramatiques (Guillaud and Trabelsi, 1991).

La nappe phréatique de la plaine est alimentée par les Oueds Merguellil et Zeroud, et fortement exploitée à la fois par les besoins agricoles que par l'alimentation en eau potable. De ce fait, ce réservoir aquifère d'importance régionale commence à s'épuiser et à se rabattre avec une baisse de niveaux piézométriques depuis les années 70 (estimés à 1 m par an) continuellement à cause de l'augmentation des forages illicites et des puits de surface provoquant une surexploitation de la nappe et donc une pénurie d'eau (Leduc et al., 2007). Cette surexploitation s'est accentuée après le 14 janvier 2011 à cause du très grand nombre de puits et forages illicites réalisés par les agriculteurs suite à l'affaiblissement de l'administration en post-révolution du Jasmin.

L'agriculture consomme plus de 80 % de la quantité totale d'eau extraite par l'aquifère de Kairouan chaque année. La plupart des agriculteurs de la plaine utilisent leurs propres puits pour extraire l'eau destinée à l'irrigation. Cependant quelques agriculteurs utilisent des réseaux publics et collectifs de distribution d'eau reliés à un forage principal. L'intensification des cultures au cours des dernières décennies, associée à une forte demande d'irrigation, a entraîné une augmentation de la demande en eau et une surexploitation des eaux souterraines (Saadi et al., 2017, 2015, 2014).


#### **2.1.4. Nature des sols**

Les sols trouvés sur le site d'étude sont principalement constitués de dépôts alluviaux, de formations d'argile et de sable grossier, et se caractérisent par une grande variabilité spatiale de leur texture. Les principales unités de sol sont des sols pauvres, des sols complexes (plusieurs unités de sols), des sols calcimagnétiques, des sols isohumiques (Shabou et al., 2015). Dans ce contexte, les inondations extrêmes de 1969 ont entraîné de fortes hétérogénéités spatiales en termes de texture du sol, car elles ont déposé des matériaux sableux à limoneux sableux dans les secteurs amont et aval. Elles ont également transporté de grandes quantités d'alluvions qui, combinées au mécanisme de dépôt naturel, modifiaient la distribution spatiale de ces dépôts (Batjes, 2010). En effet, la poussée du gisement le long du lit principal de l'oued, lorsqu'il déborde, conduit à une répartition dans laquelle les composants les plus grossiers restent en amont tandis que les alluvions les plus fines sont acheminées en aval.

D'autre part, l'introduction de systèmes de culture et de champs a entraîné des évolutions cycliques des conditions de surface et d'utilisation des terres au fil du temps. Le travail du sol et les travaux agricoles peuvent ainsi modifier les caractéristiques physiques du sol, entraînant des modifications de sa texture de surface.

#### **2.1.5. Occupation des sols et pratiques agricoles**

L'occupation des sols de la plaine du Kairouan est étroitement reliée à ces facteurs climatiques et ressources hydriques disponibles dans cette région. Le secteur agricole de la plaine se compose alors de trois sous-secteurs de production à savoir l'agriculture pluviale et irriguée, et l'élevage.



**Figure 2. 5:** Carte des occupations des sols de la plaine de Kairouan pour l'année agricole 2016-2017 (Source: Kassouk, 2017)

La Figure 2.5 illustre la carte d'occupation du sol de la plaine de Kairouan réalisée pour l'année agricole 2016-2017. La classification de l'occupation des sols est générée à partir d'une série temporelle de NDVI dérivée d'images Sentinel-2A et Sentinel-2B (une dizaine d'images acquises au cours de l'année), en utilisant une classification par Arbre de Décision. La classification de ces images a été validée sur une centaine de parcelles de référence.

Cette carte révèle l'importance des superficies des terres agricoles dans la plaine par la céréaliculture et l'oléiculture vue l'adaptabilité de ces cultures aux caractéristiques spécifiques des zones arides. Les cultures maraichères (légumes d'été et légumes d'hiver), ainsi que l'arboriculture arrivent en seconde position.

En effet, les oliviers en pluviale ou en irrigué occupent approximativement 40 % des surfaces de la plaine, ils sont très adaptés aux conditions du milieu. On trouve en second lieu, les cultures annuelles telles que la céréaliculture avec un pourcentage de 12 %, l'arboriculture irriguées 4 % et on trouve en faible pourcentage les légumes d'hiver et les légumes d'été (environ 9 %) (Chahbi et al., 2014).

Au final, les activités agricoles occupent près de 90 % du paysage. Les cultures saisonnières sont regroupées selon deux grandes classes, à savoir les cultures d'hiver et d'été, en fonction de leur période de développement. Concernant les cultures d'hiver, elles sont semées au cours de la période comprise entre les mois d'Octobre et Décembre. Elles sont récoltées durant les mois de Mai et de Juin. Elles sont majoritairement représentées

par les cultures céréalières (blé dur et tendre, luzerne, et orge). Durant cette période, les pois et les fèves sont également cultivés.

Les cultures d'été sont semées au printemps. La récolte s'échelonne entre la fin de l'été et l'automne. Elles sont principalement représentées par les piments et les tomates. Les melons et pastèques sont également cultivés durant cette même période. Cependant, ils représentent des surfaces cultivées réduites. Les cultures se distinguent par ailleurs, par les pratiques agricoles mises en œuvre, qui sont propres aux espèces et aux exploitants. L'espacement entre les rangs et la densité des grains semés varient ainsi à l'échelle du paysage.

Pour l'arboriculture, les oliviers sont des cultures très répandues dans la plaine de Kairouan. Les plantations arborées sont principalement situées dans les parties Sud-ouest et Est de la plaine. La majorité des zones non cultivées (les sols nus) se situent au Nord-est et au Sud de la plaine. La partie centrale de la plaine est dominée par les cultures céréalières (Figure 2. 5).

L'irrigation est quasi-systématique durant la période de croissance des céréales, alors que seulement quelques parcelles de blé ou d'orge sont en pluvial. Ces irrigations peuvent intervenir en fonction des conditions climatiques lors de la phase de développement de la culture. Les techniques d'irrigation diffèrent en fonction des cultures et des moyens des agriculteurs. Au sein de la zone d'étude, les asperseurs et les canaux à gouttes-à-gouttes sont les techniques les plus répandues, où les agriculteurs disposent de bornes individuelles sur un réseau collectif, assuré par les Groupements de Développement Agricole (GDA) qui gèrent l'eau d'irrigation à partir de compteurs. Le parcellaire agricole est très hétérogène. Cette hétérogénéité concerne la superficie des parcelles cultivées. On peut trouver des parcelles agricoles de faible superficie inférieure à 1 ha et d'autres ayant des superficies pouvant parfois atteindre 15 ha.

Cette première analyse qualitative des données terrain va permettre de mettre en évidence plusieurs caractéristiques de la zone d'étude. Pendant la saison humide, les dynamiques de la végétation et de l'humidité du sol sont très marquées, avec de très forts contrastes dans les conditions de surface (sol et végétation) entre les deux saisons. L'importance de ces deux facteurs (dynamique et contraste) est pilotée par l'intensité et la distribution des pluies et les périodes d'irrigation.

La suite de ce travail va donc porter sur une extraction quantitative de certains paramètres de surface (sol et végétation) afin de les utiliser dans l'enchaînement de ce travail et dans la perspective de la caractérisation des états de surface.

## 2.2. La base de données

Pour estimer et quantifier la variabilité des états de surface, il est nécessaire de déterminer les paramètres liés au sol et à la végétation. La sélection des parcelles de référence est basée sur différents critères. Elle doit présenter des conditions contrastées d'un point de vue du sol (localisations, nature du sol, texture, etc.) et des pratiques culturales (cultures et espèce, irrigation, etc.). Les données satellitaires (multi-capteurs) sont riches en information et permettent d'extraire de nombreux indices et paramètres nécessaires à l'étude du milieu. Au cours de cette campagne expérimentale, les mesures

sur le terrain ont été accompagnées par des acquisitions issues de la nouvelle génération de capteurs RSO et optiques.

### 2.2.1. Données satellitaires

L'intérêt général de ce travail repose sur la valorisation et l'exploration du potentiel de la nouvelle génération de capteurs qui propose une particularité innovante à travers une haute résolution spatiale pour un suivi à des échelles très fines et avec une haute répétitivité temporelle. Deux types d'acquisitions ont servi lors de cette étude, issus de deux instruments différents : des capteurs actifs et des capteurs passifs.

Cette section représente les deux capteurs utilisés pour cette étude, y compris les données Sentinel-1, Sentinel-2 et Landsat-8, leurs caractéristiques et les différentes étapes de traitement des données générées par ces derniers.

#### 2.2.1.1. Données radars

Depuis le lancement de la première génération de Radar à Synthèse d'Ouverture (RSO) vers les années 90, de nombreuses études ont montré le potentiel des données radars en bandes C (ERS-1, Radarsat, Envisat-ASAR, etc.) pour le suivi de l'évolution du système terrestre depuis l'espace, plus précisément des surfaces agricoles. Au cours des deux années agricoles 2015-2016 et 2016-2017, des séries d'images radars Sentinel-1A et Sentinel-1B ont été acquises, combinées à des mesures optiques issues des capteurs Sentinel-2A et Sentinel-2B. Ces images allient à la fois la haute fréquence temporelle à la haute résolution spatiale. La fiabilité, la disponibilité et la gratuité des données, ont justifié le choix de ces capteurs pour permettre un suivi régulier et pertinent.

##### 2.2.1.1.1. Caractéristiques du capteur Sentinel-1

La constellation Sentinel est lancée dans le cadre du programme Copernicus, par l'Agence Spatiale Européenne (ESA) pour des applications opérationnelles d'accès aux informations environnementales pour l'observation et la surveillance de la surface terrestre. Sentinel-1 est le premier parmi plusieurs autres capteurs s'inscrivant dans le cadre de ce programme comprenant les satellites Sentinel-2 (Imageur multi-spectral), Sentinel-3 (Radiomètres, Imageur multi spectral, altimètre), Sentinel-4 (sondeur infrarouge et ultraviolet), Sentinel-5 (sondeur infrarouge et ultraviolet) et Sentinel-6 (altimètre).

Sentinel-1A et Sentinel-1B sont deux satellites partageant la même orbite, constituant une constellation. Lancés respectivement en Avril 2014 et 2016, les deux satellites produisent des images par Radar à Synthèse d'Ouverture (RSO) en bande C (5,4 GHz) et avec une résolution spatiale très fine variant entre 10 et 40 m (Tableau 2. 1). Les RSO sont insensibles aux conditions météorologiques et permettent d'obtenir des images de jour comme de nuit. Ayant chacun une durée de revisite de 12 jours et vu qu'ils opèrent sur le même plan d'orbite, cela implique une revisite tous les six jours entre les deux, avec les deux modes : Ascendant et Descendant. Les instruments mettent à disposition des images à simple polarisation et à double polarisation selon les quatre combinaisons de transmission-réception (en polarisation parallèle (HH ou VV) ou croisée (HV ou VH)) :

HH : transmission et réception horizontales

VV : transmission et réception verticales

HV : transmission horizontale et réception verticale

VH : transmission verticale et réception horizontale

**Tableau 2. 1:** Caractéristiques du capteur radar Sentinel-1

Satellite	Sentinel-1A / Sentinel-1B
<b>Résolution spatiale</b>	Entre 5 et 40 m
<b>Revisite temporelle</b>	6 jours
<b>Fréquence</b>	5.4 GHz
<b>Hauteur de l'orbite</b>	693 km
<b>Polarisation</b>	parallèle (HH, VV) croisée (VV+VH, HH+HV)
<b>Orbite</b>	Ascendant /descendant
<b>Angle d'incidence</b>	20° et 46°

Les images sont produites en format niveau-1 SLC (Single Look Complex) ou niveau-1 GRD (Ground Range Detected). Les produits SLC sont les images où chaque pixel est représenté par une valeur complexe qui contient à la fois l'amplitude et la phase, ils sont disponible spécifiquement pour des zones limitées. Les produits GRD sont des produits multi-lookés, projetés et détectés ce qui permet d'avoir des images avec un chatoiement (le bruit speckle) réduit. Les valeurs de pixels de l'image sont représentées simplement en amplitude (l'information sur la phase est alors perdue) (ESA, 2017).


Le radar Sentinel-1 opère en quatre modes différents (Figure 2.6) selon les applications thématiques à résoudre (ESA, 2018):

**Strip Map (SM) :** C'est un mode d'imagerie radar standard où l'empreinte au sol est illuminée avec une séquence continue d'impulsions. Le déplacement du satellite sur son orbite permet la formation des images. Le mode SM acquiert des données avec une largeur de bande de 80 km à une résolution proche de 5 m à visée simple. Il sert comme mode d'acquisition de données pour d'autres capteurs comme les capteurs TerraSAR-X, Radarsat-2 et Alos.

**Interferometric Wide Swath Mode (IW) :** C'est un mode d'acquisition pour le suivi terrestre avec une fauchée de 250 km. Il acquiert selon une composition de trois sous-bandes, en utilisant la technique d'imagerie TOPSAR « Terrain Observation with Progressive Scans SAR ». Cette technique permet de balayer la surface avec une longue rafale et fait dévier l'antenne tout au long de l'acquisition de manière cyclique entre les trois sous-bandes.

**Extra Wide Swath Mode (EW) :** Similaire au mode IW, le mode EW utilise également la technique TOPSAR mais avec une plus grande couverture de bande, de largeur 400 km avec une résolution de 20x40 m, obtenue à partir de l'imagerie de 5 sous-bandes. Ce mode est destiné principalement pour le suivi des glaciers, des zones maritimes et polaires.

Wave Mode (WV) : Ce mode permet d'acquérir de petites scènes (appelées aussi vignettes) de 20x20 km, à une résolution spatiale de 5 m, avec un intervalle de 100 km entre les vignettes en polarisation VV ou HH. Chaque vignette étant traitée comme une image distincte. Ce sous-échantillonnage permet de générer un faible volume de données. Les vignettes sont acquises en mode "bissectile", avec une alternance sous deux angles d'incidence différents, c'est-à-dire qu'une vignette est acquise à un angle d'incidence proche de la distance tandis que la vignette suivante est acquise à un angle d'incidence à longue portée. Ce mode est conçu spécialement pour des applications océaniques.



**Figure 2. 6:** Les quatre modes d'acquisitions du capteur Sentinel-1: SM, IW, EW et WV (Source : ESA, 2018)

Dans notre cas d'étude, les images S-1A et S-1B ont été acquises sur le site de la plaine de Kairouan avec des mesures en polarisation VV et VH et des angles d'incidence entre 39° et 40° (Tableau 2.2).

**Tableau 2. 2:** Dates d'acquisitions et configurations des images radar S-1A et S-1B entre les deux années agricoles 2015-2016 et 2016-2017

2015-2016				2016-2017			
Capteurs	Dates d'acquisition	Polarisations	Angles d'incidence	Capteurs	Dates d'acquisition	Polarisations	Angles d'incidence
S-1A	06/12/2015	VV+VH	39° - 40°	S-1A	29-30/11/2016	VV+VH	39° - 40°
S-1A	17-18/12/2015	VV+VH	39° - 40°	S-1A	11-12/12/2016	VV+VH	39° - 40°
S-1A	29-30/12/2015	VV+VH	39° - 40°	S-1A	23-24/12/2016	VV+VH	39° - 40°

<b>S-1A</b>	10-11/01/2016	VV+VH	39° - 40°	<b>S-1A</b>	04-05/01/2017	VV+VH	39° - 40°
<b>S-1A</b>	22-23/01/2016	VV+VH	39° - 40°	<b>S-1B</b>	11-12/01/2017	VV+VH	39° - 40°
<b>S-1A</b>	03-04/02/2016	VV+VH	39° - 40°	<b>S-1A</b>	16-17/01/2017	VV+VH	39° - 40°
<b>S-1A</b>	16-16/02/2016	VV+VH	39° - 40°	<b>S-1B</b>	22-23/01/2017	VV+VH	39° - 40°
<b>S-1A</b>	27-28/02/2016	VV+VH	39° - 40°	<b>S-1A</b>	28-29/01/2017	VV+VH	39° - 40°
<b>S-1A</b>	10-11/03/2016	VV+VH	39° - 40°	<b>S-1B</b>	03-04/02/2017	VV+VH	39° - 40°
<b>S-1A</b>	22-23/03/2016	VV+VH	39° - 40°	<b>S-1A</b>	09-10/02/2017	VV+VH	39° - 40°
<b>S-1A</b>	03-04/04/2016	VV+VH	39° - 40°	<b>S-1B</b>	15-16/02/2017	VV+VH	39° - 40°
<b>S-1A</b>	15-16/04/2016	VV+VH	39° - 40°	<b>S-1A</b>	21-22/02/2017	VV+VH	39° - 40°
<b>S-1A</b>	27-28/04/2016	VV+VH	39° - 40°	<b>S-1B</b>	27-28/02/2017	VV+VH	39° - 40°
				<b>S-1A</b>	05-06/03/2017	VV+VH	39° - 40°
				<b>S-1B</b>	11-12/03/2017	VV+VH	39° - 40°
				<b>S-1A</b>	17-18/03/2017	VV+VH	39° - 40°
				<b>S-1B</b>	23-24/03/2017	VV+VH	39° - 40°
				<b>S-1A</b>	29-30/03/2017	VV+VH	39° - 40°

On dispose de 61 images, qui ont été collectées entre Décembre 2015 et Mars 2017, en concordance avec des mesures effectuées sur le terrain, au format GRD niveau-1, en mode IW, à une résolution spatiale de 10 m, tous les 6 à 12 jours. Le processus de traitement est présenté dans la section suivante.

#### **2.2.1.1.2. Traitement des données radars**

Les images S-1 nécessitent des étapes de prétraitement afin de les rendre utilisables. Cette phase consiste à calibrer radiométriquement les images, à corriger et diminuer les distorsions géométriques liées aux reliefs et appliquer un filtre réduisant le chatoiement sur toute la série temporelle. Le traitement des images radars a été effectué par la Sentinel Toolbox implémentée dans le logiciel SNAP (Sentinel Application Platform) développé par l'ESA pour traiter les images satellitaires (<https://step.esa.int/main/toolboxes/snap/>).

##### *- Calibration radiométrique*

La première étape pour le traitement des images radars consiste à calibrer les images. La calibration radiométrique se base essentiellement sur la représentation de la rétrodiffusion selon un coefficient de rétrodiffusion (les valeurs numériques pour chaque pixel). Le coefficient de rétrodiffusion est proportionnel au rapport entre la puissance reçue et la puissance émise de l'antenne. C'est donc une grandeur physique sans dimension qui dépend non seulement des paramètres propres du capteur tel que l'angle

d'incidence, la polarisation et la longueur d'onde, mais aussi des paramètres de surface qui représentent les propriétés diélectriques et géométriques de la surface (humidité du sol, rugosité de surface et diffuseurs). Il est généralement exprimé en décibels selon l'équation suivante :

$$\sigma_{ab}^0 = 10 \log \sigma_{lin}^0 \quad (15)$$

Où  $\sigma_{lin}^0$  le coefficient de rétrodiffusion en linéaire exprimant la valeur naturelle de chaque pixel de l'image.

L'utilisation d'une échelle logarithmique est beaucoup plus pratique et représentative que l'utilisation du coefficient de rétrodiffusion exprimé en linéaire.

- *Réduction du chatoiement ou du Speckle*

Le chatoiement ou Speckle est un bruit multiplicatif, représenté par une granulométrie provoquée par une interférence de construction et de destruction aléatoire des ondes réfléchies entraînant un bruit poivre et sel tout au long de l'image, spécifique aux images radars (Maher, 1997).

Le filtrage spatial d'une image consiste à éliminer ce bruit pour faciliter l'interprétation et l'utilisation d'une image. Le bruit se produit généralement lors de la numérisation de l'image. Il consiste simplement à remplacer chaque niveau de gris par une combinaison linéaire des niveaux de gris des points voisins, en préservant les éléments structuraux de l'image. De nombreux algorithmes ont été développés pour réduire le Speckle des images radars (Bovik et al., 1983 ; Frost et al., 1982 ; Lee, 1981 ; Lopes et al., 1990)

Dans notre cas, un filtre de Lee (Lee, 1983 ; Lee, 1981) a été appliqué sur les images en calculant des paramètres statistiques tels que la moyenne et la variance locale, il est basé sur un algorithme qui minimise l'erreur quadratique moyenne pour réduire la dispersion, et conserve la valeur moyenne des pixels de la zone. Il réduit le chatoiement tout en préservant les contours et les contrastes des objets.

- *Correction géométrique*

La distorsion et la modification géométrique au niveau d'une image brute est le résultat du mouvement de l'orbite ascendant ou descendant, des effets topographiques des reliefs et de la géométrie de visée latérale du capteur (mesure la distance des objets obliquement) qui apparaissent sous des formes sombres sur l'image (appelées « Effets d'ombres » ou « Shadowing »). La correction géométrique corrige l'image des distorsions géométriques à l'aide d'un modèle numérique de terrain (MNT) pour passer à une géométrie plane. Un SRTM 3sec (Shuttle Radar Topography Mission) a été choisi comme entrée pour le traitement des données d'élévation. La zone de Kairouan présente peu de reliefs, elle est donc très peu affectée par les déformations géométriques.

Les images sont ensuite projetées selon un système de coordonnées géographiques bien déterminé. Le système de projection utilisé dans ce cas d'étude est le système WGC 84, UTM zone 32N. En sorties, les coefficients  $\sigma^0$  en polarisation VV et VH sont alors obtenus, ainsi que l'angle d'incidence ( $\theta$ ) en °.

Par la suite, le comportement du coefficient de rétrodiffusion est étudié sur les parcelles tests, qui ont été identifiées comme des régions d'intérêt (ROI : Region Of

Interest), relevées sur le terrain. Le coefficient de rétrodiffusion est ensuite moyenné sur chaque polygone de parcelle, et converti en décibels.

Les différentes étapes de traitement sont nécessaires pour pouvoir analyser les relations entre les états de surface et la réponse radar tout en essayant d'établir des liens entre les réponses des coefficients de rétrodiffusions avec les propriétés diélectriques (humidité du sol, contenu en eau de la végétation) et géométriques (rugosité, taille orientation des feuilles, densité du couvert végétal) de la surface.

### 2.2.1.2. Données optiques

De nombreuses études ont montré le potentiel des données optiques principalement pour le suivi des surfaces agricoles et l'estimation les différents paramètres du couvert végétal. Une série d'images Landsat-8 a été utilisée entre 2015 et 2016 en tant que données auxiliaires et une série d'images Sentinel-2A entre 2015 et 2017. Les dates d'acquisitions des images optiques correspondent approximativement à des dates proches des acquisitions des images radars.

#### 2.2.1.2.1. Landsat-8

LDCM (Landsat Data continuity Mission) est une série de satellites Landsat, lancée par la collaboration entre l'agence spatiale américaine NASA (National Aeronautics and Space Administration) et l'institut des études géologiques américain (United States Geological Survey : USGS). Le programme est destiné à fournir des observations pour la surveillance de l'occupation des sols et la gestion des territoires, la géologie ou encore le suivi du changement climatique et son impact sur l'environnement. Le programme comporte une famille de 8 satellites (Landsat) destinés à fournir des observations de la terre dans le domaine du visible, l'infrarouge et infrarouge thermique.

Le satellite Landsat-8 a été lancé par la NASA en Février 2013 et diffusé par l'USGS. C'est un radiomètre spectral, qui couvre la terre tous les 16 jours, offrant 11 bandes spectrales entre le visible et le thermique avec une résolution spatiale de 30 m (Visible, Proche infrarouge, moyen infrarouge), 100 m (thermique) et 15 m (panchromatique).

Ces images ont été corrigées des effets atmosphériques, en utilisant l'algorithme LEDAPS (Landsat Ecosystem Disturbance Adaptive Processing System), élaboré par la NASA utilisant le modèle de transfert radiatif 6S (Seconde Simulation d'un Signal Satellite dans le Spectre Solaire) pour convertir les données brutes en réflectances de surface. Le code 6S se base sur la modélisation de transferts radiatifs en simulant les flux directs et diffus arrivant au sol en tenant compte des caractéristiques atmosphériques tels que les aérosols, la vapeur d'eau, l'ozone, le méthane, et le dioxyde de carbone, etc.

Ces images ont été utilisées pour caractériser le couvert végétal de la zone. L'indice de végétation par différence normalisée NDVI (Normalized Difference Vegetation Index) est extrait des réflectances, les bandes 4 et 5 correspondant au rouge et au proche infrarouge respectivement. Il est exprimé selon la formule suivante:

$$NDVI = \frac{R_{NIR} - R_{RED}}{R_{NIR} + R_{RED}} \quad (16)$$

Où RED: Rouge ; NIR : Proche-Infrarouge (PIR)

RNIR représente la réflectance dans le Proche-Infrarouge (PIR) et RRED représente la réflectance dans le Rouge.

### 2.2.1.2.2. *Sentinel-2*

Sentinel-2A (S-2A) est un imageur spectral, lancé et mis en orbite en Juin 2015 dans le cadre du programme « Copernicus » par l'ESA avec succès, suivi de Sentinel-2B (S-2B) en Mars 2017, permettant un suivi régulier avec une répétitivité temporelle de 5 jours des deux satellites réunis et tous les 10 jours avec un seul satellite. Ils offrent 13 bandes spectrales entre le visible et l'infrarouge avec une résolution spatiale entre 10 m (pour le visible et proche infrarouge, 20 m (pour Red Edge et moyen infrarouge) et 60 m (pour la détection des nuages) (Tableau 2.3). les deux satellites circulent sur une orbite héliosynchrone de 10h30, avec un déphasage de 180° l'un par rapport à l'autre. Ils balayent la surface du sol avec une fauchée de 290 km, avec une fréquence de revisite de 5 jours.

**Tableau 2. 3:** Caractéristiques des bandes spectrales du capteur Sentinel-2

Bandes spectrales	Longueur d'onde (nm)	Résolution spatiale (m)
<b>Bande 1 (Aérosol)</b>	443	60
<b>Bande 2 (Bleu)</b>	490	10
<b>Bande 3 (Vert)</b>	560	10
<b>Bande 4 (Rouge)</b>	665	10
<b>Bande 5 (Végétation Red Edge)</b>	705	20
<b>Bande 6 (Végétation Red Edge)</b>	740	20
<b>Bande 7 (Végétation Red Edge)</b>	783	20
<b>Bande 8 (PIR)</b>	842	10
<b>Bande 8A (Végétation Red Edge)</b>	865	20
<b>Bande 9 (Vapeur d'eau)</b>	945	60
<b>Bande 10 (MIR)</b>	1375	60
<b>Bande 11 (MIR)</b>	1610	20
<b>Bande 12 (MIR)</b>	2190	20


L'objectif de ce programme est d'assurer une acquisition continue des données pour un suivi multi-temporel, poursuivant ainsi la collecte des données réalisée par les missions Landsat de la NASA et Spot du CNES (Centre National des Etudes Spatiales) avec une amélioration de la résolution spatiale et temporelle, mais surtout offrant des produits gratuits et accessibles au monde de la recherche. Le suivi permet donc de collecter des informations sur le sol, le couvert végétal et les forêts.

Les images Sentinel-2 ont été téléchargées depuis le site Français THEIA, « Pôle Thématique Surfaces Continentales » (<https://www.theia-land.fr/>). Le site offre notamment des données sur la Tunisie au format Niveau 2A, dans une projection cartographique standard (Dans ce cas, c'est la projection WGS 84 UTM Zone 32). La chaîne de traitement MAJA (MACCS-ATCOR Joint Algorithm), développé par le CNES et le Centre des Etudes Spatiales de la BIOSphère (CESBIO), a été appliquée sur l'ensemble des données issues de S-2 pour détecter les nuages et leurs ombres et corriger des effets atmosphériques (Hagolle et al., 2010). Les données sont disponibles sous forme de tuile pour les deux imageurs S-2A et S-2B. L'accès aux données est libre et gratuit.


Les images contiennent donc des données de réflectances de surface, des données sur les effets atmosphériques, ainsi que des données avec une correction supplémentaire qui prennent en compte les effets de pente et un masque de « no data », de pixels saturés et de nuages pour les deux résolutions 10 et 20 m.

A partir de la série temporelle acquise entre 2015 et 2017, l'indice spectral NDVI a été calculé à partir des images S-2A selon des dates d'acquisition proche des données radars, vu que la végétation n'évolue pas aussi rapidement (10 jours approximativement entre les deux acquisitions). Les bandes 4 et 8 du Rouge et du Proche-Infrarouge ont été utilisées pour calculer l'indice.

Les Figures 2.7 montrent la différence entre une image optique dérivée (NDVI calculé à partir des bandes spectrales) du capteur Sentinel-2 et une image radar en polarisation VV du capteur Sentinel-1. Sur l'image radar S-1, on peut difficilement distinguer les parcelles agricoles contrairement à l'image optique S-2, les données radars offrent des informations précises et stables, et présentent une forte sensibilité aux paramètres de surface. Par ailleurs, vu les conditions météorologiques, la disponibilité des images optiques est réduite, et présente un facteur limitant pour une acquisition régulière de données. C'est sur ces constats que l'étude s'est basée sur une approche combinant d'images optiques et radars à haute résolution pour le suivi de l'état hydrique de surface dans le contexte semi-aride de la région de Kairouan.



(a)




(b)

**Figure 2. 7:** Différence entre: a) une image optique issue d'une bande spectrale du capteur S-2 et b) une image radar issue du capteur S-1, selon la même résolution spatiale (10 m)

### 2.2.1.3. Comparaison entre les images Landsat-8 et les images Sentinel-2


Une analyse basée sur la comparaison entre les produits Landsat-8 et Sentinel-2A a été élaborée pour valider les produits dérivés de S-2 (Figure 2.8). Les résultats ont montré que les valeurs de NDVI issues des capteurs sont cohérentes avec une valeur de RMSE très faible de l'ordre de 0.02 et de  $R^2$  égale à 0.97.



**Figure 2. 8:** Comparaison entre le NDVI dérivé des images S-2 et le NDVI dérivé des images L-8

### 2.2.2. Campagnes expérimentales et mesures sur le terrain

Les campagnes de mesures ont été réalisées sur la plaine de Kairouan, principalement sur deux saisons agricoles : le premier cycle commence au début du mois de Décembre 2015 jusqu'à la fin du mois d'Avril 2016, le deuxième entre Novembre 2016 et Mars 2017. Vu que les cultures céréalières dominent la plaine de Kairouan, et représentent majoritairement les cultures d'hiver, les parcelles de référence se mélangent entre des parcelles de sol nu et des parcelles de céréales (Tableau 2.4, Figure 2.9). Les caractéristiques des parcelles sont très hétérogènes. Cette hétérogénéité concerne les superficies, la texture du sol (parcelle limoneuse, argileuse ou sableuse) et l'irrigation (parcelle en irrigué ou en pluvial). On peut donc trouver de petites parcelles avec une superficie de 1 ha et d'autres avec des superficies qui peuvent atteindre 15 ha. La période d'étude s'est étalée principalement entre le mois de Décembre et de Mars, qui couvre l'intégralité du cycle phénologique de la culture et qui correspond également à la période de semis et le maximum de développement du couvert.



**Figure 2. 9 :** Localisation des parcelles de référence (de sol nu et de céréale) sur la plaine de Kairouan

**Tableau 2. 4 :** Brève description des parcelles de référence sélectionnées sur les deux années agricoles 2015-2016 et 2016-2017

Occupation de sol	2015 - 2016	2016 - 2017
Sol nu	P2, P4, P5, P6, P8a, P10, P18, P21, P21b	P5, P12, P18
Jachère	P2b, P9, P15, P22	P10, P15
Blé irrigué	P1, P3, P7, P8b, P11, P12, P13, P16, P19,	P1, P3, P7, P8, P11, P14b, P16, P16b, P19, P22
Blé pluvial	P14	P2b, P4, P6, P14, P21

### 2.2.2.1. Paramètres du sol

Les mesures expérimentales sont constituées principalement de mesures des propriétés du sol (l'humidité et la rugosité de surface) et des mesures des paramètres de la végétation (LAI, hauteur du couvert et contenu en eau de la végétation). Une première analyse qualitative des données terrain permet de mettre en évidence plusieurs résultats caractéristiques de la zone.

### **2.2.2.1.1. Mesure de l'humidité du sol**

Le suivi de l'humidité est très important pour la caractérisation de l'état hydrique du sol, outre le développement de la végétation. En effet, l'humidité du sol est très contrastée sous l'effet des conditions météorologiques (sécheresse et pluviométrie) et de l'irrigation ou sous l'effet de la nature du sol. Une forte dynamique temporelle s'ajoute alors à la variabilité spatiale. La plaine de Kairouan a connu entre ces deux années (2015-2016 et 2016-2017) une période de sécheresse lors de la première année (2015-2016) et une période relativement humide lors de la seconde année agricole (2016-2017). La zone a donc connue une forte dynamique concernant l'humidité de surface due aux conditions climatiques, à laquelle s'ajoute la variabilité spatiale de la texture du sol (sableux, argileux-limoneux, argileux) et le travail du sol (labour fin, labour en sillon ou un labour grossier) de chaque parcelle.

Le signal radar en bande C ne pénètre que dans la couche superficielle du sol, c'est-à-dire les premiers centimètres du sol. On s'est donc intéressé à la mesure de ce paramètre dans les cinq premiers centimètres du sol au moment du passage du satellite (chaque 12 jours (S-1A) entre 2015 et 2016 et chaque six jours (S-1A et S-1B) entre 2016 et 2017). Les mesures ponctuelles ont été alors effectuées au sein de chaque parcelle de céréales et de sol nu aléatoirement de manière bien répartie, par une sonde portable Thetaprobe ML2x qui atteint une profondeur de 5 cm dans le sol. Sur chaque parcelle test, une vingtaine de mesures sont prélevées à chaque passage du satellite. Elles seront moyennées par la suite pour représenter le taux d'humidité pour chaque parcelle et par date. Ces mesures de Thetaprobe ont été calibrées avec des mesures gravimétriques dans des campagnes précédentes par l'équipe sur le même site d'étude (Zribi et al., 2011). En effet, les mesures gravimétriques consistent à prélever, sécher des échantillons du sol dans une étuve à 100°C pendant 48h, et les peser avant et après le séchage.

Particulièrement, les mesures de l'humidité du sol peuvent être très variables suite à une irrigation ou un événement pluvieux. Lors de ces campagnes de mesures, les acquisitions satellitaires et les mesures sur le terrain ont été réalisées de manière quasi-synchrone, dans un délai qui ne dépasse pas les 2 heures.




**Figure 2. 10** : Un Thetaprobe ML2x pour la mesure de l'humidité du sol

Le climat semi-aride de la région est caractérisé par une forte variabilité des précipitations, ce qui révèle une large variabilité du taux d'humidité dans le sol, oscillant entre 3.9 vol. % et 45 vols. % sur les deux années agricoles.

#### **2.2.2.1.2. Mesure de la rugosité de surface**

La rugosité du sol est l'une des caractéristiques géométriques du sol. Elle représente la variation de la hauteur micro-topographique de la surface du sol, formée par des sillons ou des mottes, dus à un labour du sol. Elle est donc prélevée pour chaque changement d'état de surface du à des événements de pluie intensifs ou des travaux du sol (labour, sillons, semis, etc.). Elle est décrite selon deux paramètres statistiques essentiels : l'écart-type des hauteurs (Hrms) et la longueur de corrélation (l). L'écart type des hauteurs définit la variabilité verticale de la rugosité et la longueur de corrélation décrit l'échelle horizontale de la variation des hauteurs.

Des mesures à l'aide d'un rugosimètre (ou profilomètre) à aiguilles sont effectuées sur les parcelles de sol nu. Constitué d'une cinquantaine d'aiguilles, espacées de 2 cm l'une de l'autre, le rugosimètre utilisé est de longueur 1 m. En se posant sur le sol, les aiguilles reproduisent le profil de la surface (Figure 2.11). Une photo du rugosimètre permet de figer le profil, matérialisé par ses extrémités. Sur les parcelles de suivies, à chaque changement d'état (surtout avant la semence des céréales en automne) cinq profils sont réalisés parallèlement au sens du travail de la parcelle, et cinq autres profils sont réalisés perpendiculairement pour prendre en considération l'effet directionnel du sens de labour. Les profils sont ensuite digitalisés pour extraire les deux paramètres statistiques de rugosité, soit la longueur de corrélation et l'écart-type des hauteurs.



**Figure 2. 11:** Exemple de profil de rugosité élaboré par un rugosimètre de 1 m: a) pour des sols lisses et b) des sols en labour

Pour un sol avec un labour assez profond, la rugosité présente des valeurs élevées de Hrms (avec des moyennes supérieures à 2 cm). Avec des valeurs de Hrms entre 1 et 2 cm, le labour est plutôt fin avec des sillons peu profonds. Les sols lisses ont des valeurs de rugosité très faibles ( $Hrms < 0.6$  cm) (Zribi et al., 2014). Pour les parcelles de céréales, les variations de la rugosité ne sont observées qu'avant la période de semis lors de la préparation du sol c'est-à-dire en automne et après la récolte, généralement vers le début de l'été. Entre les deux périodes, les valeurs de la rugosité demeurent quasi constantes lors de la semence des céréales et la croissance de la végétation, car il n'y a pas de travail du sol supplémentaire après la période de semis. La rugosité n'évolue alors que très faiblement et lentement sous l'effet de la pluie ou de l'irrigation.


#### 2.2.2.2. Paramètres de la végétation

La période de mesures pour la caractérisation du couvert végétal s'étale sur tout le cycle phénologique de la culture céréalière (blé et orge). Ces mesures concernent l'état de la végétation et représentent des mesures d'indice foliaire (Leaf Index Area : LAI), de la hauteur du couvert végétal et de contenu en eau. Le suivi du couvert est effectué chaque deux semaines environ, puisque la végétation n'évolue pas aussi rapidement durant cette période.

Des informations concernant les pratiques agricoles (dates d'irrigation, date de semis, type de fertilisants, etc.) sont aussi collectées auprès des agriculteurs de la région, et seront exploitées pour le traitement et l'analyse des données.

#### 2.2.2.2.1. *L'indice foliaire*

Le LAI est une variable biophysique qui caractérise les phénomènes de transfert radiatif entre la végétation et l'atmosphère. L'indice foliaire est une variable clé pour différents modèles hydrologiques et agronomiques. Il est défini comme étant l'aire d'une feuille par unité de surface au sol ( $m^2/m^2$ ). Différentes méthodes existent pour estimer les indices foliaires de surface et consistent en des mesures directes et indirectes.



**Figure 2. 12 :** Photos hémisphériques pour des mesures de LAI: a) lors du semis et b) lors l'épiaison

Les mesures de LAI ont été effectuées par des photo-hémisphériques avec un appareil photo et un objectif « Fish-Eye » dont le champ de vue est de  $180^\circ$  (Figure 2.12). Le principe de traitement des photos est basé sur la classification binaire (sol et végétation), en calculant la fraction de trou qui la relie à la structure du couvert (Baret et al., 2010 ; Demarez et al., 2008)

Sur chaque champ de céréale, une vingtaine de photos sont prises, en s'assurant que le soleil soit dans la même direction que la prise à 1 m environ au dessus de la végétation. Les mesures ont été effectuées durant les différents stades de développement végétatif du blé, sur chaque parcelle afin de prendre en compte l'hétérogénéité intra-parcellaire. Le LAI, ainsi que la fraction de couverture ( $F_c$ ) sont alors estimés par l'algorithme (Duchemin et al., 2008).

#### 2.2.2.2.2. *Hauteur de la végétation*


Les mesures de LAI sont accompagnées par des mesures de la hauteur du couvert pour chaque parcelle de céréale. Une vingtaine de mesures sont considérées et moyennées sur chaque champ afin d'obtenir une valeur représentative de la hauteur de culture pour chaque stade de développement. Les valeurs des hauteurs varient entre 0 et 110 cm qui représentent généralement le stade maximal de croissance pour l'orge et le blé, atteint vers la fin du mois de Mars et le début du mois d'Avril.

### 2.2.2.2.3. Contenu en eau de la végétation

Le contenu en eau caractérise l'état physiologique et biochimique de la végétation. C'est un paramètre clé pour comprendre différents processus, en outre il représente un bon indicateur de stress hydrique chez la plante. Le protocole expérimental consiste à positionner un cadre (de dimensions 35 cm x 35 cm) aléatoirement sur une parcelle et de prélever le contenu de la végétation sur le cadre. Trois échantillons sont prélevés pour chaque parcelle lorsque la végétation a atteint une certaine hauteur et un certain stade de développement. Ces derniers sont alors pesés et séchés dans une étuve à 70°C pendant 48 heures. Après séchage, les échantillons sont alors pesés afin de déterminer la quantité d'eau dans la plante. Les campagnes sont réalisées sur les deux saisons agricoles, pour les différents stades de développement de la culture. Et en moyenne, trois prélèvements sont effectués par cycle végétatif et pour toutes les parcelles céréalières. Les valeurs du contenu en eau augmentent après une irrigation ou des événements pluvieux et diminuent lorsque la culture a atteint le maximum de croissance (c'est-à-dire vers la fin du mois de Mars).

### 2.2.2.2.4. Relations entre les paramètres de la végétation

Les Figures 2.13 montrent la relation qui relie le LAI à la hauteur du couvert et au contenu en eau de la végétation. Les figures montrent alors que pour les deux cas la relation évolue selon une loi logarithmique. Une forte corrélation existe entre les trois paramètres de la végétation, surtout lors de la phase de croissance de la culture (entre Janvier et début Avril). Cependant, cette corrélation diminue avec la phase de maturation du blé et le développement de l'épi avec une diminution du contenu en eau de la végétation. Dès que le LAI atteint la valeur de 3 m<sup>2</sup>/m<sup>2</sup>, les relations entre les paramètres se dispersent.



**Figure 2. 13:** Relation entre la hauteur de la végétation, le contenu en eau et le LAI établie sur les parcelles de référence

### 2.2.2.3. Collecte de données sur l'irrigation

A l'échelle de la plaine de Kairouan, une enquête a été réalisée pour recenser les parcelles irriguées et non-irriguées sur plusieurs secteurs. L'objectif de cette enquête est de recueillir des informations pour identifier les parcelles en irrigué et les parcelles en pluvial. Il s'agit donc de collecter des informations sur la localisation de différentes parcelles qui sont réparties sur toute la plaine, on note également le système d'irrigation ainsi que la


durée et la fréquence d'arrosage, par des observations et enquêtes auprès des agriculteurs de la région.

La première année (2015-2016) était une année marquée par une longue période relativement sèche, avec une pluviométrie inférieure à 120 mm, couvrant la période entre le mois de Novembre et le mois de Juin, enregistrée par la station météorologique INGC (Institut National des Grandes Cultures, 9°56'16"E; 35°37'15"N). La plupart des agriculteurs ont réalisé une irrigation durant tout le cycle. L'humidité du sol pour les zones non-irriguées ne dépassait pas les 10 vols. %, tandis que les parcelles irriguées avait des valeurs d'humidité assez élevées (approximativement entre 20 et 40 vol. %). La seconde année agricole (2016-2017) était une année plus humide, caractérisée par une pluviométrie de 240 mm approximativement. Cette campagne s'est déroulée principalement entre les mois d'Avril et de Mars, où l'irrigation devient de plus en plus fréquente. Durant l'année 2017, 74 parcelles ont été recensées dont 46 représentent des parcelles irriguées et 28 parcelles non-irriguées. La superficie des parcelles varie entre 2 et 25 ha.

#### 2.2.2.4. Stations agro-météorologiques et stations de mesures de l'humidité du sol

Sur le bassin de Merguellil, on dispose de cinq stations agro-météorologiques et sept stations de mesures de l'humidité du sol. Le site est donc bien suivi sur le plan hydrométéorologique.

Pour le suivi de l'état hydrique du sol, trois stations de mesures ont été installées sur le site, composées de sondes à différentes profondeurs du sol (5 cm, 20 cm, 40 cm, 80 cm et 120 cm). En 2013, quatre autres stations ont été rajoutées au réseau de Merguellil pour compléter les mesures avec des acquisitions télétransmises tous les six heures.



(a)

(b)

**Figure 2. 14:** a) La station de mesure de l'humidité du sol et b) la station météorologique INGC, implémentées sur la plaine de Kairouan

Depuis 2009, quatre stations agro-météorologiques Chebika, Barroua, Sidi Ali Ben Salem et Nasrallah, ont été implantées de part et d'autres sur la plaine. Ces stations sont

constituées par un anémomètre et une girouette pour la mesure de la vitesse et la direction du vent, de sondes pour la température et l'humidité de l'air, d'un pyromètre pour le rayonnement global et un pluviomètre pour la précipitation. Ces stations fournissent des données météorologiques télétransmises, acquises au pas de temps de la demi-heure. Les données se résument donc à la température de l'air ( $^{\circ}\text{C}$ ), l'humidité relative (%), la vitesse du vent (m/s), le rayonnement global ( $\text{W}/\text{m}^2$ ) et la pluviométrie (mm).

La station météorologique la plus proche des parcelles de référence est la station INGC. Elle est sélectionnée pour le suivi de la pluviométrie de la zone d'étude, comme données supplémentaires pour analyser les cartes d'humidité du sol.

### **2.3. Conclusion partielle**

Ce chapitre présente la zone d'étude, la plaine de Kairouan pour l'estimation de l'humidité du sol et pour la cartographie de l'irrigation. La plaine de Kairouan est considérée comme l'une des plus importantes régions pour la production agricole. Avec une surexploitation des nappes de Kairouan et l'expansion des réseaux d'irrigation, la région fait face à plusieurs problèmes pour la gestion des ressources en eau.

La base de données, utilisée au cours de cette thèse, comprend des données de télédétection et les données mesurées sur le terrain. Les données Sentinel-1 et Sentinel-2 sont les principales données satellitaires utilisées pour le développement de la méthodologie. La base de données sera utilisée pour la méthodologie développée au cours de ce travail (dans les prochains chapitres) et pour valider l'approche utilisée.

Pour la cartographie de l'irrigation et de la texture du sol, les enquêtes sur le terrain et les analyses en laboratoires ont permis de développer les différentes approches.

# Chapitre 3: Analyses de sensibilité et modélisation de la rétrodiffusion

*Les analyses, la modélisation et les résultats de chapitre sont présentés dans l'article suivant:*

*Bousbib, 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, doi:10.3390/s17112617.*

*Publié dans le journal Sensors.*

## Sommaire

---

<b>CHAPITRE 3: ANALYSES DE SENSIBILITE ET MODELISATION DE LA RETRODIFFUSION .....</b>	<b>73</b>
3.1. INTRODUCTION .....	74
3.2. ANALYSES DE SENSIBILITE ET COMPORTEMENT DU SIGNAL RADAR .....	74
3.3. MODELISATION DE LA RETRODIFFUSION .....	75
3.3.1. <i>Modélisation sur sols nus</i> .....	75
3.3.2. <i>Modélisation sur un couvert végétal</i> .....	76
3.4. ARTICLE .....	77
3.5. ANALYSES SUPPLEMENTAIRES ET RESULTATS NON-PUBLIES .....	85
3.5.1. <i>Analyses de sensibilité du signal radar au contenu en eau de la végétation</i> .....	85
3.5.2. <i>Comparaison des résultats de la modélisation sur sols nus avec d'autres approches</i> .....	85
3.5.3. <i>Comparaison des résultats de la modélisation sur la végétation avec d'autres approches</i> .....	87
3.6. SYNTHÈSE ET CONCLUSION PARTIELLE .....	88

---

### 3.1. Introduction

L'humidité du sol, la rugosité de surface et les propriétés du couvert végétal sont les principaux paramètres, liés aux propriétés diélectriques et géométriques de surface, influençant le signal radar.

Les mesures expérimentales et les acquisitions multi-capteurs montrent de grandes opportunités d'exploitation de la base de données établie sur les parcelles de référence de la zone d'étude (la plaine de Kairouan). Une première partie de l'article concerne des analyses de sensibilité des données satellitaires pour l'évaluation des différents paramètres de surface. Cette analyse a déjà fait l'objet de plusieurs études scientifiques (Attema & Ulaby, 1978 ; Aubert et al., 2011 ; Bindlish & Barros, 2001 ; El Hajj et al., 2016 ; Fontanelli et al., 2013 ; Holah et al., 2005 ; Zribi et al., 2011 ; Zribi & Dechambre, 2002). Dans l'objectif de déterminer la configuration optimale (polarisation, fréquence et angle d'incidence) pour la caractérisation des paramètres du sol et de la végétation (humidité du sol, paramètre de la rugosité, LAI, hauteur de la végétation et contenu en eau), la réponse du signal radar à ces paramètres est alors étudiée. Ce type d'analyses est essentiel pour la formulation, la calibration et la validation des modèles de rétrodiffusion.

La deuxième partie de ce chapitre est consacrée à la modélisation de la rétrodiffusion qui permet de simuler le signal radar en fonction des caractéristiques physiques de la surface et des paramètres du capteur. Cette analyse vise à évaluer le potentiel des nouveaux instruments Sentinel-1 pour la restitution des paramètres du sol et les données optiques issues du capteur Landsat-8 pour les paramètres de la végétation. Une première modélisation de la rétrodiffusion est appliquée sur les parcelles de sols nus et une deuxième approche est utilisée sur les parcelles de céréale.

Dans les sections suivantes, on présente les analyses établies sur les données de la télédétection en fonction des paramètres de surface. La description des différents modèles utilisées est exposée dans la Section 3.2. L'article correspondant à ce chapitre est présenté dans la Section 3.4. La Section 3.5 comporte les analyses et les résultats supplémentaires obtenus. Un résumé des résultats obtenus et une conclusion de ce chapitre sont présentés à la Section 3.6.

### 3.2. Analyses de sensibilité et comportement du signal radar

Les résultats de ce chapitre reposent sur l'utilisation d'une base de données très riche sur deux années agricoles (2015-2016 et 2016-2017). Les analyses de sensibilité du signal radar se basent sur des relations empiriques entre les données satellitaires et l'humidité du sol, la rugosité, le LAI, la hauteur de végétation et son contenu en eau. Ces relations ont été établies sur les parcelles de référence. Pour les paramètres du sol, la relation qui relie le signal radar à l'humidité du sol, est linéaire et croissante (plus l'humidité du sol croît plus le signal augmente) (El Hajj et al., 2016 ; Fontanelli et al., 2013 ; M. Zribi et al., 2011). Cette sensibilité se voit néanmoins décroître avec le développement du couvert végétal, à partir d'un certain seuil de NDVI, dans les différentes configurations du capteur (les deux polarisations VV et VH) (Said et al., 2012). Ce qui permet d'expliquer le choix d'effectuer une analyse selon des classes de NDVI, allant des sols nus jusqu'au maximum de

développement de la culture. Pareillement, le signal radar croît avec la rugosité (l'écart-type des hauteurs, Hrms), selon une loi logarithmique (Shi et al., 1997 ; Srivastava et al., 2003 ; Zribi et al., 2014) et selon les deux classes d'humidité du sol (état sec et état humide), pour éliminer l'effet de cette dernière sur le signal.

Pour la végétation, le signal est analysé en fonction du LAI, de la hauteur de végétation et du contenu en eau, selon les différentes conditions d'humidité du sol (en séparant les sols secs et humides) et les deux polarisations du capteur VV et VH. Le signal répond différemment pour les deux polarisations. Le signal est plus sensible au LAI en polarisation VV qu'en polarisation VH et lorsque le sol est sec. Ceci peut être expliqué par deux phénomènes : la première concerne l'influence de l'humidité du sol sur le signal radar et la deuxième l'atténuation du signal par la densité du couvert végétal. Cette atténuation est principalement due à l'orientation verticale de la tige et au changement de la morphologie de la plante (le développement d'épis), d'où l'insensibilité du sol à la polarisation horizontale (Fontanelli et al., 2013).

Concernant la hauteur de la culture, deux comportements qui relient ce paramètre au signal radar sont observés. Le premier montre une diminution du signal lorsque la hauteur augmente pour la polarisation VV, similairement à ce qui a été obtenu pour le LAI. À l'inverse, le signal croît avec la hauteur de végétation en polarisation VH. Différents travaux ont confirmé des résultats similaires. Cette divergence peut être expliquée par le fait que les mesures sur le terrain ont commencé lorsque la hauteur de la végétation était d'environ 10 à 15 cm, à la suite des premières campagnes LAI. Cela signifie que l'influence du sol était plus faible et que la diffusion volumique de la végétation peut dominer les signaux radars rétrodiffusés. Les travaux de Fieuzal et al. (2013) sur la culture de blé ont montré que pour une hauteur comprise entre 3 cm et 50 cm environ, le signal radar diminuait de 1,3 dB à mesure que la hauteur du blé augmentait de 10 cm. En revanche, il augmentait avec la hauteur lorsqu'elle dépassait les 50 cm.

### **3.3. Modélisation de la rétrodiffusion**

Les modèles de rétrodiffusion, basés sur la théorie de transfert radiatif, visent à comprendre l'interaction de l'onde électromagnétique et la surface (le milieu) et représentent un outil d'analyse pour interpréter la relation entre le signal radar et les états de surface. Les modèles de rétrodiffusion reproduisent un signal radar de la manière la plus réaliste possible. Ils s'appuient généralement sur les paramètres de surface (en particulier la rugosité, l'humidité du signal et paramètres de la végétation) et les caractéristiques de capteur (polarisation, longueur d'onde et angle d'incidence).

La rétrodiffusion va donc dépendre soit des propriétés du sol ou de la végétation, d'où la considération de deux modèles de rétrodiffusion : sur les sols nus et sur les couverts végétaux. Ces modèles sont entre autres inversés afin de restituer les paramètres de surface.

#### **3.3.1. Modélisation sur sols nus**

Dans un premier temps, le signal radar a été simulé sur les parcelles de sol nu, considérant comme paramètres la rugosité et l'humidité du sol mesurées sur le terrain. Le modèle semi-empirique, proposé par Zribi et al. (2014), est très simple, nécessite peu de

paramètres en entrée et a testé sur une large gamme de validité. Les signaux radars sur des sols nus sont modélisés à l'aide d'une expression empirique simple, qui inclut une relation linéaire en ce qui concerne l'humidité du sol et un comportement logarithmique en ce qui concerne la rugosité (l'écart-type des hauteurs).

### 3.3.2. Modélisation sur un couvert végétal

Le modèle WCM est un modèle semi-empirique, développé par Attema et Ulaby (1978) sur des couverts végétaux, et se base sur une solution d'un modèle de transfert radiatif de premier ordre, utilisant comme paramètre le NDVI pour décrire la végétation, dérivé des images L-8. Comme il a été décrit dans la partie de l'état de l'art dans le premier chapitre, le modèle WCM relie la contribution de la végétation et la contribution du sol au signal radar.

$$\sigma^0 = \sigma_{\text{vég}}^0 + \sigma_{\text{vég-sol}}^0 + \tau^2 \sigma_{\text{sol}}^0 \quad (12)$$

Où  $\sigma_{\text{vég}}^0$  Le coefficient de rétrodiffusion du couvert végétal représenté par l'équation suivante :

$$\sigma_{\text{vég}}^0 = A \cdot \text{NDVI} \cdot \cos \theta \cdot (1 - \tau^2) \quad (13)$$

$\sigma_{\text{vég-sol}}^0$  Le coefficient de rétrodiffusion dû à l'interaction entre le couvert et le sol. Ce terme est souvent négligé dans notre cas.

$$\sigma^0 = \sigma_{\text{vég}}^0 + \tau^2 \sigma_{\text{sol}}^0 \quad (12)$$

$\sigma_{\text{sol}}^0$  Le coefficient de rétrodiffusion du sol.

$$\sigma_{\text{sol}}^0 = \alpha \cdot Mv + \beta$$

Où :

$\alpha$  et  $\beta$  sont les paramètres à calibrer, dépendants des conditions du sol, principalement de l'humidité du sol.

$Mv$  est l'humidité du sol mesurée par une sonde Thetaprobe.

$\tau^2$  La transmissivité de la végétation qui représente le facteur d'atténuation et s'exprime selon l'équation suivante :

$$\tau^2 = \exp(-2 \cdot B \cdot \text{NDVI} \cdot \sec \theta) \quad (14)$$

$A$  et  $B$  sont des paramètres empiriques dépendant du type de culture. Le NDVI va permettre de décrire le développement de la culture selon son stade de développement.

Comme dans le cas des sols nus, lorsque le modèle est validé avec un ensemble de parcelles de référence, le signal simulé est en bon accord avec les mesures réelles (RMSE égal à 0.84 dB). Malgré sa simplicité, le modèle de nuage d'eau est capable de décrire correctement le comportement des signaux radars, en fonction de l'humidité du sol et des

Chapitre 3: Analyses de sensibilité et modélisation de la rétrodiffusion  
paramètres de la végétation. Les paramètres d'étalonnage empiriques dérivés de cette  
analyse ont été adaptés pour les parcelles agricoles recouvertes de céréales

### **3.4. Article**

Article

# Potential of Sentinel-1 Radar Data for the Assessment of Soil and Cereal Cover Parameters

Safa Bousbih <sup>1,2,\*</sup>, Mehrez Zribi <sup>1,\*</sup>, Zohra Lili-Chabaane <sup>2</sup>, Nicolas Baghdadi <sup>3</sup>, Mohammad El Hajj <sup>3</sup>, Qi Gao <sup>1,4,5</sup> and Bernard Mougenot <sup>1</sup>

<sup>1</sup> CESBIO (CNRS/UPS/IRD/CNES), 18 Avenue Edouard Belin, 31401 Toulouse CEDEX 9, France; qi.gao@isardsat.cat (Q.G.); bernard.mougenot@ird.fr (B.M.)

<sup>2</sup> Université de Carthage / INAT/ LR GREEN-TEAM, 43 Avenue Charles Nicolle, Tunis 1082, Tunisia; zohra.lilichabaane@ucar.rnu.tn

<sup>3</sup> IRSTEA, UMR TETIS, 500 Rue François Breton, 34093 Montpellier CEDEX 5, France; nicolas.baghdadi@teledetection.fr (N.B.); mohammad.el-hajj@teledetection.fr (M.E.-H.)

<sup>4</sup> IsardSAT, Parc Tecnològic Barcelona Activa, Carrer de Marie Curie, 8, 08042 Barcelona, Spain;

<sup>5</sup> Observatori de l'Ebre (OE), Univ. Ramon Llull - CSIC, Spain.

\* Correspondence: safabousbih1@outlook.fr (S.B.); mehrez.zribi@cesbio.cnes.fr (M.Z.); Tel.: +33 56155 8501 (S.B.); Tel.: +33 56155 8525 (M.Z.)

Received: 12 September 2017; Accepted: 10 November 2017; Published: 14 November 2017

**Abstract:** The main objective of this study is to analyze the potential use of Sentinel-1 (S1) radar data for the estimation of soil characteristics (roughness and water content) and cereal vegetation parameters (leaf area index (LAI), and vegetation height (H)) in agricultural areas. Simultaneously to several radar acquisitions made between 2015 and 2017, using S1 sensors over the Kairouan Plain (Tunisia, North Africa), ground measurements of soil roughness, soil water content, LAI and H were recorded. The NDVI (normalized difference vegetation index) index computed from Landsat optical images revealed a strong correlation with in situ measurements of LAI. The sensitivity of the S1 measurements to variations in soil moisture, which has been reported in several scientific publications, is confirmed in this study. This sensitivity decreases with increasing vegetation cover growth (NDVI), and is stronger in the VV (vertical) polarization than in the VH cross-polarization. The results also reveal a similar increase in the dynamic range of radar signals observed in the VV and VH polarizations as a function of soil roughness. The sensitivity of S1 measurements to vegetation parameters (LAI and H) in the VV polarization is also determined, showing that the radar signal strength decreases when the vegetation parameters increase. No vegetation parameter sensitivity is observed in the VH polarization, probably as a consequence of volume scattering effects.

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

---

## 1. Introduction

Soil surface and vegetation cover play a key role in various processes at the soil-vegetation-atmosphere interface, such as evapotranspiration, infiltration and runoff [1-4]. They are also essential characteristics in agricultural contexts, since they can allow improved estimations of crop conditions and requirements to be derived, and can also facilitate the optimized management of irrigation. Surface parameters have long been based on field measurements that do not allow their spatio-

temporal variability to be retrieved. In this context, various studies based on optical and radar remote sensing have been proposed in the last 30 years in an effort to better characterize surface conditions and characteristics [5,6]. At present, various moisture products are proposed on a global operational basis. These are derived from microwave radiometric measurements (such as SMOS, AMSR-E) and/or scatterometer measurements (e.g., ASCAT), with a spatial resolution ranging between 10 and 40 km [7,8].

At the scale of individual agricultural fields, the monitoring of spatio-temporal variations in the vegetation's biophysical parameters, together with the soil's surface characteristics (water content in particular) can provide farmers with key information for the irrigation and management of their crops. Several methods have been developed to retrieve soil surface characteristics, especially surface roughness and soil moisture, from high (fine) spatial resolution synthetic aperture radar (SAR) data [9-20]. These techniques were considerably enriched by the launch of more advanced SAR sensors in the 2000s—ASAR/ENVISAT, RADARSAT, TerraSAR-X, and so forth—and make use of various types of algorithmic methods, including neural networks, look-up tables, and the inversion of physical or empirical models.

In the case of bare soils, the radar signal scattered by the surface depends on the roughness, as well as the dielectric constant of the first centimeters of soil. The latter is directly related to the soil's water content and the frequency of the radar sensor. The corresponding depth ranges from approximately 5 cm in the L-band to 1 cm in the X-band, in soils with a high water content [21]. Several studies have analyzed the behavior of the radar signal as a function of soil moisture content. Stronger signal sensitivity is observed at low incidence angles, between 20° and 35°, than at high incidence angles [22,23]. Different inversion approaches have been proposed, based on empirical or physical radar backscattering models (Oh model [24], IEM model [25], Dubois model [26], Baghdadi model [27], etc.). Inversion studies generally report an accuracy ranging between 3 and 6 vol. % in the case of bare soils [28-33].

Unlike the case of soil moisture, soil roughness estimations are most accurate when they are made at high angles of incidence [34], and the dynamic range of the backscattered radar signal associated with this parameter decreases as a function of increasing radar frequency [35]. The soil roughness description is based mainly on two statistical parameters: the root mean square surface height ( $H_{rms}$ ) and the correlation length of soil height variations ( $L$ ). Different approaches have been proposed to improve the roughness description [36-40]. Most experimental inversion studies have been restricted to the evaluation of just two or three roughness classes (smooth, medium, high) [41].

For surface with a vegetation cover, the backscattered radar signal depends on the characteristics of the soil and vegetation, as well as the radar configurations used for the observations. Various models have been developed in an effort to accurately retrieve soil parameters and to gain a clear understanding of the behavior of soil and vegetation components in the radar total backscattering coefficient [35].

These models are based primarily on solving the radiative transfer equation. The most commonly used model is the semi-empirical water cloud model [42], which considers the total signal to be the sum of contributions from the vegetation cover, together with a second contributor related to the soil, attenuated by its vegetation cover. Experimental studies using this model have shown that the vegetation-related terms in the model could be derived from different vegetation parameters, such as the vegetation water content or the leaf area index (LAI) [43,44]. In this context, remote sensing in the visible and infrared (i.e., "optical") spectral ranges has demonstrated its potential for the estimation of these vegetation parameters [45,46].

When it is used in synergy with optical data, SAR imagery can thus provide valuable estimations of both soil moisture and vegetation parameters [30,44,48]. Zribi et al. [30] estimated soil moisture using ASAR images (C-band) in synergy with SPOT-5 optical images recorded over wheat plots, using the Water Cloud model, with an accuracy of approximately 0.06 m<sup>3</sup>/m<sup>3</sup>. Fieuzal et al. [48] estimated the soil moisture over irrigated wheat plots using TerraSAR-X (TSX), Radarsat-2 and Advanced Land

Observing Satellite (ALOS)/Palsar data coupled with Formosat-2 and *Satellite Pour l'Observation de la Terre* (SPOT)-4/5 images. El Hajj et al. [44] combined X-band data retrieved from TSX with data derived from CosmoSky-Med (CSK) sensors, as well as NDVI, LAI, FAPAR (Fraction of Absorbed Photosynthetically Active Radiation) and FCOVER (Fraction of Cover) products from SPOT-4, SPOT-5, LANDSAT-7 and LANDSAT-8 images, using a water cloud model to obtain soil moisture estimations over grassland areas.

Despite the considerable contributions of optical data to the estimation of biophysical vegetation parameters, due to saturation effects, their application to the case of high or very dense vegetation (with high values of LAI) is often inadequate. Secondly, in the case of regions with a high average level of cloud cover, such as tropical zones, high quality optical acquisitions are very limited and/or infrequently recorded. In this context, several studies have also assessed the sensitivity of SAR signals at different radar wavelengths (mainly the L, C and X-bands) to vegetation conditions [49–52]. For example, Fontanelli et al. [52] revealed the high sensitivity of TSX and CSK data to increasing LAI in the case of cereal cover ( $\sim 0.6$  dB/1 m<sup>2</sup>/m<sup>2</sup>), with a coefficient of determination greater than 0.70. El Hajj et al. [44] also reported the high sensitivity of X-band data to LAI, when the soil moisture lies between 10 and 20 vol. % over grassland areas. Baghdadi et al. [51] analyzed the potential interpretation of TSX data as a function of sugarcane height, showing that the backscattering coefficient increases with crop height at a high incidence angle (47°).

The Sentinel-1 constellation was launched in 2014 (Sentinel-1A) and 2016 (Sentinel-1B), with both satellites carrying a C-band radar payload. Thanks to its short temporal repeat frequency (six days), as well as the high spatial resolution (10 m) provided by its payload, this constellation is making it possible to achieve regular operational estimations of the conditions and characteristics of the continental surface.

In this context, the main objective of the present study is to make use of a large database to analyze the potential of Sentinel-1 (S1) data for the assessment of different soil and cereal parameters. The synergetic use of S1 radar data with Landsat high-resolution optical data is also analyzed. Section 2 describes the study site, satellite images and ground measurement database. Section 3 provides a statistical analysis of the relationships established between the backscattered radar signal and the surface parameters (soil and vegetation). Section 4 discusses the performance of the different backscattering models for bare and covered soils. Our conclusions are provided in Section 5.

## 2. Study site and Database

### 2.1. Description of the Study Site

The study site is located on the Kairouan plain (9°23'–10°17' E, 35°1'–35°55' N; Figure 1), in Central Tunisia [30]. This region is exposed to a semi-arid Mediterranean climate, characterized by a dry summer season, with precipitation occurring mainly in autumn and spring, leading to an annual average rainfall of approximately 300 mm. This precipitation is highly variable in time and space, with frequently occurring drought events [30]. The average annual temperature is 19.2 °C, with the minimum occurring in January and the maximum in August. The average potential evapotranspiration is close to 1600 mm. The landscape in this area is mainly flat and the vegetation is dominated by agricultural plants (cereals, olive trees, and market gardens). Various different cereal crops are grown, and their rotation is typical of semi-arid regions. The Kairouan plain aquifer is the largest in central Tunisia. Surface and groundwater streams are drained into the Sebkhia Kelbia, a large salt lake.




Figure 1. Location of the study site in Tunisia.

## 2.2. Database

### 2.2.1. Satellite Data

#### (a) Sentinel-1 radar data

The first S-1A satellite was launched on 3 April 2014 and was followed by the S-1B Sentinel satellite on 25 April 2016. This dual-satellite constellation offers a six-day repeat frequency for all regions of the globe. The SAR payloads use a C-band frequency of 5.4 GHz and have the following standard operating modes: Strip Map (SM); Interferometric Wide Swath (IW); Extra Wide Swath (EW), and; WaVe (WV). In the present study, 10 IW S1 images were analyzed. They were characterized by a  $10 \times 10$  m spatial resolution, dual VV and VH polarization measurements, and an incidence angle of approximately  $39\text{--}40^\circ$  (Table 2). These were acquired between December 2015 and March 2017. All of the images were generated from the high-resolution, Level-1 Ground Range Detected (GRD) product. The data were preprocessed using the Sentinel-1 Toolbox, in four steps:

- Thermal noise removal;
- Radiometric calibration;
- Terrain correction using Shuttle Radar Topography Mission (SRTM) Digital Elevation Model (DEM) at 30 m;
- Filtering of speckle using a Lee filter.

The calibration is designed to convert the digital values of the raw images into backscattering coefficients ( $\sigma^0$ ).

#### (b) Landsat optical data

Seven Landsat-8 images downloaded from the USGS website (<http://earthexplorer.usgs.gov/>) were used to provide optical wavelength observations of the study area. The atmospheric correction of these images was performed using NASA's Landsat Ecosystem Disturbance Adaptive Processing System (LEDAPS). This software uses the 6S (Second Simulation of a Satellite Signal in the Solar Spectrum) radiative transfer model to estimate the surface reflectance. The NDVI vegetation index, expressed by  $NDVI = (RNIR - RRED)/(RNIR + RRED)$ , where RNIR is the near-infrared (NIR)

reflectance and RRED is the red reflectance, was calculated from the optical images. The data used in this analysis were derived from images recorded in the absence of clouds.

### 2.2.2. Ground Measurements

During two cycles of cereal fields (from December 2015 to May 2016, and from December 2016 to March 2017), ground measurements were carried out at the same time as several S1 sensor acquisitions (Figure 2). In the Kairouan plain, early December generally corresponds to the sowing season, whereas the end of March corresponds to the period of maximum cereal growth. Cereal senescence occurs prior to harvesting, between mid-April and the end of May. For each cycle, more than 20 reference fields ranging in size between 2 and 5 ha were considered, under conditions of either bare soil with varying degrees of roughness, or bearing cereals at different stages of growth (irrigated and non-irrigated) (Table 1). The first campaign in each agricultural cycle (during the month of December) was carried out on bare soil, prior to cereal growth. The fields are sufficiently large to ensure that the mean values of the radar measurements, which are affected by the presence of speckle noise, are sufficiently accurate.

They were observed during both cereal cycles; moisture and roughness measurements were carried out for the soil characterization. Leaf area index (LAI) and canopy height (H) measurements were recorded for the fields with a vegetation cover. Table 2 lists the dates of the field campaigns, and the corresponding types of measurement.




Figure 2. Location of reference fields on the study site (Landsat image).

Table 1. Land cover during 2015–2017.

Land Cover	2015–2016	2016–2017
Bare soil	P2, P4, P5, P6, P8a, P10, P18, P21, P21b	P5, P12, P18
Pasture	P2b, P9, P15, P22	P10, P15
Irrigated wheat	P1, P3, P7, P8b, P11, P12, P13, P16, P19	P1, P3, P7, P8, P11, P14b, P16, P16b, P19, P22
Rain-fed wheat	P14	P2b, P4, P6, P14, P21


**Table 2.** Radar and ground measurement campaigns during 2015–2017. Radar image configurations; Root mean square surface height (Hrms); leaf area index (LAI); vegetation height (H).

Date	Radar Image (polarization, Angle)	Soil Moisture (vol. %)	Hrms (cm)	LAI (m <sup>2</sup> /m <sup>2</sup> )	H (cm)
6 December 2015	VV/VH, 39–40°	[5.2–26.49]	[0.56–2.93]		
3 February 2016	VV/VH, 39–40°	[5.29–25]	-	[0.64–4.16]	[16.38–64.37]
28 February 2016	VV/VH, 39–40°	[4.48–28.05]	-	[1.28–5]	[28.72–95.10]
15 April 2016	VV/VH, 39–40°	[10.81–23.1]	[0.62–3.24]	[0.03–4.25]	[56.3–112]
09 May 2016	VV/VH, 39–40°	[9.02–23.02]	-	[0.001–0.03]	[76.8–110.7]
23 December 2016	VV/VH, 39–40°	[23.14–41.18]	[0.72–4.55]		-
16 January 2017	VV/VH, 39–40°	[11.96–33.19]	-	[0.05–4.23]	[8.34–25.63]
21 February 2017	VV/VH, 39–40°	[8.97–30.64]	[1.08–3.78]	[0.28–5]	[11.57–62.57]
18 March 2017	VV/VH, 39–40°	[8.12–31.58]	-	[0.58–5]	[18–84.07]
23 April 2017	VV/VH, 39–40°	[6.36–34.46]	-	[0.09–1.6]	[56.93–99.07]

#### (a) Soil Moisture

On each of the dates listed in Table 2, approximately 20 handheld Theta Probe measurements were made in each reference field (irrigated or non-irrigated) at a depth of 5 cm. The samples were taken from various locations in each reference field, within a two-hour time frame of the concurrent satellite acquisitions, and the Theta Probe measurements were calibrated with gravimetric measurements recorded during previous campaigns [30]. This semi-arid region is characterized by strong temporal variations in rainfall, which were revealed by the very high range of soil moisture content values (between 3.9 vol. % and 45 vol. %) measured during the experimental campaigns (Table 2).

In addition to the moisture measurements carried out in reference fields, a network of seven continuous Theta Probe stations (Figure 1), installed at various bare soil locations over the studied site, was used to provide moisture measurements every 3 h. At each station, the measurements were made at depths of 5 and 40 cm. Figure 3 plots the daily values of precipitation and the mean daily volumetric surface soil moisture, estimated by calculating the mean value of the continuous recordings given by Theta Probe measurements at a depth of 5 cm during the two studied agricultural seasons. A strong correlation can be noted between the soil moisture estimations and the precipitation events.



**Figure 3.** Daily precipitation and mean surface moisture over the studied site during the measurement campaigns.

(b) Soil roughness parameters

Radar signals are highly sensitive to the geometry of scattering surfaces. In the present context, roughness is a measure of the variations in micro-topographic height of the soil surface. Measurements were made using a 1 m long pin profiler, with a separation of 2 cm between successive needles. For each test plot, five parallel and five perpendicular profiles were compared in order to take the possible effects of directional roughness retrieval into account. The roughness profiles are considered to be stationary and ergodic. Two statistical parameters are then estimated: the root mean square surface height (Hrms) and the correlation length (L) [34]. These were computed from the correlation functions of the heights of the surface profiles. We considered two roughness measurement campaigns during each agricultural year, which was sufficient to account for most variations in soil roughness (Table 2). The soil roughness can vary over a wide range of values, mainly in autumn, prior to the sowing of cereals. After sowing, the soil is no longer tilled and is affected only by very small temporal variations in roughness. During all measurement campaigns, Hrms ranged between 0.56 and 4.55 cm, and the correlation length varied between 1.96 and 13.14 cm.

(c) Vegetation parameters

Vegetation cover measurements are carried out to characterize several parameters: the leaf area index (LAI) and canopy height (H), as described in the following.

**Leaf Area Index (LAI)**

The LAI is defined as the total one-sided area of leaf tissue per unit ground surface area. According to this definition, the LAI is a dimensionless quantity. For each test field, 20 hemispherical digital images were used. These were processed by analyzing the canopy gap fraction, in order to retrieve this vegetation parameter [53]. The measurements were applied four times during each agricultural season. During all measurement campaigns, the computed value of LAI ranged between 0 and 5 (Table 2). The highest values of LAI were observed mainly in irrigated test fields, between the end of March and the beginning of April.

**Vegetation Height (H)**

Approximately 20 vegetation height measurements were considered for each reference field and for each date. These were averaged, to retrieve a mean height value for each test field. In the case of H, measurements were carried out four times during each agricultural season. The tallest vegetation heights lie in the range (90–110 cm) and are reached towards the end of March or the beginning of April (Table 2).

**Land use**

Land use maps were produced in 2017. This process relies on the decision-tree method proposed in [30] and was applied to four LANDSAT images (recorded in late autumn, early winter, spring and summer). Ten classes of land-use classification were identified: non-irrigated olive trees; irrigated trees; irrigated winter vegetables; irrigated summer vegetables; cereals; urban areas; sebkha areas; landforms; dams, and; oueds. These remotely sensed classifications were validated during a ground verification campaign, involving more than 100 fields with various types of land use. The results reveal an identification accuracy of approximately 75%. Figure 4 shows the Resulting Land Use Map for the 2016–2017 season.




Figure 4. Land use map.

### 3. Results and Discussions


#### 3.1. Relationships between NDVI and Vegetation Parameters

The values of NDVI corresponding to each pixel were obtained from optical Landsat images, and then averaged for each reference field. Figure 5 provides a plot of the NDVI as a function of the LAI ground measurements, showing that the NDVI saturates at a value of 0.78 when the LAI reaches a value of around  $3 \text{ m}^2/\text{m}^2$ .

An exponential function has been proposed to describe this relationship [30,44,47]:

$$NDVI = NDVI_{\max} + (NDVI_{\text{soil}} - NDVI_{\max}) \times e^{-k \text{ LAI}} \quad (1)$$

where  $NDVI_{\max}$  (0.78) is the NDVI corresponding to the maximum value of LAI,  $NDVI_{\min}$  is the bare soil NDVI (=0.15), and  $k$  is the extinction coefficient (=0.96). The coefficient of determination  $R^2$  for this data is 0.79, with a RMSE (relative mean square error) of  $0.96 \text{ m}^2/\text{m}^2$ . Courault et al. [47] reported a value of  $k = 0.71$ , derived from Formosat-2 images acquired over a larger area in Southeast France including wheat and rice fields, as well as irrigated grasslands. In the case of Landsat images of grassland plots in France, El Hajj et al. [44] reported a value of  $k = 0.69$ .




**Figure 5.** Relationship between LAI ground measurements and normalized difference vegetation index (NDVI) derived from optical images.


### 3.2. Radar Signal Analysis

#### 3.2.1. Relationship between Radar Signal and Soil Moisture

In order to minimize the influence of vegetation heterogeneity, the sensitivity of the radar signals to soil moisture was analyzed for three classes of NDVI. The first of these is defined by  $NDVI < 0.25$ , corresponding (in general) to bare or poorly covered soils. The second class is defined for  $0.25 < NDVI < 0.5$ , corresponding to a medium vegetation density, and the third class is defined for high NDVI values ( $NDVI > 0.5$ ). The NDVI threshold defined at 0.5 corresponds to an LAI equal to  $\sim 1$ . Figure 6 plots the VV and VH radar signals as a function of soil moisture for the three NDVI classes. The sensitivity of radar signals to soil moisture can be seen to decrease with increasing NDVI. The vegetation component, which attenuates the signal scattered by the soil, thus influences the radar sensitivity to variations in soil moisture. As an example, for the VV polarization the sensitivity decreases from 0.27 dB/vol.% for the weak NDVI values ( $NDVI < 0.25$ ), and to 0.12 dB/vol.% for the highest NDVI values ( $NDVI > 0.5$ ). The signal strength sensitivity is clearly higher in the VV than in the VH polarization, for all three classes of NDVI. As an example, in the first NDVI class the sensitivity is 0.27 dB/vol.% for VV and 0.18 dB/vol.% for VH. In the VH polarization, the lower soil moisture sensitivity can be explained by the higher sensitivity of the radar signals to the volume component of medium scattering [35]. For the two highest NDVI classes, the correlation between moisture and radar signals is the lowest, due to the disruptive effect of increasing vegetation cover and the absence of field data at low values of soil moisture.



**Figure 6.** Cont.




**Figure 6.** S1 radar data as a function of soil moisture: (a) VV polarization,  $\text{NDVI} < 0.25$ ; (b) VH polarization;  $\text{NDVI} < 0.25$ ; (c) VV polarization,  $0.25 < \text{NDVI} < 0.5$ ; (d) VH polarization,  $0.25 < \text{NDVI} < 0.5$ ; (e) VV polarization,  $\text{NDVI} > 0.5$ ; (f) VH polarization,  $\text{NDVI} > 0.5$ .

The behaviors found for S-1 are generally consistent with those reported in previous studies, in the case of data acquired in the C-band [30,54].

### 3.2.2. Relationship between Radar Signal and Soil Roughness

As noted in the introduction, in the case of bare soils, the soil roughness has a very strong influence on the behavior of radar signals. In the present study, the relationship between radar signals and the parameter  $H_{rms}$  was analyzed. As shown in several preceding studies [16,34], it is valid, to a good approximation, to take the linear sum of the radar signal contributions produced by roughness and soil moisture. In order to avoid the influence of moisture heterogeneities, the relationship between roughness and radar signals is analyzed for two moisture classes: a class with low moisture values  $\leq 10$  vol. % and a second class with soil moisture (mv) ranging between 10 vol. % and 20 vol. %. In the database used for the present study, since a very small number of bare soil measurements (8) were found to correspond to the highest moisture values ( $>20$  vol. %), an additional third class, with  $mv > 20$  vol. %, was not considered. Figure 8 shows the relationship between the soil roughness parameter ( $H_{rms}$ ) and the S1 signals in the VV and VH polarizations, for each of these two moisture classes. A high correlation, greater than 0.7 in the case of low moisture values ( $mv < 10$  vol. %), is obtained between the radar signal strengths and the roughness parameters. In this moisture class, the VV and VH data have approximately the same behavior, characterized by roughness-induced signal strength variations of approximately 6 dB. It can be seen in Figure 7 that in the high moisture class ( $10\% < mv < 20\%$ ) there is just a small number of data points (16 observations), with no reference fields having a value of  $H_{rms}$  smaller than 1 cm. This leads to a lower correlation between roughness and radar signal.



**Figure 7.** S1 radar data as a function of the Hrms roughness parameter in two soil moisture (mv) classes: (a) VV polarization,  $mv \leq 10$  vol. %; (b) VH polarization,  $mv < 10$  vol. %; (c) VV polarization,  $10 \text{ vol. \%} < mv < 20 \text{ vol. \%}$ ; (d) VH polarization,  $10 \text{ vol. \%} < mv < 20 \text{ vol. \%}$ .


### 3.2.3. Relationship between Radar Signal and Cereal Parameters

In this section, the sensitivity of radar signals is discussed, for the case of two vegetation parameters: LAI and H. Figure 8 shows the relationship between the radar signals (VV and VH polarizations) and the LAI, for two moisture classes:  $mv \leq 15$  vol. % and  $mv > 15$  vol. %. Just two moisture classes were proposed, in order to include a sufficiently large number of observations. In the VV polarization, the radar sensitivity to LAI leads to a dynamic range of approximately 2 dB in both moisture classes, with the signal decreasing with increasing LAI. This behavior is due to the fact that when the LAI increases, it leads to stronger vegetation-induced attenuation of the backscattered soil signals.


The behavior of the VH radar signals as a function of LAI is different to that observed in the VV polarization, and vegetation cover appears to have a relatively weak influence on the radar signal strength. In practice, when the vegetation-induced attenuation increases, this is accompanied by a decrease in the soil component of the total radar signal, and vegetation scattering (in particular, volume scattering, which is stronger in the VH polarization) increases with increasing LAI. Fontanelli et al. [52] have shown similar results for HH and VV-polarized radar observations (TSX data), in which the signal strength decreases as a function of increasing LAI. However, radar signals are not affected in the same way by all types of vegetation cover, since the radar signal is strongly dependent on the geometric structure characterizing each type of vegetation. As an example, El-Hajj et al. [44] observed a positive relationship between signal strength and LAI in the case of grass-covered fields.

Figure 9 plots the VV and VH signals as a function of the second vegetation parameter, the vegetation height (H). This analysis was made for vegetation heights recorded until the beginning of April, corresponding to the end of the local period of plant growth. After this date, although the height of the plants remains constant, the vegetation is characterized by a decreasing level of vegetation water content. As in the case of the LAI observations, two moisture classes,  $mv \leq 15$  vol. % and  $mv > 15$  vol. %, were considered. In the VV polarization, very similar behaviors are observed, as in the case of the LAI parameterization. The VV radar signal strength can be seen to decrease with

increasing vegetation height. In the low moisture class, there are no data points corresponding to vegetation higher than 100 cm, which could explain the observed decrease in correlation with respect to the values determined for the high moisture class. As shown in Figure 9, in the VH polarization the radar signal strength increases with increasing vegetation height. This behavior appears to be contradictory to that observed in Figure 8, which reveals a weakly decreasing VH signal strength as a function of increasing LAI. This apparent discrepancy can be explained by the fact that ground-truth measurements began when the vegetation height was approximately 10–15 cm, following the first LAI campaigns. This means that the influence of the soil was lower, and that volume scattering from the vegetation (Figure 9) could have dominated the backscattered radar signals.



**Figure 8.** S1 data as a function of LAI for two classes of soil moisture (mv): (a) VV polarization, mv ≤ 15 vol. %; (b) VH polarization, mv ≤ 15 vol. %; (c) VV polarization, mv > 15 vol. %; (d) VH polarization, mv > 15 vol. %.



**Figure 9.** Sentinel-1 (S1) radar data as a function of H in two soil moisture (mv) classes: (a) VV polarization, mv < 15 vol. %; (b) VH polarization, mv < 15 vol. %; (c) VV polarization, mv > 15 vol. %; (d) VH polarization, mv > 15 vol. %.

#### 4. Simulation of S1 Data with Backscattering Models

In this section, two models are used to simulate radar backscattering over fields characterized by two different types of land use: bare soil and soil covered by cereals. In the case of bare soils, an empirical model was used. This takes the influence of moisture and roughness into account. In the case of surfaces with a vegetation cover, the water cloud model was applied [42]. This is particularly useful for the inversion of radar data over agricultural soils [30].

##### 4.1. Bare Soil Backscattering Model


In the present study, two empirical expressions were used to model the radar backscattering over bare soil, for the VV and VH polarizations. These can be written as:

$$\sigma_{vv}^{soil} = \alpha_{vv} mv + \beta_{vv} \log(Hrms) + \delta_{vv} \quad (2)$$

$$\sigma_{vh}^{soil} = \alpha_{vh} mv + \beta_{vh} \log(Hrms) + \delta_{vh} \quad (3)$$

The observations describing the bare soil reference fields are separated into two datasets. The first of these includes 45 fields and is used for the calibration of the proposed expression, whereas the second set of (45) fields is used to validate the results. Table 3 lists the calibrated model parameters for the VV and VH polarizations and corresponding statistical parameters (RMSE and  $R^2$ ). The two datasets correspond to multi-temporal measurements made in two sets of distinctly different reference fields.

Figure 10 plots the results obtained through validation of the proposed model, by comparing the signal strengths predicted by the model with the real data derived from the bare soil surfaces described in the second dataset. This figure shows that there is a strong agreement between the simulations and measurements, with an RMSE equal to 1.27 and 1.23 dB for the VV and VH data, respectively, and a bias equal to 0.1 and 0.2 dB for the VV and VH data, respectively. These results highlight the potential of this model for the analysis and inversion of radar data over bare soils.



**Figure 10.** Empirical model validation: (a) VV polarization; (b) VH polarization.

**Table 3.** Calibration parameters and statistical precision coefficients computed with the proposed empirical models, for the VV and VH polarizations. Relative mean square error (RMSE) and correlation coefficient  $R^2$ .

Polarisation	$\alpha_{pq}$	$\beta_{pq}$	$\delta_{pq}$	RMSE (dB)	$R^2$
pq=VV	0.17	3.25	-15.06	1.27	0.61
pq=VH	0.13	1.88	-23.01	1.23	0.5

##### 4.2. Validation of the Water Cloud Model

The water cloud model developed by Attema and Ulaby [42] was used to model the radar signal backscattered by covered surfaces. At an incidence angle  $\theta$ , the backscattering coefficient in this model is given by the following expression:

$$\sigma^0 = \sigma_{canopy}^0 + \sigma_{canopy+soil}^0 + \tau^2 \sigma_{soil}^0 \quad (4)$$

where  $\tau^2$  is the two-way vegetation transmissivity. The first term represents scattering due to the vegetation, whereas the second term is related to multiple scattering effects, and the third term represents soil scattering attenuated by the vegetation cover. The second term, which can be neglected in the case of wheat scattering, is used to account for double-bounce scattering, the effects of which are stronger in the VV than in the VH polarization. Expression (4) can thus be simplified to:

$$\sigma^0 = \sigma_{canopy}^0 + \tau^2 \sigma_{soil}^0 \quad (5)$$

With

$$\tau^2 = \exp(-2 B V1 \sec\theta) \quad (6)$$

And

$$\sigma_{canopy}^0 = A V1 \cos\theta (1 - \tau^2) \quad (7)$$

where  $V1$  is a parameter related to the vegetation. In the present case we consider the NDVI, which is strongly related to the vegetation parameters. The parameters  $A$  and  $B$  depend on the type of canopy. This formulation represents a first-order solution for the radiative transfer equation through a weak medium, where multiple scattering is neglected. As in the case of bare soils, we consider two datasets, with the first being used for the calibration of  $A$  and  $B$ , and the second for validation of the retrieved model.

The empirical model proposed in expression (2) was used to represent the soil contribution.

In the present study, two different data sets were used, with different soil and vegetation conditions (moisture, roughness, vegetation index (NDVI)). The first of these contains data recorded from 110 reference fields, and is used to determine the parameters  $A$  and  $B$ , which are then used to calibrate the model. The second dataset describes a different set of 110 reference fields, which are used to validate the calibrated model. As the results described in Section 3.2 reveal a very low sensitivity of VH signals to vegetation cover, which is probably due to a volume scattering effect, in the water cloud model we consider the VV polarization only. The calibration process allows the empirical parameters  $A$  and  $B$  to be determined as:  $A = 0.06$ ;  $B = 0.42$ .

In Figure 11, the modeled VV radar strength is compared with the measured values taken from the second validation dataset. These are based on measurements made over reference fields, which are different to those used for the calibration. The modeled signal strengths can be seen to be in very good agreement with the real radar signal. This agreement was observed for a large range of vegetation types (NDVI between 0.14 and 0.69), soil moistures (ranging from 6.4 vol. % to 37.1 vol. %) and soil roughness values (ranging between 0.94 cm and 2.02 cm). The RMSE is equal to 0.84 dB and the bias is equal to 0.08 dB.




Figure 11. Water cloud model validation for the VV polarization.

## 5. Conclusions

In this study, the potential use of Sentinel-1 radar signals for the assessment of different surface states (soil moisture and soil roughness, vegetation cover parameters) is analyzed. The results are based on the use of a large database, describing two agricultural years of cereal production (2015–2016 and 2016–2017). Remotely sensed data recorded by the Sentinel-1 and Landsat payloads are compared with in situ measurements, corresponding to more than 20 reference plots, which are characterized either by bare soil, or by cereal coverage. This study has made it possible to determine the sensitivity of Sentinel-1 signals to soil moisture. The radar sensitivity is clearly determined, through the interpretation of data corresponding to three classes of vegetation, ranging from bare soil to dense canopies. The radar signal sensitivity is found to decrease with increasing NDVI index, and to be higher in the VV polarization than in the VH polarization. This suggests that VV data have a greater potential for the estimation of soil moisture. Concerning the soil roughness, the Sentinel-1 VV and VH radar signals are found to be highly sensitive to the roughness parameter  $H_{rms}$ , with a dynamic range reaching 6 dB for both polarizations. A correlation greater than 0.7 is determined for an empirical logarithmic relationship between the radar signals and  $H_{rms}$ , for the case of plots in the low moisture class ( $mv \leq 10$  vol. %). Two classes of moisture ( $mv \leq 15$  vol. %,  $mv > 15$  vol. %) are used to analyze the role of vegetation cover, revealing that the VV radar signals are highly sensitive to the LAI. The dynamic range of the radar signals is equal to 2 dB and 1.5 dB, for these two classes of soil moisture. There is almost no significant correlation between signal strength and soil moisture in the case of the VH polarization.

The radar signals expected over bare soils are modeled using a simple empirical expression, which includes a linear relationship with respect to soil moisture, and a logarithmic behavior with respect to roughness. When the calibrated model is validated with real data recorded over a variety of reference fields, it is found to be very accurate: the RMSE is equal to 1.27 and 1.23 dB, for the VV and VH polarizations, respectively.

In the case of radar signals observed over covered soils, a calibrated water cloud model is proposed, using the NDVI as a parameter to describe the vegetation. This model is proposed for the VV polarization only. As in the case of bare soils, when the model is validated with a set of reference fields, the simulated signal strengths are found to be in good agreement with the real measurements (RMSE equal to 0.84 dB). Despite its simplicity, the water cloud model is able to correctly describe the behavior of radar signals, as a function of soil moisture and vegetation parameters. The empirical calibration parameters derived from this analysis have been adapted to the case of agricultural plots with a cereal cover. In future studies, they will be tested at a different site, characterized by different types of vegetation cover.

This study reveals the high potential of Sentinel-1 data, when combined in synergy with optical (Landsat) images, for the recovery of moisture and vegetation characteristics. It is clearly shown that

VV polarized signals have a greater sensitivity to these surface parameters, and that remotely sensed Sentinel-1 radar data can be inverted and used for the mapping of soil and cereal cover characteristics.

**Acknowledgments:** This study was funded by the ANR AMETHYST (ANR-12 TMED-0006-01) and TOSCA/CNES ASCAS projects. We extend our warm thanks to the technical teams at the IRD and INAT (Institut National Agronomique de Tunisie) and Aicha Chahbi for their invaluable collaboration and support during the ground-truth measurement campaigns and data processing.

**Author Contributions:** Safa Bousbih and Mehrez Zribi conceived and designed the experiments; Safa Bousbih and Bernard Mougenot performed the experiments; Safa Bousbih, Mehrez Zribi and Nicolas Baghdadi analyzed the data; Zohra Lili-Chabaane, Mohammad El-Hajj, Qi Gao contributed to materials/analysis tools; Mehrez Zribi and Safa Bousbih wrote the paper.

**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. Regions of strong coupling between soil moisture and precipitation. *Science* 2004, 305, 1138–1140. [CrossRef] [PubMed]
2. Zhao, N.; Yu, F.; Li, C.; Wang, H.; Liu, J.; Mu, W. Investigation of Rainfall-Runoff Processes and Soil Moisture Dynamics in Grassland Plots under Simulated Rainfall Conditions. *Water* 2014, 6, 2671–2689. [CrossRef]
3. Saux-Picart, S.; Otlé, C.; Decharme, B.; André, C.; Zribi, M.; Perrier, A.; Coudert, B.; Boulain, N.; Cappelaere, B. Water and Energy budgets simulation over the Niger super site spatially constrained with remote sensing data. *J. Hydrol.* 2009, 375, 287–295. [CrossRef]
4. Zhuo, L.; Han, D. The relevance of soil moisture by remote sensing and hydrological modeling. *Procedia Eng.* 2016, 154, 1368–1375. [CrossRef]
5. Baghdadi, N.; Zribi, M. *Optical Remote Sensing of Land Surfaces: Techniques and Methods*; ISTE Press: London, UK; Elsevier: Oxford, UK, 2016; ISBN 9781785481024.
6. Baghdadi, N.; Zribi, M. *Microwave Remote Sensing of Land Surfaces: Techniques and Methods*; ISTE Press: London, UK; Elsevier: Oxford, UK, 2016; ISBN 978178548159.
7. Paloscia, S.; Macelloni, G.; Santi, E. Soil moisture estimates from AMSR-E brightness temperatures by using a dual-frequency algorithm. *IEEE Trans. Geosci. Remote Sens.* 2006, 44, 3135–3144. [CrossRef]
8. 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]
9. 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. [CrossRef]
10. Srivastava, H.S.; Patel, P.; Manchanda, M.L.; Adiga, S. Use of multiincidence angle RADARSAT-1 SAR data to incorporate the effect of surface roughness in soil moisture estimation. *IEEE Trans. Geosci. Remote Sens.* 2003, 41, 1638–1640. [CrossRef]
11. Singh, D. A simplistic incidence angle approach to retrieve the soil moisture and surface roughness at X-band. *IEEE Trans. Geosci. Remote Sens.* 2005, 43, 2606–2611. [CrossRef]
12. 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]
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. 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]
15. Yu, F.; Zhao, Y. A new semi-empirical model for soil moisture content retrieval by ASAR and TM data in vegetation-covered areas. *Sci. China Earth Sci.* 2011, 54, 1955–1964. [CrossRef]

16. Fieuzal, R.; Duchemin, B.; Jarlan, L.; Zribi, M.; Baup, F.; Merlin, O.; Hagolle, O.; Garatuza-Payan, J. Combined use of optical and radar satellite data for the monitoring of irrigation and soil moisture of wheat crops *Hydrol. Earth Syst. Sci.* 2011, 15, 1117–1129. [CrossRef]
17. Petropoulos, G.P.; Ireland, G.; Barrett, B. Surface soil moisture retrievals from remote sensing: Current status, products and future trends. *Phys. Chem. Earth* 2015, 83, 36–56. [CrossRef]
18. Chai, X.; Zhang, T.; Shao, Y.; Gong, H.; Liu, L.; Xie, K. Modeling and Mapping Soil Moisture of Plateau Pasture Using RADARSAT-2 Imagery. *Remote Sens.* 2015, 7, 1279–1299. [CrossRef]
19. Alexakis, D.D.; Mexis, F.K.; Vozinaki, A.K.; Daliakopoulos, I.N.; Tsanis, I.K. SoilMoisture Content Estimation Based on Sentinel-1 and Auxiliary Earth Observation Products. A Hydrological Approach. *Sensors* 2017, 17, 1455. [CrossRef] [PubMed]
20. 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]
21. Zribi, M.; Gorrab, A.; Baghdadi, N.; Lili-Chabaane, Z.; Mougenot, B. Influence of radar frequency on the relationship between bare surface soil moisture vertical profile and radar backscatter. *IEEE Geosci. Remote Sens. Lett.* 2014, 11, 848–852. [CrossRef]
22. Baghdadi, N.; Zribi, M.; Bruand, A.; King, C. Potentiel of ASAR/ENVISAT for the characterization of soil surface parameters over bare agricultural fields. *Sensors* 2010, 10, 8899–8900. [CrossRef] [PubMed]
23. Baghdadi, N.; Cerdan, O.; Zribi, M.; Auzet, V.; Darboux, F.; El Hajj, M.; Kheir, R.B. Operational performance of current synthetic aperture radar sensors in mapping soil surface characteristics in agricultural environments: Application to hydrological and erosion modeling. *Hydrol. Process.* 2008, 22, 9–20. [CrossRef]
24. 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, 370–382. [CrossRef]
25. 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]
26. Dubois, P.C.; Van Zyl, J.; Engman, T. Measuring soil moisture with imaging radars. *IEEE Trans. Geosci. Remote Sens.* 1995, 33, 915–926. [CrossRef]
27. Baghdadi, N.; Choker, M.; Zribi, M.; El-hajj, M.; Paloscia, S.; Verhoest, N.; Lievens, H.; Baup, F.; Mattia, F. A new empirical model for radar scattering from bare soil surfaces. *Remote Sens.* 2016, 8, 920. [CrossRef]
28. Zribi, M.; Saux-Picart, S.; André, C.; Descroix, L.; Otlé, O.; Kallel, A. Soil moisture mapping based on ARSAR/ENVISAT radar data over a sahelian site. *Int. J. Remote Sens.* 2007, 28, 3547–3565. [CrossRef]
29. Wang, J.R.; Hsu, A.; Shi, J.C.; O'Neill, P.E.; Engman, E.T. A comparison of soil moisture retrieval models using SIR-C measurements over the Little Washita River watershed. *Remote Sens. Environ.* 1997, 59, 308–320. [CrossRef]
30. Zribi, M.; Chahbi, A.; 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]
31. 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, 1607–1621. [CrossRef]
32. 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]
33. Gao, Q.; Zribi, M.; Baghdadi, N.; Escorihuela, M.J. Synergetic Use of Sentinel-1 and Sentinel-2 Data for Soil Moisture Mapping at 100 m Resolution. *Sensors* 2017, 17, 1966. [CrossRef] [PubMed]
34. 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 SIRC/XSAR and ERASME 1994 data over Orgeval. *Remote Sens. Environ.* 1997, 59, 256–266. [CrossRef]
35. Fung, A.K. *Microwave Scattering and Emission Models and Their Applications*; Artech House: Boston, MA, USA, 1994.
36. Mattia, M.; Toan, T.L.; Souyris, J.C.; Carolis, G.D.; Floury, N.; Posa, F.; Pasquariello, G. The effect of surface roughness on multifrequency polarimetric SAR data. *IEEE Trans. Geosci. Remote Sens.* 1997, 35, 954–966. [CrossRef]

37. Zribi, M.; Baghdadi, N.; Holah, N.; Fafin, O.; Guérin, C. Evaluation of a rough soil surface description with ASAR-ENVISAT Radar Data. *Remote Sens. Environ.* 2005, *95*, 67–76. [CrossRef]
38. Lievens, H.; Vernieuwe, H.; Alvarez-Mozos, J.; de Baets, B.; Verhoest, N.E.C. Error in SAR-derived soil moisture due to roughness parameterization: An analysis based on synthetical surface profiles. *Sensors* 2009, *9*, 1067–1093. [CrossRef] [PubMed]
39. Lievens, H.; Verhoest, N.E.C.; De Keyser, E.; Vernieuwe, H.; Matgen, P.; Álvarez-Mozos, J.; De Baets, B. Effective roughness modelling as a tool for soil moisture retrieval from C-and L-band SAR. *Hydrol. Earth Syst. Sci.* 2011, *15*, 151–162. [CrossRef]
40. Zribi, M.; Gorrab, A.; Baghdadi, N. A new soil roughness parameter for the modeling of radar backscattering over bare soil. *Remote Sens. Environ.* 2014, *152*, 62–73. [CrossRef]
41. Gorrab, A.; Zribi, M.; Baghdadi, N.; Lili Chabaane, Z. Mapping of surface soil parameters (roughness, moisture and texture) using one radar X-band SAR configuration over bare agricultural semi-arid region. In *Proceedings of the International Geoscience and Remote Sensing Symposium, Beijing, China, 10–15 July 2016*.
42. Attema, E.P.W.; Ulaby, F.T. Vegetation modeled as a water cloud. *Radio Sci.* 1978, *13*, 357–364. [CrossRef]
43. Zhang, J.H.; Xu, Y.; Yao, F.M.; Wang, P.J.; Guo, W.J.; Li, L.; Yang, L.M. Advances in estimation methods of vegetation water content based on optical remote sensing techniques. *Sci. China Technol. Sci.* 2010, *53*, 1159–1167. [CrossRef]
44. El Hajj, M.; Baghdadi, N.; Belaud, G.; Zribi, M.; Cheviron, B.; Courault, D.; 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]
45. Asrar, G.; Fuchs, M.; Kanemasu, E.T.; Hatfield, J.L. Estimating absorbed photosynthetic radiation and leaf area index from spectral reflectance in wheat. *Agron. J.* 1984, *76*, 300–306. [CrossRef]
46. Weiss, M.; Baret, F.; Smith, G.J.; Jonckheere, I.; Coppin, P. Review of methods for in situ leaf area index (LAI) determination: Part II. Estimation of LAI, errors and sampling. *Agric. For. Meteorol.* 2004, *121*, 37–53. [CrossRef]
47. Courault, D.; Hadria, R.; Ruget, F.; Olioso, A.; Duchemin, B.; Hagolle, O.; Dedieu, G. Combined use of FORMOSAT-2 images with a crop model for biomass and water monitoring of permanent grassland in Mediterranean region. *Hydrol. Earth Syst. Sci. Discuss.* 2010, *7*, 1731–1744. [CrossRef]
48. 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]
49. Paloscia, S.; Macelloni, G.; Pampaloni, P.; Sigismondi, S. The potential of C- and L-band SAR in estimating vegetation biomass: The ERS-1 and JERS-1 Experiments. *IEEE Trans. Geosci. Remote Sens.* 1999, *37*, 2107–2110. [CrossRef]
50. Bindlish, R.; Barros, A.P. Parameterization of vegetation backscatter in radar-based, soil moisture estimation. *Remote Sens. Environ.* 2001, *76*, 130–137. [CrossRef]
51. Baghdadi, N.; Cresson, R.; Todoroff, P.; Moinet, S. Multitemporal observations of sugarcane by TerraSAR-X images. *Sensors* 2010, *10*, 8899–8919. [CrossRef] [PubMed]
52. 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]
53. Duchemin, B.; Maisongrande, P.; Boulet, G.; Benhadj, I. A simple algorithm for yield estimates: Evaluation for semi-arid irrigated winter wheat monitored with green leaf area index. *Environ. Model. Softw.* 2008, *23*, 876–892. [CrossRef]
54. Baghdadi, 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*, 1129–1244. [CrossRef]




### 3.5. Analyses supplémentaires et résultats non-publiés

#### 3.5.1. Analyses de sensibilité du signal radar au contenu en eau de la végétation

Comme pour les différents paramètres de la végétation, le contenu en eau de la végétation a été également analysé en fonction du signal radar pour les deux polarisations VV et VH (Figure 2.15). Le comportement du signal radar par rapport au contenu en eau est le même que celui observé pour la hauteur de végétation avec une diminution du signal radar en polarisation VV avec l'augmentation du contenu en eau avec une sensibilité approximativement de  $0.65 \text{ dB/ [kg/m}^2]$ . Pour le signal en polarisation VH, les points sont plus dispersés et le signal est alors insensible au contenu en eau, comme celui observé pour la hauteur de la végétation et ce qui est expliqué par l'atténuation du signal radar par le développement de la végétation.


Compte tenu du nombre limité de mesures du contenu en eau, il est difficile d'affiner les résultats et d'inclure des classes concernant l'humidité du sol ou du stade de développement de la culture.



**Figure 3. 1:** Le coefficient de rétrodiffusion ( $S_1$ ) en dB en fonction du contenu en eau de la végétation : a) pour la polarisation VV et b) pour la polarisation VH

#### 3.5.2. Comparaison des résultats de la modélisation sur sols nus avec d'autres approches

D'autres approches ont été évaluées afin de comparer les résultats de la modélisation. Différents modèles ont été appliqués sur les parcelles tests : le modèle IEM calibré par Baghdadi (Baghdadi et al., 2004 ; Baghdadi et al., 2006 ; Baghdadi et al., 2011 ; Baghdadi et al., 2016) et la version modifiée du modèle de Dubois (Baghdadi et al., 2016) pour ces données sur les parcelles de sols nus. Ces modèles requièrent les mêmes paramètres que le modèle utilisé: les paramètres de sol (humidité et rugosité) et les paramètres du capteur (angles d'incidence, longueur d'onde et polarisation).




**Figure 3. 2:** Simulation du signal radar par: a) le modèle IEM selon la polarisation VV; b) le modèle IEM selon la polarisation VH; c) le modèle Dubois selon la polarisation VV et d) le modèle Dubois selon la polarisation VH

Les Figures 3.2 comparent les résultats obtenus à partir des modèles avec les données radars pour les deux polarisations. Les différents modèles simulent correctement le signal radar, les résultats statistiques sont proches des résultats obtenus par le modèle semi-empirique. La version modifiée du modèle de Dubois par Baghdadi donne le meilleur ajustement du signal radar pour les deux polarisations VV et VH avec des valeurs de RMSE de 1.9 dB et 1.46 dB respectivement. Les simulations du modèle IEM calibré montrent une faible corrélation entre signal modélisé et le signal réel en polarisation VH et une meilleure corrélation en polarisation VV avec des RMSE de 2.72 dB et 1.88 dB respectivement.

### **3.5.3. Comparaison des résultats de la modélisation sur la végétation avec d'autres approches**

Une approche similaire a été proposée par Baghdadi et al. (2017) sur deux sites différents avec des conditions très contrastées. Cette approche se base sur le couplage du modèle WCM pour les couverts végétaux, et le modèle physique IEM calibré par Baghdadi et al. (2004, 2011, 2015) sur les sols nus.

Le modèle utilise similairement une synergie de données radars (S-1A et S-1B) et de données optiques (S-2A et S-2B) avec une résolution spatiale de 10 m et un temps de revisite de 6 jours. L'étude a donc été menée sur un premier site, la plaine de Kairouan avec un climat semi-aride, cela a permis la calibration du modèle. Les mesures, effectuées sur le deuxième site à Montpellier dans le sud de la France ( $43.38^{\circ}52' - 43^{\circ}45'N$  ;  $03^{\circ}47' - 03^{\circ}52'E$ ) avec un climat méditerranéen, ont permis de valider les résultats de la modélisation et le signal rétrodiffusé. Des mesures sur des sols nus et sur des sols couverts (des parcelles de blé pour le site Tunisien et des prairies pour le site Français) ont été collectées en parallèle avec l'acquisition des images radars. Elles comprennent des mesures d'humidité du sol et de rugosité recouvrant une large gamme de valeurs. Les résultats du paramétrage du modèle présentent une similarité avec les résultats obtenus par le modèle WCM utilisant une expression simplifiée de la contribution du sol.



**Figure 3. 3:** Les coefficients de rétrodiffusion observés à partir d'images S-1 par rapport aux valeurs de rétrodiffusion modélisées à partir de WCM : a,b) pour la phase calibration et c,d) pour la phase validation (Source : Baghdadi et al., 2017)

### 3.6. Synthèse et conclusion partielle

L'objectif général de cette partie est d'évaluer le potentiel des données radars Sentinel-1 et les données optiques Landsat-8 utilisées en synergie pour l'inversion des modèles de rétrodiffusion pour la cartographie de l'état hydrique de surface à haute résolution spatiale.

La pertinence de la présente étude bénéficie de l'ampleur de la campagne terrain qui s'étale sur deux années agricoles pour le cycle des cultures céréalières. L'étude a donc bénéficié d'une large base de données couvrant les différents stades de développement de la culture pour un nombre important de parcelles de référence (23 parcelles de sols nus et de céréales pour l'année 2015-2016 et 20 parcelles pour l'année 2016-2017), accompagnées d'acquisitions radars et optiques. Cela a ajouté une forte significativité aux corrélations observées et aux résultats avec une grande variabilité des conditions du sol à savoir la rugosité, l'humidité du sol et la texture. Les analyses de sensibilité montrent que le signal radar diffusé par le sol est atténué lorsque la végétation devient plus dense et recouvre la totalité de la surface. Pour ce stade, la contribution du sol est alors faible

devant la contribution de la végétation ce qui nécessite une correction du signal par un modèle de rétrodiffusion.

Pour les sols nus sélectionnés sur la plaine de Kairouan, un modèle semi-empirique (Zribi et al., 2014) est utilisé dans un premier temps pour reproduire le signal mesuré par le capteur radar S-1 sur des sols nu avec un RMSE de l'ordre de 1.2 dB. L'originalité majeure du modèle WCM (Attema et Ulaby, 1978), développé pour simuler le signal radar sur un couvert végétal réside dans sa simplicité et son implémentation sur différents sites à différentes conditions et sur plusieurs types de couverts. Il a été appliqué sur les parcelles de céréales, afin de corriger le signal radar des effets de la végétation. Les deux modèles ont été calibrés à partir d'une partie de la base de données établie sur le site d'étude. Ils simulent correctement le signal radar avec quelques limitations liées à la densité de la végétation. Le modèle WCM n'a été appliqué que pour le signal en polarisation VV vu que les résultats des analyses de sensibilité montrent que le signal est plus sensible aux paramètres de surface en polarisation VV que VH.

# Chapitre 4: Estimation de l'humidité du sol et cartographie des zones irriguées et non-irriguées

*Les résultats de la modélisation de la rétrodiffusion des surfaces agricoles s'avèrent encourageants. Les différents modèles testés sur la zone d'étude sont en mesure de reproduire correctement un coefficient de rétrodiffusion très proche des mesures réelles. Par conséquent, afin de produire des cartes d'humidité du sol, nous avons utilisé le modèle avec les paramètres de la calibration présenté dans le chapitre précédent. Une démarche originale a été menée pour la cartographie de l'irrigation à partir de ces produits.*

*Le chapitre 4 est présenté à partir d'un article intitulé :*

*Bousbib, 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 Sensing, 2018, 10, 1953; doi:10.3390/rs10121953 .*

*Publié dans le journal Remote Sensing.*

## Sommaire

---

<b>CHAPITRE 4: ESTIMATION DE L'HUMIDITE DU SOL ET CARTOGRAPHIE DES ZONES IRRIGUEES ET NON-IRRIGUEES</b>	<b>90</b>
4.1. INTRODUCTION .....	91
4.2. INVERSION DE LA RETRODIFFUSION ET CARTOGRAPHIE DE L'HUMIDITE DU SOL .....	92
4.3. CARTOGRAPHIE DES ZONES IRRIGUEES ET NON-IRRIGUEES .....	92
4.4. ARTICLE .....	92
4.5. SYNTHÈSE ET CONCLUSION PARTIELLE.....	113

---

## 4.1. Introduction

Le suivi des états de surface, particulièrement l'état hydrique du sol en milieu agricole est essentiel pour la compréhension des différents processus entre le sol, l'atmosphère et le couvert végétal. L'état hydrique de surface est alors décrit comme un paramètre clé pour différentes applications, notamment pour le pilotage de l'irrigation. Dans ce contexte, le suivi l'humidité du sol est un enjeu majeur pour la gestion durable des ressources en eau à grandes échelles, notamment pour les régions semi-arides continuellement confrontées à des pénuries d'eau. Ce paramètre représente un outil d'aide à la décision, utile pour le développement des stratégies agricoles et la lutte contre la raréfaction de l'eau.

Les approches pour la restitution des paramètres de surface sont généralement basées sur la simple inversion des modèles de rétrodiffusion (Baghdadi et al., 2006 ; Baghdadi et al., 2018 ; Hosseini et al., 2015 ; Li & Wang, 2018 ; Lievens & Verhoest, 2011 ; Oevelen et al., 1999 ; Prévot et al., 1993 ; Rawat et al., 2018 ; Sikdar & Cumming, 2004). Les travaux menés ces dernières vingt années ont permis de développer des méthodologies plus innovantes pour l'exploitation des images RSO pour estimer l'état hydrique du sol. Ces méthodes reposent sur des techniques statistiques basées sur les réseaux de neurones, ou par les méthodes de détection de changements (El Hajj et al., 2017 ; Jiang & Cotton, 2004 ; Paloscia et al., 2013 ; Wagner et al., 1999 ; Zribi et al., 2011 ; Gao et al., 2017). Plusieurs applications ont été développées pour assimiler ces produits adaptés aux modèles hydrologiques ou agronomiques (Aubert et al., 2003 ; Crow & Ryu, 2009 ; Jin et al., 2018 ; Pauwels et al., 2002 ; Zhou et al., 2019). Le potentiel de la bande C a été particulièrement exploité dans de nombreuses recherches pour extraire l'humidité sur des parcelles de sols nus et des parcelles avec un couvert végétal (Baghdadi et al., 2016 ; El Hajj et al., 2017 ; Paloscia et al., 2013 ; Srivastava et al., 2009 ; Zribi et al., 2011).

Dans un second temps, l'irrigation est l'un paramètre clé du bilan hydrique. Son suivi contribue par ailleurs à une meilleure gestion des ressources en eau, permet une bonne croissance et un développement de la végétation, et favorise l'augmentation des rendements agricoles. De plus, l'irrigation est étroitement liée à l'humidité du sol. En effet, le suivi de l'humidité du sol est très utile pour améliorer les prises de décisions pour l'irrigation. De ce fait, les informations sur les zones irriguées et non-irriguées sont nécessaires, particulièrement dans les régions semi-arides où ces zones atteignent une extension notable. Grâce aux satellites Sentinel-1 et Sentinel-2 des mesures opérationnelles sont proposées, à des résolutions spatiales fines, adaptés à un suivi à l'échelle locale ou régionale.

Ce chapitre présente les méthodologies adoptées pour la cartographie de l'humidité dans un premier temps et la cartographie des zones irriguées et non-irriguées dans les Sections 4.2 et 4.3. Ensuite les principaux résultats de ce travail sont exposés dans l'article qui est incluse dans la Section 4.4. La Section 4.5 comporte la synthèse de ce chapitre les principales conclusions.

## **4.2. Inversion de la rétrodiffusion et cartographie de l'humidité du sol**

L'objectif de ce chapitre est de proposer des produits d'humidité du sol à partir d'une synergie de données radars (S-1) et de données optiques (S-2). Un algorithme d'inversion directe du modèle WCM a été développé pour produire une série temporelle de l'humidité du sol spatialisée. Les cartes ont été validées sur les parcelles de référence de la plaine de Kairouan. Un bon accord est enregistré entre les simulations et les mesures par Thetaprobe avec des précisions de l'ordre de 5 vol. %. Ces cartes ont été ensuite comparées à des produits dérivés de l'inversion du modèle WCM par réseaux de neurones avec un RMSE de l'ordre de 6 vol. % et un coefficient de détermination  $R^2$  de 0.8, validés sur une large gamme de données avec un NDVI entre 0.08 pour les sols nus et 0.65 pour un couvert dense et avec des conditions d'humidité variant d'un sol sec à un sol très humide.

## **4.3. Cartographie des zones irriguées et non-irriguées**

Pour pouvoir valider l'approche proposée, une enquête sur le terrain a été menée afin de recenser plusieurs parcelles de référence couvrant la plaine de Kairouan. Plus de 70 parcelles ont été collectées par des informations concernant l'irrigation, leur localisation, leur superficie, etc.

A travers la combinaison de ces produits (radar/optique), une carte pour détecter les zones irriguées et non-irriguées est déduite. En outre, une classification des zones irriguées et pluviales a été conduite à partir de:

- Une série temporelle de NDVI, moyenné sur le mois de Mars (maximum de développement de la culture)
- Des indices statistiques sur une série temporelle d'humidité du sol : moyenne et variance
- Une combinaison des différents indicateurs (NDVI et humidité du sol).

L'approche développée est basée sur des classifications par Arbre de Décision et par Support Vector Machine (SVM). La classification par SVM a permis tout d'abord de séparer entre les deux types de parcelles en utilisant les moyennes et les variances de l'humidité du sol, à travers une droite linéaire. Ensuite la classification par Arbre de Décision a été appliquée sur les différents cas d'études pour cartographier l'irrigation.

Les résultats des classifications illustrent la forte contribution des séries temporelles d'humidité du sol à détecter les zones irriguées, vu que les données radars sont très sensibles à l'humidité du sol, et peuvent donc être associés à l'irrigation.

## **4.4. Article**

Article

# Soil Moisture and Irrigation Mapping in A Semi-Arid Region, Based on the Synergetic Use of Sentinel-1 and Sentinel-2 Data

Safa Bousbih <sup>1,2,\*</sup>, Mehrez Zribi <sup>1,\*</sup>, Mohammad El Hajj <sup>3</sup>, Nicolas Baghdadi <sup>3</sup>,  
Zohra Lili-Chabaane <sup>2</sup>, Qi Gao <sup>1,4,5</sup> and Pascal Fanise <sup>1</sup>

<sup>1</sup> CESBIO (CNRS/UPS/IRD/CNES), 18 Avenue Edouard Belin, 31401 Toulouse CEDEX 9, France; qi.gao@isardsat.cat (Q.G.); pascal.fanise@ird.fr (P.F.)

<sup>2</sup> LR GREEN-TEAM/Université de Carthage/INAT, 43 Avenue Charles Nicolle, Tunis 1082, Tunisia; zohra.lili.chabaane@gmail.com

<sup>3</sup> IRSTEA, University of Montpellier, UMR TETIS, 34093 Montpellier CEDEX 5, France; mohammad.el-hajj@teledetection.fr (M.E.H.); nicolas.baghdadi@teledetection.fr (N.B.)

<sup>4</sup> IsardSAT, Parc Tecnològic Barcelona Activa, Carrer de Marie Curie, 8, 08042 Barcelona, Spain

<sup>5</sup> Observatori de l'Ebre (OE), Universitat Ramon Llull-CSIC, 08022 Barcelona, Spain

\* Correspondence: safabousbih1@outlook.fr (S.B.); mehrez.zribi@ird.fr (M.Z.); Tel.: +33-56155-8501 (S.B.); Tel.: +33-56155-8525 (M.Z.)

Received: 21 September 2018; Accepted: 3 December 2018; Published: 5 December 2018

**Abstract:** This paper presents a technique for the mapping of soil moisture and irrigation, at the scale of agricultural fields, based on the synergistic interpretation of multi-temporal optical and Synthetic Aperture Radar (SAR) data (Sentinel-2 and Sentinel-1). The Kairouan plain, a semi-arid region in central Tunisia (North Africa), was selected as a test area for this study. Firstly, an algorithm for the direct inversion of the Water Cloud Model (WCM) was developed for the spatialization of the soil water content between 2015 and 2017. The soil moisture retrieved from these observations was first validated using ground measurements, recorded over 20 reference fields of cereal crops. A second method, based on the use of neural networks, was also used to confirm the initial validation. The results reported here show that the soil moisture products retrieved from remotely sensed data are accurate, with a Root Mean Square Error (RMSE) of less than 5% between the two moisture products. In addition, the analysis of soil moisture and Normalized Difference Vegetation Index (NDVI) products over cultivated fields, as a function of time, led to the classification of irrigated and rainfed areas on the Kairouan plain, and to the production of irrigation maps at the scale of individual fields. This classification is based on a decision tree approach, using a combination of various statistical indices of soil moisture and NDVI time series. The resulting irrigation maps were validated using reference fields within the study site. The best results were obtained with classifications based on soil moisture indices only, with an accuracy of 77%.

**Keywords:** irrigation; soil moisture; NDVI; Sentinel-1; Sentinel-2; Water Cloud Model

---

## 1. Introduction

With the world population being projected to reach 9.1 billion by 2050, agricultural production will need to increase substantially, to meet the surging demand for food [1,2]. In this context, increased production must be accompanied by strategies for improved irrigation efficiency and the development of more sustainable agricultural techniques. In semi-arid regions, the limited availability of water represents a major obstacle to enhanced crop production. Efficient agricultural water management is thus a major issue, especially in areas where irrigation is deployed, meaning that the

development of tools that can provide regional estimates of the water balance may contribute to the sustainable management of water resources in such areas [3–5]. It has been shown that the irrigation process requires a high level of precision, in order to optimize water input and crop response, while minimizing its potentially adverse environmental impacts [6].

The monitoring of irrigation water requires the mapping of irrigated and non-irrigated areas at high spatial and temporal resolutions [7,8]. In practice, an accurate knowledge of spatio-temporal variations in the soil's water content is crucial, when it comes to assessing the optimal volume of water to be delivered to the crops, at specific times throughout the year.

Remote sensing currently provides a wealth of information describing the Earth's surface. In particular, remotely sensed optical data has long been used to estimate agricultural surface parameters, and to provide surface vegetation measurements, which can be interpreted in the form of vegetation parameters such as the Leaf Area Index (LAI), Fraction Cover (FC), and the Normalized Difference Vegetation Index (NDVI), etc., at low and high spatial resolutions [9–13]. However, meteorological conditions, aerosols, optical turbulence, as well as the presence of cloud cover affect these measurements, and can limit their validity and relevance. Several studies have also used thermal infrared data to measure the surface temperature and estimate the soil water content [14,15]. The use of these techniques at the scale of agricultural fields remains imperfect, due to limitations inherent to ambient weather conditions and the lack of data recorded at high spatio-temporal resolutions. By contrast, Synthetic Aperture Radar (SAR) observations are not affected by meteorological conditions, and can be used to monitor various surface parameters, including soil moisture, over agricultural areas [16–20].

Three main methodologies have been proposed for the retrieval of soil surface moisture from remotely sensed radar observations: the first of these relies on the inversion of semi-empirical or physical models, the second makes use of a statistical approach such as that of neural networks, and the third is based on the use of change detection algorithms.

With the first approach, both semi-empirical models (e.g., the Dubois, Oh, and Baghdadi models) [21–23] and physical models (e.g., the Integral Equation (IEM), and the Small Perturbation (SPM) models) [24–26] have been developed for the assessment of bare soil moisture at the scale of agricultural fields. In the case of surfaces with a vegetation cover, several models have been proposed for the simulation of soil and vegetation contributions, using various parameters to represent the influence of vegetation on the radar signal. The most commonly used technique makes use of the semi-empirical Water Cloud Model (WCM), developed by Attema and Ulaby [27], coupled with a semi-empirical or empirical backscattering soil model [28,29]. This approach requires solving of the radiative transfer equation, and computes the total backscattering coefficient by summing the signals reflected by the vegetation together with those attenuated by the vegetation and scattered by the soil. Vegetation descriptors are derived mainly from optical data. The most commonly used descriptor is the NDVI, which provides an accurate representation of the influence of vegetation on the total backscattering coefficient. Bousbih et al. [30] and Baghdadi et al. [31] calibrated the WCM using Sentinel-1 data, together with the NDVI derived from various optical images. Several studies propose the retrieval of soil moisture from inversion of the WCM, for various types of crop and configuration. Prévot et al. [28] inverted the WCM to estimate soil moisture with an accuracy of 6.5% (Vol.) and LAI with 1 m<sup>2</sup> m<sup>-2</sup>, using C and X-band data recorded by the scatterometer Radar Multifréquences Sol pour l'Etude des Signatures Spectrales (RAMSES) (Ground-based multi-frequency radar scatterometer for the study of spectral signatures) over winter wheat fields. Kumar et al. [29] used the LAI as a vegetation descriptor, and the ASAR instrument on ESA's ENVironment SATellite (ENVISAT) platform, to generate soil moistures with an RMSE of approximately 4% (Vol.), in various campaigns over sugarcane fields. Zribi et al. [18] estimated soil moisture values using the WCM, together with C-band ASAR and SPOT/HRV data, leading to an RMSE of approximately 6% (Vol.) over wheat fields. El Hajj et al. [32] used the NDVI, LAI, Fraction of Absorbed Photo-synthetically Active Radiation (FARPAR), and Fraction Cover (FC) to invert the WCM with X-band SAR data, thus allowing the soil moisture to be estimated with an RMSE of 3.6% (Vol.) for NDVI values ranging between 0.45 and 0.75, and 6.1% (Vol.) for NDVI values ranging between 0.75 and 0.90.

The second approach to the retrieval of soil surface moisture is based on Neural Network computations, and usually involves the use of one or two radar signal polarizations and the NDVI. This method also produces quite accurate estimations of the soil moisture [33–37]. Paloscia et al. [34] have proposed an approach based on an Artificial Neural Network, using VV SAR data and the NDVI from the Moderate Resolution Imaging Spectro-radiometer (MODIS) time series. The results obtained with this technique have a good accuracy, with a soil moisture RMSE of 4% (Vol.). El Hajj et al. [36] developed an algorithm based on a Neural Network, to estimate soil moisture over agricultural fields, by combining the WCM with the IEM (Integral Equation Model), the backscattering model used for bare soils. This combined use of optical and radar data allowed soil moistures to be estimated with an RMSE of approximately 5% (Vol.). C-band SAR radar sensors can be used to estimate soil moisture at depths between approximately 0 and 2 cm [38–40]. However, in agricultural contexts characterized by high rates of evaporation, this product can become highly variable, thus making it difficult to analyze the temporal dynamics of soil moisture [37,38].

The third approach to soil moisture estimation makes use of the change detection technique [41–43]. This method has been implemented using scatterometer sensors, at low spatial resolutions. Zribi et al. [41] proposed an algorithm using VV ASAR/ENVISAT data and MODIS time series observations, recorded over North Africa. When validated over central Tunisia, the soil moisture estimations were found to be very accurate, with an RMSE of 3.5% (Vol.) at a spatial resolution of 1 km. Gao et al. [42] combined Sentinel-1 data and the NDVI computed from Sentinel-2 images to retrieve soil moisture at a spatial resolution equal to 100 m. These products were validated, with an RMSE in volumetric moisture equal to approximately 8.7% (Vol.) and 5.9% (Vol.), using two different change detection methods.


The mapping of irrigated and rainfed areas can be used to prepare irrigation schedules and to assess the condition of water-stressed crops. Several studies [44–52] have demonstrated the considerable potential of optical remote sensing for irrigation mapping. Thiruvengadachari [44] proposed the interpretation of single-date Landsat imagery for the mapping of irrigated areas, by including additional information related to major surface irrigation projects, canal network maps, drainage patterns, and recorded groundwater utilization. Although single-date imagery can be used to identify irrigated fields, it is not always reliable, since single-date analysis does not take the dynamic changes of the vegetation cover into account, over a full agricultural season. Multi-temporal analysis is thus better adapted to the detection of irrigated fields. Thenkabail et al. [46] used time-series data from MODIS to generate a map of irrigated areas for the Ganges and Indus river basins. Studies combining the two aforementioned methods have increased the spatial and temporal resolution of irrigation mapping. Gumma et al. [50] developed a decision-tree approach using Landsat 30 m single-date data, combined with MODIS 250 m time series data. They achieved a precision lying in the range 67–93% for the identification of irrigated fields, with different classes of vegetation. Despite the strong potential of these techniques, the use of optical data is heavily dependent on the prevailing weather conditions, and cloud cover in particular. In areas affected by high cloud cover, these methods can be difficult to implement. During wet years, under low water stress conditions with vegetation cover, it can be difficult to distinguish between irrigated and non-irrigated fields using optical indices only. However, the use of soil moisture estimations can be used to improve the accuracy with which irrigated and non-irrigated areas are classified.

The aim of the present study is to propose an accurate technique for the mapping of soil water content, through the inversion of Sentinel-1 (S-1) and Sentinel-2 (S-2) data, combined with the use of the Water Cloud Model. In addition, the resulting soil moisture data can then be used to produce annual irrigation maps, allowing irrigated and rainfed areas to be distinguished. The remote sensing data (S-1 and S-2) analyzed in this study was acquired over cereal crops at a high spatial resolution, with short revisit times. The following section describes the study site and the database. The soil moisture mapping process and its validation are presented in Section 3 (methodology). In the fourth section, the resulting irrigation maps are evaluated. The final section includes a discussion of the results together with our conclusions.

## 2. Study site and Database


## 2.1. Study Site

The Kairouan plain (Central Tunisia:  $9^{\circ}53'57''\text{E}$ ;  $35^{\circ}34'51''\text{N}$ ; Figure 1a) is a semi-arid, typically agricultural region. Its flat topography is characterized by widespread cultivation (cereal crops and market gardening) together with arboriculture, which is dominated mainly by olive tree plantations [53]. The area has dry summer seasons, with an average temperature of approximately  $30^{\circ}\text{C}$  during the hottest months (July and August), and wet winters. Precipitation is variable, with frequent periods of drought and an annual average rainfall of approximately 300 mm. The mean annual potential evapotranspiration is close to 1600 mm. The landscape in this area is dominated by agricultural plants (cereals and olive trees), as shown in Figure 1b, and the fields are covered by topsoil (5 cm in depth) consisting mainly of loam and clay.



(a)

Figure 1. Cont.



(b)

**Figure 1.** (a) Location of the study site; (b) land use map.

Twenty reference fields with winter wheat crops (irrigated and rainfed wheat) were selected, and two campaigns were organized during the agricultural seasons (which start at the time of sowing and end after harvesting), from December 2015 to May 2016, and from December 2016 to March 2017. The first campaign was between December 2015 and May 2016; the second was between December 2016 and March 2017. These periods fall between the sowing and harvesting seasons of cereal crops [18]. The campaigns involved ground measurements and satellite acquisitions, and were carried out over the study site at regular intervals.

## 2.2. Ground Measurements

In situ soil moisture readings were recorded in selected reference fields (bare soil and wheat fields), and Sentinel-1 (S-1) radar observations were acquired, during the two cereal crop cycles (between December 2015 and March 2017). The in situ soil moisture and vegetation measurements were carried out on 38 different dates, at the same time as the radar acquisitions. For each reference field, twenty Thetaprobe measurements of volumetric soil moisture were made at a depth of 5 cm. These were calibrated using gravimetric measurements from previous campaigns [18]. Most of the fields were covered by smooth or moderately tilled soils.

The first agricultural season (2015–2016) was an extremely dry one, with a total annual rainfall of approximately 120 mm, recorded by the nearby INGC meteorological station (“Institut National des Grandes Cultures”; 9°56′16″E; 35°37′15″N). The soil moisture values were relatively low in the rainfed plots, and ranged between 3.9% (Vol.) and 18% (Vol.). In the case of the irrigated plots, the soil moisture values ranged between 5% (Vol.) and 39% (Vol.). The second agricultural season (2016–2017) was characterized by a relative higher average annual rainfall (approximately 240 mm), which was nevertheless lower than the long-term annual average, and soil moisture values ranging between 5% (Vol.) and 45% (Vol.).

An additional campaign was carried out between March and April 2017, in order to locate and collect information from several different agricultural fields (Table 1), and to assess the differences in soil moisture characterizing rainfed and irrigated cereal crops. The data recorded during this campaign was later used to calibrate and validate the irrigation maps produced from the first two observation campaigns. Seventy-four plots were located over the Kairouan plain, corresponding to a total of 46 irrigated cereal crops and 28 rainfed wheat fields, with surface areas ranging between 2 and 25 ha.

The Kairouan plain has an extensive network of measuring stations, including meteorological and regular soil moisture stations. Four of the meteorological stations were installed in 2009, at Chebika (INGC), Skhira, Sidi Ali Ben Salem and Nasrallah. The closest station to the study site is that at Chebika, which provides meteorological data such as air temperature, relative humidity, global radiation, wind speed, atmospheric pressure and precipitation, at 30 min intervals.

**Table 1.** Scheduling of the study site measurement campaigns between 2015 and 2017.

Date Ranges	Campaigns	Fields Numbers
6 December 2015–28 April 2016	Theta Probe measurements	23
29 November 2016–30 March 2017	Theta Probe measurements	20
17 March 2017–17 April 2017	Irrigation investigation	74

### 2.3. Satellite Data

#### 2.3.1. Sentinel-1

Sentinel-1A and Sentinel-1B images were acquired between December 2015 and March 2017. These satellites have the same orbital pattern, and are operated in the C-band (5.4 GHz), Interferometric Wideswath (IW) mode, with a spatial resolution of 10 m. Each satellite has a revisit period of 12 days, leading to a dual-satellite revisit period equal to six days. The sensors provide dual-polarization imagery (VV and VH) at an incidence angle ranging between 39° and 40°. This study used Level-1 ground range detection (GRD) products, derived from focused SAR images that were multi-looked and projected to a ground-range, using an Earth Ellipsoid Model.

The image processing was carried out using the Sentinel Application Platform (SNAP) toolbox. The first step in this process involved conversion of the signal, to obtain the backscattering coefficient. Terrain corrections were then applied, to correct for geometric distortions, using the Digital Elevation Model (DEM) proposed by the Shuttle Radar Topography Mission (SRTM), at a spatial resolution of 30 m. Finally, thermal noise removal and a Lee filter were applied, in order to reduce speckle effects in the images. The backscattering coefficient was averaged for each reference field. Seventy Sentinel-1 images recorded in the VV and VH polarizations, in both ascending and descending orbital modes, were successively downloaded and processed every six days.

#### 2.3.2. Sentinel-2

Optical images of the study site were obtained from the Sentinel-2A satellite, on dates close to the Sentinel-1 images acquired between December 2015 and March 2017. The S-2A images were downloaded and processed from THEIA, a French open-source land data service center (<https://www.theia-land.fr/>).

The data was derived from cloud-free images with radiometric and atmospheric corrections. The Normalized Difference Vegetation Index (NDVI) was then computed, with Bands 4 and 8, which represent the Red (RED) and Near-Infrared (NIR) reflectances, using the expression:

$$NDVI = (NIR - RED) / (NIR + RED) \quad (1)$$

The values of NDVI were averaged for each reference field, and these ranged between 0.08 in the case of bare soils, and 0.8 in the case of dense vegetation.

Twenty-eight S-2 optical images were recorded on dates close to the S-1 radar acquisitions, with a delay of not more than ten days between the S-1 and S-2 images (in this area, cereal crops do not change significantly in a single week).

### 3. Methodology

#### 3.1. Soil Moisture Retrieval Methodology

The soil moisture estimations were computed for bare soils and cereal fields. These need to be observed at a high spatial resolution, in order to facilitate the detection of irrigation events in individual fields. The proposed approach is based on the inversion of the WCM, coupled to an empirical soil backscattering model. The inversion algorithm comprises two successive phases, the first of which includes calibration of the model over the study site, and removal of all radar signal attenuation and/or scattering effects produced by the vegetation. The second step involves the implementation of an inversion algorithm to retrieve the soil moisture.

##### 3.1.1. Water Cloud Model

The Water Cloud Model was developed by Attema and Ulaby [27], in order to simulate the characteristics of a radar signal when it is backscattered by the ground, and in any way affected by the soil surface moisture and plant canopies. The total backscattering coefficient ( $\sigma^0$ ) in this model is given by the following expressions:

$$\sigma^0 = \sigma_{veg}^0 + \sigma_{veg/soil}^0 + \tau^2 \sigma_{soil}^0 \quad (2)$$

where

$$\tau^2 = \exp(-2BV \sec(\theta)) \quad (3)$$

In Expression (2), the first term represents scattering due to the vegetation, and the second term,  $\sigma_{veg/soil}^0$ , is related to multiple (“double-bounce”) scattering, which can often be neglected in the case of wheat scattering [54]. The third term represents soil scattering, attenuated by the vegetation cover.

The vegetation backscattering is modeled as:

$$\sigma_{veg}^0 = AV \cos(\theta) (1 - \tau^2) \quad (4)$$

and the soil backscattering is modeled as:

$$\sigma_{soil}^0 = C 10^{D.Mv} \quad (5)$$

The latter expression thus assumes that there is a linear relationship between the soil moisture and the radar signal expressed in dB, where C and D are calibration parameters,  $\tau^2$  is the two-way vegetation transmissivity, Mv is the soil moisture,  $\theta$  is the incidence angle of the radar signal, and V is the vegetation parameter.

The calibration and validation of the WCM are described in a previous study [28]. The parameterization of the WCM was adapted to a wide range of soil moistures (between 5% (Vol.) and 45% (Vol.)), and NDVI values (between 0.14 and 0.8). The model is calibrated in two successive steps, the first of which uses bare soil reference fields to retrieve the parameters C and D, with the second step using vegetation-covered fields to retrieve the parameters A and B.

The fitted model allows the parameters A, B, C and D, (Table 2), which depend on the type of canopy, to be determined. An earlier study [30] has also shown that the signal in the VV polarization is more sensitive to the soil surface parameter. For this reason, we consider the VV polarization only in the following section.

**Table 2.** Water Cloud Model parameters for the VV polarization.

A	B	C	D	RMSE
0.06	0.42	-16.97	0.27	0.84 dB


### 3.1.2. Inversion of the Water Cloud Model and Soil Moisture Retrieval

Following its calibration with the aforementioned parameters, the WCM is inverted and the soil moisture is computed. This inversion process makes use of the spatialized NDVI, derived from S-2 images and the backscattering coefficient. In the present study, we introduced a moving average filter with a  $5 \times 5$  pixel window, in order to mitigate speckle artifacts on the resulting maps.

### 3.2. Irrigation Mapping Methodology

In this section, we propose a methodology for the identification of irrigated areas at the scale of individual fields, based on the interpretation of Sentinel-1 and Sentinel-2 images.

The structure of this algorithm is described by the flow chart in Figure 2. The key input data used in this process are the soil moisture maps produced by the inversion technique, and the values of NDVI derived from S-2 images.



**Figure 2.** Flow chart of the irrigation mapping procedure, using SVM and Decision Tree classifications.

The first step involves the processing of a segmented S-2 image, using NDVI data to generate meaningful image segments, including the agricultural fields of interest. The soil moisture and NDVI values are averaged for each of the segmented fields. The algorithm then makes use of the mean and variance of the soil moisture time series, and the mean value of the NDVI time series, in order to distinguish between irrigated and rainfed fields. Support Vector Machine and Decision Tree classification were incorporated into the process. Finally, the resulting irrigation maps are validated using selected reference fields.

### 3.2.1. Image Segmentation


To calculate the statistical parameters of the satellite products (mean and variance), the agricultural fields are assigned as homogenous segments, using an NDVI image derived from S-2 data. A segmentation algorithm (mean-shift) is then applied, and for each segments the mean NDVI, together with the mean and variance of the soil moisture, are computed.

### 3.2.2. Support Vector Machine Classification

The purpose of the second step in the classification procedure is to distinguish between rainfed and irrigated areas. An initial classification step is implemented using a Support Vector Machine (SVM). The SVM is a supervised machine-learning algorithm, which has been widely applied to the classification of remote sensing images [55–57]. In the case of the present algorithm, classification is achieved by identifying a decision boundary that differentiates between the two classes. This boundary is generally an optimal hyperplane for linear, separable patterns (Figure 3), which can be expressed as:

$$Y = ax + b \quad (6)$$

where  $a$  and  $b$  are the hyperplane parameters, with  $a$  equal to 0.058 and  $b$  equal to 13.7.



**Figure 3.** SVM classification using mean values of soil moisture as a function of soil moisture variance, for irrigated and rainfed areas (calibration data set).

The input variables in the SVM classification are the mean and variance of the soil moisture time series, computed from the descending node radar data, which has a revisit time of six days.

A total of 74 training cereal crops (irrigated and rainfed fields) were assessed across the study site, and then separated into two datasets: 46 fields were used to compute the parameters of the hyperplane equation, in the SVM modeling step. The results of this classification are shown in Figure 3, in which the irrigated and rainfed fields lie respectively above and below the linear hyperplane, and the highest mean values of soil moisture correspond to irrigated fields. It can also be seen that the variance and mean value of the soil moisture product time series are correlated. This trend can be explained in terms of the relative aridity of the study site, where frequent changes in the soil moisture of irrigated fields, from initially dry to relatively wet conditions, are associated with an increase in the variance of this parameter.

### 3.2.3. Decision Tree Classification


The Decision Tree classifier has long been employed for land cover mapping [58,59], to distinguish between various classes of agricultural area using indices derived from remote sensing data. The method developed in the present study applies the Decision Tree classification, using mean and variance maps of soil moisture together with a map of mean NDVI values, to separate the irrigated from the rainfed areas. This classification is based firstly on the use of maps of mean NDVI values only. It is then associated with the SVM classification, using the hyperplane parameters, together with the soil moisture parameters. Finally, the irrigation/rainfed classification is completed by combining the soil moisture parameters with the mean value of NDVI, leading to the production of irrigation maps. The 28 reference fields, which were not included in the 74 training fields, were used to validate the irrigated and rainfed fields identified by the classification algorithm.

## 4. Results

### 4.1. Validation and Mapping of Soil Moisture


#### 4.1.1. Validation of the Proposed Inversion Against Ground Measurements

The first validation is achieved by comparing the estimated water content with the ground measurements, acquired by the Theta Probe sensor on the reference fields, for soil moisture conditions ranging from dry to wet. Figure 4 shows the good agreement found between the measured and estimated soil moistures (derived from data in the VV polarization), for NDVI values ranging between 0.08 and 0.7. With these results, the RMSE is 6.4% (Vol.), the bias is 0.25% (Vol.), and the coefficient of determination  $R^2$  is equal to 0.4 (with  $p$ -value  $< 0.01$ ).



**Figure 4.** Soil moisture values (Mv) retrieved by direct inversion of the Water Cloud Model, as a function of soil moisture levels measured in the reference fields.

Figure 5 plots the estimated and measured (Theta probe) values of soil moisture as a function of time, for two different reference fields, showing that the remotely sensed estimations are in good agreement with the ground truth measurements.



**Figure 5.** Temporal variations of the remotely sensed and measured soil moisture, for two reference fields: (a) Field P19; (b) Field P2.

#### 4.1.2. Validation of Soil Moisture Products Computed by Inversion, Using Neural Networks

##### (a) Neural Network products


A Neural Network (NN) technique for soil moisture mapping, based on the inversion of radar signals, has been proposed by El Hajj et al. [36]. This NN uses the WCM, coupled with the Integral Equation Model (IEM), and is trained using C-band SAR data in the VV and VH polarizations, together with NDVI data derived from optical S-2 images. Although, in an effort to improve the soil moisture estimations, the NN can include meteorological data to provide the network with *a priori* information concerning rainfall events, it can also be used without this information. In practice, rainfall has a significant influence on the soil and is strongly related to its surface moisture content. After a long period of drought, the soil becomes very dry, with low soil moisture values (Mv between 2% and 25% (Vol.)). Sudden bouts of heavy rain then lead to high levels of soil moisture (Mv between 25% and 40% (Vol.)).

In this context, NNs can be established for two distinct cases:

- no *a priori* information concerning the soil moisture
- availability of *a priori* information concerning the soil moisture: dry to wet or very wet soil.

This approach was shown to perform very well in the south of France [36], with an RMSE equal to 5.5% (Vol.) in the absence of *a priori* soil moisture information, and 4% (Vol.) in the presence of *a priori* information, for dry soils. In the case of wet soils, this technique led to an RMSE of 6.9% (Vol.) without *a priori* information, and 5.1% (Vol.) with *a priori* information.


Figure 6 shows the performance of the NN over the Merguellil site, for both cases (with and without *a priori* soil moisture information). In the absence of *a priori* information, the estimated values of Mv have an RMSE equal to 6.8% (Vol.) and a coefficient of determination ( $R^2$ ) equal to 0.5 ( $p$ -value < 0.01). When *a priori* information is available, the agreement between predicted and measured values of soil moisture is improved, and estimations with an RMSE equal to 5.8% (Vol.), and a coefficient of determination  $R^2$  equal to 0.58 ( $p$ -value < 0.01).



**Figure 6.** Neural Network simulations for two cases: (a) without *a priori* information; (b) with *a priori* information for the reference fields.

(b) Comparing NN estimations with the proposed inversion products


Here, the soil moisture obtained with the NN and *a priori* information is compared with the values of soil moisture computed using direct inversion of the WCM (Figure 7), showing that these two products are highly correlated, with a coefficient of determination  $R^2$  equal to 0.8, an RMSE of 4.3% (Vol.) and a bias of 1.9% (Vol.). Despite the limitations and simplicity of the inversion methodology, the results obtained with the NN validation show that it can accurately estimate the soil moisture.



**Figure 7.** Comparison between WCM and Neural Network estimations of soil moisture.

#### 4.2. Soil Moisture Mapping

Figure 8 provides examples of the resulting soil moisture maps, computed for the study site by inverting the WCM. Two specific dates selected in order to analyze the soil moisture values obtained for the whole study site, for two specific cases: a wet period (24 December 2016), and a dry period (20 July 2016). The results obtained for these two cases are significantly different, as a consequence of their differences in terms of seasonal and meteorological conditions (rainfall).



**Figure 8.** Soil moisture maps over the study site on two different dates: 24 December 2016 (a) and 20 July 2016 (b).

#### 4.3. Irrigation Mapping

A mask is first applied to the images, in order to eliminate high ground, lakes or ponds, dams, urban areas, salt flats, and olive fields.

Three cases are then considered for the classification of irrigated and rainfed areas:

- classification using mean NDVI values only
- classification using soil moisture parameters (mean and variance) only
- classification using the mean and variance of soil moisture, combined with the mean values of NDVI.

The irrigation maps corresponding to the above three cases are shown in Figures 9–12. These patterns of irrigation were then analyzed in greater detail, in order to identify the irrigated and non-irrigated fields on the study site. For this, confusion matrices were used to compare the pixels of each field with the resulting irrigation map. The resulting confusion matrices, used for the Decision Tree classification, are listed in Tables 3–5. They summarize the accuracy statistics in terms of the Kappa coefficient, which is a standardized indicator of the overall accuracy of the validation step. This coefficient measures the strength of the agreement between the classification algorithm and the ground truth measurements, thus indicating the accuracy of each class, established with the validation data set. These classifications are based on a Decision Tree classifier.


- Classification based on NDVI statistical parameters

With this approach, the only classification parameter used to discriminate between fields was the mean value of NDVI, derived from the time series of NDVI images acquired during the month of March. This is the period during which cereals experience their most rapid growth. Earlier dates were not considered, because the sowing dates varied from one field to another. In the absence of any change in irrigation, this could significantly affect the measured values of NDVI. An empirical threshold of 0.6 was used to separate the irrigated from the non-irrigated fields. A field with a mean value of NDVI greater than 0.6 is thus interpreted as having irrigated crops, whereas fields with a lower NDVI are considered to be rainfed. This threshold can be shifted, in accordance with the climatic conditions and agricultural practices of the studied region.

The relatively poor accuracy (58.1%) of this “NDVI classification” is shown in Table 3.

**Table 3.** Classification accuracy when the NDVI is assessed.

Classes		Reference		
		Irrigated Pixels	Rainfed Pixels	Total
Classified	Irrigated pixels	1381	335	1716
	Rainfed pixels	616	334	950
	Total	1997	669	2666
Overall accuracy		58.1%		
Kappa coefficient (K)		0.12		




**Figure 9.** Classification of irrigated and rainfed areas using the NDVI parameter.

- Classification using soil moisture statistics only

With this approach, we use soil moisture alone as a parameter to discriminate between irrigated and non-irrigated fields, without the NDVI index. Using the SVM algorithm, we compute the hyperplane parameters from the mean and variance of soil moisture values, which are estimated from the time series (January to end of March). The hyperplane is then used to separate the irrigated from the non-irrigated fields. In this region, the irrigation of cereal fields generally begins in early January, whereas the period of maximum vegetation growth occurs towards the end of March; soil moisture estimations are limited by a maximum NDVI of approximately 0.7 [36].

Figure 10 provides two examples of typical soil moisture product time series, for the 2015–2016 and 2016–2017 agricultural seasons, corresponding to irrigated and rainfed fields. During the studied seasons, soil moisture estimations were not computed for cases in which the weather (cloud cover) during the 15 preceding days had hindered the acquisition of suitable Sentinel-2 images. In both cases, we observed a significant difference between the moisture levels of irrigated and rainfed fields. This difference was particularly strong in the case of the driest season (2015–2016), during which very low values of soil moisture were observed in the rainfed fields.




**Figure 10.** Temporal time series of remotely sensed soil moisture estimations, (a) 2015–2016; (b) 2016–2017.

The overall classification accuracy achieved with the soil moisture parameter is better than that obtained using the NDVI: 77.2%, with a Kappa coefficient (K) equal to 0.58 (Table 4).

**Table 4.** Classification accuracy when the soil moisture is assessed.

Classes	Reference		
	Irrigated Pixels	Rainfed Pixels	Total
Classified	Irrigated Pixels	70	1722
	Rainfed Pixels	978	1052
	Total	1048	2774
Overall Accuracy	77.2%		
Kappa coefficient (K)	0.58		



**Figure 11.** Classification of irrigated and rainfed areas using soil moisture parameters.


- Classification using statistical parameters derived from both soil moisture and NDVI

With this approach, a decision tree classification is used based on three statistical parameters: the mean value of NDVI for the month of March, using the same threshold (0.6) as described above, and the mean and variance of the soil moisture. Thresholds were applied to the SVM algorithm, based on two statistical parameters: the mean and variance of the soil moisture time series. In the second approach, the values of soil moisture computed for the period between the beginning of January and the end of March are considered.

The combined use of these three indicators leads to good results, with an overall classification accuracy of 71.8% (Table 5).

**Table 5.** Classification accuracy when both soil moisture and NDVI are assessed.

Classes		Reference		
		Irrigated Pixels	Rainfed Pixels	Total
Classified	Irrigated pixels	1554	3	1557
	Rainfed pixels	270	1112	1382
	Total	1824	1115	2939
Overall accuracy		71.8%		
Kappa coefficient (K)		0.52		



**Figure 12.** Classification of irrigated and rainfed areas using both soil moisture and NDVI parameters.

## 5. Discussion

### 5.1. Soil Moisture Estimation

Soil moisture retrievals were computed using two different approaches, using optical and radar data at high spatial resolution. The first approach was based on the direct inversion of the WCM and the second one used the NN techniques. The two methods provided good results, with an RMSE approximately equal to 6% (Vol.), and are highly correlated. However, overestimations and underestimations of the approach, as shown in Figures 4 and 6, are explained by dense vegetation cover and rough field.

The overestimation of soil moisture (in particular, the data points identified with a blue circle in Figure 4) is attributed to errors produced in the case of rough soil reference fields. In practice, as the proposed soil backscattering model simplifies the soil roughness to a uniform value for all fields, the soil moisture retrieved for fields with high roughness levels tends to be overestimated. For dense cereal crops with the highest values of NDVI (above 0.65, corresponding to the data points identified by a red ellipse in Figure 4), the proposed algorithm underestimates the soil moisture.

Two specific dates were selected to analyze the soil moisture maps. Figure 8a shows the soil moisture map, derived from the S-1 image acquired on 24 December 2016, revealing high levels of soil moisture across the site: most of the soil moisture values lie in the range between 25% (Vol.) and 45% (Vol.). The higher values correspond to a period characterized by a cumulative rainfall of 85 mm during the five days preceding the estimations, recorded by the meteorological station (INGC) within the site. Figure 8b (20 July 2016) corresponds to a dry date: the lowest values of soil moisture range between 5% (Vol.) and 20% (Vol.). In the case of this observation, no precipitation had been recorded during the months of June and July. The significantly higher values of soil moisture revealed in certain areas are interpreted as the consequence of local irrigation in selected fields.

### 5.2. Irrigation Mapping

The first generated irrigation map was based on the mean value of NDVI (Figure 9, Table 3). This classification provided the lowest results with an overall accuracy of 58.1%. Relatively frequent

confusions occur between rainfed and irrigated fields, due to two different factors: (a) in the case of the 2016–2017 season, which was not particularly dry, even non-irrigated fields could attain high values of NDVI; (b) as fertilizers are not used by all farmers, higher NDVI levels could be observed for non-irrigated, but fertilized fields, rather than for irrigated fields without fertilization. These constraints, combined with the absence of optical images on certain dates (due to cloud cover), illustrate the limitations of an approach-based solely on the interpretation of NDVI.

Figure 11 provided the resulting irrigation map from the classification using only soil moisture parameters (Mean and variance value). As shown in Table 3, the classification provided the highest accuracy. This improvement can be attributed to the fact that a relatively high level of soil moisture is a more reliable indicator of irrigation than a relatively high level of NDVI. The soil moisture indicator is particularly important in the semi-arid environment of the proposed site, where the number of rainfall events is generally very small, and the level of evaporation is high, leading to a substantial difference in the behavior of soil moisture, between irrigated and non-irrigated fields.

The third classification used the soil moisture parameters and the mean value of NDVI. The inclusion of soil moisture clearly improves the accuracy of the classification. However, the case using soil moisture parameters only yields, slightly better results, thus showing that the inclusion of the NDVI slightly degrades the classification accuracy. These results are typical for a semi-arid site with a small number of rainfall events, a high level of evaporation, and variable practices in terms of the use of fertilizers.

## 6. Conclusions

In semi-arid areas, water resources are becoming increasingly scarce. For this reason, it is important to propose scenarios for the improved management of these natural resources, in an effort to ensure the future protection and development of the agricultural sector.

The aim of the present study is to generate operational irrigation maps on an annual basis, distinguishing between irrigated and rainfed areas, for the management of irrigation and the implementation of agricultural strategies, at a high spatial resolution.

In an initial step, operational approaches were proposed for the retrieval of soil moisture maps, at the scale of individual fields on the semi-arid Kairouan plain in central Tunisia.

With the arrival of the Sentinel-1 and Sentinel-2 constellations, it has now become feasible to produce soil moisture products at high spatial resolutions and relatively high temporal frequencies.

The approach proposed in this study is based on the inversion of the WCM, using radar data recorded in the VV polarization and NDVI data derived from optical images. The estimated values of soil moisture are validated using ground measurements and a Neural Network (NN) moisture product. Consistent results are obtained when the two satellite moisture products are compared, with an RMSE of 4.3% (Vol.) and a bias of 1.29% (Vol.) between the two estimations.

A classification algorithm is proposed for the mapping of irrigated and rainfed areas over the Kairouan plain. The first approach to this classification uses a Support Vector Machine (SVM) to distinguish between irrigated and rainfed areas, based on soil moisture parameters (mean and variance). A Decision Tree classification is then used to produce irrigation maps with several simulations based on these parameters, for three specific cases: a classification based on mean NDVI values for agricultural fields; a classification based on the mean and variance of soil moisture time series; and lastly a classification based on the mean and variance of soil moisture time series, together with the mean values of NDVI. The highest overall classification accuracy (77%) is achieved when the soil moisture parameters only are used. The lowest accuracy is achieved when the mean values of NDVI only are used. In the present study, the added NDVI information to the soil moisture data decreased the quality of the classification. This outcome is probably due to the limited ability of NDVI to distinguish between irrigated and non-irrigated fields, in the specific context of our semi-arid study site, which is characterized by high levels of evaporation, rare and infrequent rainfall events, and the limited application of fertilizers. Despite the considerable potential of Sentinel-1 and Sentinel-2 data for the production of irrigation maps, in certain cases their 6-day revisit period could be insufficient for the observation of all irrigation and rainfall events. In a forthcoming study, these methods will be tested in more humid regions, in an effort to examine the changes in empirical thresholds considered

in this study, as well as the limitations and specific characteristics of the optical NDVI and soil moisture products when applied to the analysis of irrigation practices.

**Author Contributions:** S.B. and M.Z. designed and developed the experimental procedures; S.B. and P.F. performed the experiments; S.B., M.Z. and N.B. analyzed the data; Z.L.-C., Q.G. and M.E.H. contributed to the materials and analysis tools; and M.Z. and S.B. wrote the paper.

**Funding:** This study was funded by the CHAAMS (ERANET-MED 03-62 CHAAMS), TOSCA/CNES ASCAS projects and the ESA-ESTEC ITT AO/1-8845/16/CT project. The study benefited from the financial support of the *Allocation de Recherche pour une Thèse au Sud* (ARTS) provided by the Institut de Recherche pour le Développement (IRD). Mobility support from the Université de Carthage's allocation is also gratefully acknowledged.

**Acknowledgments:** We extend our warm thanks to the technical teams at the IRD and INAT (Institut National Agronomique de Tunisie), who made significant contributions to the ground-truth measurement campaigns and data processing operations.

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

## References

- Alexandratos, N.; Bruinsma, J. World Agriculture towards 2030/2050: The 2012 Revision; ESA Working Paper No. 12–13; Food and Agriculture Organization of the United Nations: Rome, Italy, 2012.
- Doungmanee, P. The nexus of agricultural water use and economic development level. *Kasetsart J. Soc. Sci.* 2016, 37, 38–45. [CrossRef]
- Simonneaux, V.; Lepage, M.; Helson, D.; Metral, J.; Thomas, S.; Duchemin, B.; Cherkaoui, M.; Kharrou, H.; Berjami, B.; Chehbouni, A. Estimation spatialisée de l'évapotranspiration des cultures irriguées par télédétection: Application à la gestion de l'irrigation dans la plaine du haouz (Marrakech, Morocco). *Sécheresse* 2009, 20, 123–130.
- Saadi, S.; Simonneaux, V.; Boulet, G.; Raimbault, B.; Mougenot, B.; Fanise, P.; Ayari, H.; Lili-Chabaane, Z. Monitoring irrigation Consumption using high resolution NDVI image time series: Calibration and validation in the Kairouan plain (Tunisia). *Remote Sens.* 2015, 7, 13005–13028. [CrossRef]
- Adeyemi, O.; Grove, I.; Peets, S.; Norton, T. Advanced Monitoring and Management Systems for Improving Sustainability in Precision Irrigation. *Sustainability* 2017, 9, 353. [CrossRef]
- Kharrou, M.; Page, M.L.; Chehbouni, A.; Simonneaux, V.; Er-Raki, S.; Jarlan, L.; Ouzine, L.; Khabba, S.; Chehbouni, G. Assessment of Equity and Adequacy of Water Delivery in Irrigation Systems Using Remote Sensing-Based Indicators in Semi-Arid Region, Morocco. *Water Resour. Manag.* 2013, 27, 4697–4714. [CrossRef]
- Ambika, A.K.; Wardlow, B.; Mishra, V. Data Descriptor: Remotely sensed high resolution irrigated area mapping in India for 2000 to 2015. *Sci. Data* 2016, 3, 160118. [CrossRef] [PubMed]
- Ozdogan, M.; Gutman, G. A new methodology to map irrigated areas using multi-temporal MODIS and ancillary data: An application example in the continental US. *Int. J. Remote Sens.* 2008, 112, 3520–3537. [CrossRef]
- Satalino, G.; Mattia, F.; Ruggieri, S.; Rinaldi, M. LAI estimation of agricultural crops from optical data at different spatial resolution. In Proceedings of the 2009 IEEE International Geoscience and Remote Sensing Symposium (IGARSS 2009), Cape Town, South Africa, 12–17 July 2009. [CrossRef]
- Eklundh, L.; Jin, H.; Schubert, P.; Guzinski, R.; Heliasz, M. An Optical Sensor Network for Vegetation Phenology Monitoring and Satellite Data Calibration. *Sensors* 2011, 11, 7678–7709. [CrossRef]
- Kuusik, A. Monitoring of vegetation parameters on large areas by the inversion of a canopy reflectance model. *Int. J. Remote Sens.* 1998, 19, 2893–2905. [CrossRef]
- Leprieux, C.; Verstraete, M.M.; Pinty, B. Evaluation of the performance of various vegetation indices to retrieve vegetation cover from AVHRR data. *Remote Sens. Rev.* 1994, 10, 265–284. [CrossRef]
- 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]
- Ghahremanloo, M.; Mobasheri, M.R.; Amani, M. Soil moisture estimation using land surface temperature and soil temperature at 5 cm depth. *Int. J. Remote Sens.* 2018. [CrossRef]
- Yang, Y.; Guan, H.; Lon, D.; Liu, B.; Qin, G.; Qin, J.; Batelaan, O. Estimation of Surface Soil Moisture from Thermal Infrared Remote Sensing Using an Improved Trapezoid Method. *Remote Sens.* 2015, 7, 8250–8270. [CrossRef]

16. Zribi, M.; Gorrab, A.; Baghdadi, N. A new soil roughness parameter for the modeling of radar backscattering over bare soil. *Remote Sens. Environ.* 2014, 152, 62–73. [CrossRef]
17. Saux-Picart, S.; Otlé, C.; Decharme, B.; André, C.; Zribi, M.; Perrier, A.; Coudert, B.; Boulain, N.; Cappelaere, B. Water and Energy budgets simulation over the Niger super site spatially constrained with remote sensing data. *J. Hydrol.* 2009, 375, 287–295. [CrossRef]
18. Zribi, M.; Chahbi, A.; 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]
19. Zribi, M.; Pardé, M.; Boutin, J.; Fanise, P.; Hauser, D.; Dechambre, M.; Kerr, Y.; Leduc-Leballeur, M.; Reverdin, G.; Skou, N.; et al. CAROLS: A New Airborne L-Band Radiometer for Ocean Surface and Land Observations. *Sensors* 2011, 11, 719–742. [CrossRef]
20. King, C.; Lecomte, V.; Le Bissonnais, Y.; Baghdadi, N.; Souchère, V.; Cerdan, O. Remote-sensing data as an alternative input for the ‘STREAM’ runoff model. *Catena* 2005, 62, 125–135. [CrossRef]
21. 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, 370–382. [CrossRef]
22. Dubois, P.C.; Van Zyl, J.; Engman, T. Measuring soil moisture with imaging radars. *IEEE Trans. Geosci. Remote Sens.* 1995, 33, 915–926. [CrossRef]
23. Baghdadi, N.; Choker, M.; Zribi, M.; El-hajj, M.; Paloscia, S.; Verhoest, N.; Lievens, H.; Baup, F.; Mattia, F. A new empirical model for radar scattering from bare soil surfaces. *Remote Sens.* 2016, 8, 920. [CrossRef]
24. 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]
25. Baghdadi, N.; King, C.; Chanzy, A.; Wigneron, J.P. An empirical calibration of the integral equation model based on SAR data, soil moisture and surface roughness measurement over bare soils. *Int. J. Remote Sens.* 2002, 23, 4325–4340. [CrossRef]
26. Baghdadi, N.; Holah, N.; Zribi, M. Calibration of the integral equation model for SAR data in C-band and HH and VV polarizations. *Int. J. Remote Sens.* 2006, 27, 805–816. [CrossRef]
27. Attema, E.P.W.; Ulaby, F.T. Vegetation modeled as a water cloud. *Radio Sci.* 1978, 13, 357–364. [CrossRef]
28. Prévot, L.; Champion, I.; Guyot, G. Estimating surface soil moisture and leaf area index of a wheat canopy using a dual-frequency (C and X bands) scatterometer. *Int. J. Remote Sens.* 1993, 46, 331–339. [CrossRef]
29. Kumar, K.; Hari Prasad, K.S.; Arora, M.K. Estimation of water cloud model vegetation parameters using a genetic algorithm. *Hydrol. Sci. J.* 2012, 57, 776–789. [CrossRef]
30. 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]
31. 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]
32. 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]
33. Elshorbagy, A.; Parasuraman, K. On the relevance of using artificial neural networks for estimating soil moisture content. *J. Hydrol.* 2008, 362, 1–18. [CrossRef]
34. Paloscia, S.; Pampaloni, P.; Pettinato, S.; Santi, E. Generation of soil moisture maps from ENVISAT/ASAR images in mountainous areas: A case study. *Int. J. Remote Sens.* 2010, 31, 2265–2276. [CrossRef]
35. Paloscia, S.; Pettinato, S.; Santi, E.; Notarnicola, C.; Pasolli, L.; Reppucci, A. Soil moisture mapping using Sentinel-1 images: Algorithm and preliminary validation. *Int. J. Remote Sens.* 2013, 134, 234–248. [CrossRef]
36. 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]
37. Hassan-Esfahani, L.; Torres-Rua, A.; Jensen, A.; McKee, M. Assessment of Surface Soil Moisture Using High-Resolution Multi-Spectral Imagery and Artificial Neural Networks. *Remote Sens.* 2015, 7, 2627–2646. [CrossRef]
38. Mishra, V.; Cruise, J.F.; Hain, C.R.; Mecikalsk, J.R.; Anderson, M.C. Development of soil moisture profiles through coupled microwave–thermal infrared observations in the southeastern United States. *Hydrol. Earth Syst. Sci.* 2018, 22, 4935–4957. [CrossRef]

39. Jackson, T.J.; Cosh, M.H.; Bindlish, R.; Starks, P.J.; Bosch, D.D.; Seyfried, M.; Goodrich, D.C.; Moran, M.S.; Du, J. Validation of Advanced Microwave Scanning Radiometer Soil Moisture Products. *IEEE Trans. Geosci. Remote Sens.* 2010, 48, 4256–4272. [CrossRef]
40. Le Morvan, A.; Zribi, M.; Baghdadi, N.; Chanzy, A. Soil moisture profile effect on radar signal measurement. *Sensors* 2008, 8, 256–270. [CrossRef]
41. Zribi, M.; Kotti, F.; Wagner, W.; Amri, R.; Shabou, M.; Lili-Chabaane, Z.; Baghdadi, N. Soil moisture mapping in a semi-arid region, based on ASAR/Wide Swath satellite data. *Water Resour. Res.* 2014, 50, 823–835. [CrossRef]
42. Gao, Q.; Zribi, M.; Baghdadi, N.; Escorihuela, M.J. Synergetic Use of Sentinel-1 and Sentinel-2 Data for Soil Moisture Mapping at 100 m Resolution. *Sensors* 2017, 17, 1966. [CrossRef]
43. 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 Tropical Region. *Remote Sens.* 2015, 7, 8128–8153. [CrossRef]
44. Thiruvengadachari, S. Satellite sensing of irrigation pattern in semiarid areas: An Indian study. *Photogramm. Eng. Remote Sens.* 1981, 47, 1493–1499.
45. Gao, Q.; Zribi, M.; Escorihuela, M.; Baghdadi, N.; Segui, P. Irrigation Mapping Using Sentinel-1 Time Series at Field Scale. *Remote Sens.* 2018, 10, 1495. [CrossRef]
46. Thenkabail, P.S.; Schull, M.; Turrall, H. Ganges and Indus river basin land use/land cover (LULC) and irrigated area mapping using continuous streams of MODIS data. *Remote Sens. Environ.* 2004, 95, 317–341. [CrossRef]
47. Fieuzal, R.; Duchemin, B.; Jarlan, L.; Zribi, M.; Baup, F.; Merlin, O.; Dedieu, G.; Garatuza-Payan, J.; Watt, C.; Chehbouni, A. Combined use of optical and radar satellite data for the monitoring of irrigation and soil moisture of wheat crops. *Hydrol. Earth Syst. Sci.* 2011, 15, 1117–1129. [CrossRef]
48. Dheeravath, V.; Thenkabail, P.S.; Chandrakantha, G.; Noojipady, P.; Reddy, G.P.O.; Biradar, C.M.; Gumma, M.K.; Velpuri, M. Irrigated areas of India derived using MODIS 500 m time series for the years 2001–2003. *ISPRS J. Photogramm. Remote Sens.* 2009, 65, 42–59. [CrossRef]
49. Kamthonkiat, D.; Honda, K.; Turrall, H.; Tripathi, N.K.; Wuwongse, V. Discrimination of irrigated and rainfed rice in a tropical agricultural system using SPOT VEGETATION NDVI and rainfall data. *Int. J. Remote Sens.* 2005, 26, 2527–2547. [CrossRef]
50. Gumma, M.K.; Thenkabail, P.S.; Hideto, F.; Nelson, A.; Dheeravath, V.; Busia, D.; Rala, A. Mapping Irrigated Areas of Ghana Using Fusion of 30 m and 250 m Resolution Remote-Sensing Data. *Remote Sens.* 2011, 3, 816–835. [CrossRef]
51. Jin, N.; Tao, B.; Ren, W.; Feng, M.; Sun, R.; He, L.; Zhuang, W.; Yu, Q. Mapping Irrigated and Rainfed wheat areas using multi-temporal satellite Data. *Remote Sens.* 2016, 8, 207. [CrossRef]
52. Meier, J.; Zabel, F.; Mauser, W. A global approach to estimate irrigated areas—A comparison between different data and statistics. *Hydrol. Earth Syst. Sci.* 2018, 22, 1119–1133. [CrossRef]
53. Gorrab, A.; Zribi, M.; Baghdadi, N.; Mougenot, B.; Fanise, P.; Lili Chabaane, Z. Retrieval of Both Soil Moisture and Texture Using TerraSAR-X Images. *Remote Sens.* 2015, 7, 10098–10116. [CrossRef]
54. Ulaby, F.T.; Moore, R.K.; Fung, A.K. *Microwave Remote Sensing Active and Passive*; Artech House Publishers: Reading, MA, USA, 1986.
55. Mountrakis, G.; Im, J.; Ogole, C. Support vector machines in remote sensing. A review. *ISPRS J. Photogram. Remote Sens.* 2011, 66, 247–259. [CrossRef]
56. Pal, M.; Mather, P.M. Support vector machines for classification in remote sensing. *Int. J. Remote Sens.* 2005, 26, 1007–1011. [CrossRef]
57. Huang, C.; Davis, L.; Townshend, J. An assessment of support vector machines for land cover classification. *Int. J. Remote Sens.* 2002, 23, 725–749. [CrossRef]
58. McIver, D.K.; Friedl, M.A. Using prior probabilities in decision-tree classification of remotely sensed data. *Remote Sens. Environ.* 2002, 81, 253–261. [CrossRef]
59. Punia, M.; Joshi, P.K.; Prwal, M.C. Decision trees classification of land use cover for Delhi, India using IRS-P6 AWiFS data. *Expert Syst. Appl.* 2010, 38, 5577–5583. [CrossRef]



#### 4.5. Synthèse et conclusion partielle

L'irrigation agricole absorbe plus de 80 % des ressources en eau annuelles. La gestion de l'irrigation devient alors une activité délicate pour les différents acteurs de l'eau (agriculteurs, organismes et ministère). La gestion à grandes échelles reste, quant à elle, beaucoup plus compliquée. L'hétérogénéité spatiale de l'état hydrique du sol rend dans ce cas la planification théorique de l'irrigation difficile. Un suivi dynamique et en temps réel de l'irrigation va permettre la mise au point de stratégies pour évaluer les apports en eau et le stress hydrique au niveau de la culture.

Dans le cas particulier de la plaine de Kairouan, les ressources en eau deviennent de plus en plus rares. Le défi à travers cette étude est de développer une approche qui va permettre de faciliter le recensement des zones irriguées et non-irriguées à travers une carte annuelle d'irrigation à haute résolution spatiale.

L'approche proposée dans cette étude pour le suivi de l'état hydrique repose sur l'inversion du modèle WCM en utilisant des données radars (S-1) enregistrées uniquement dans la polarisation VV et des données NDVI dérivées d'images optiques (S-2). Les résultats de cette approche semblent très encourageants. Elle montre aussi la possibilité d'extraire différents produits à partir des données Sentinel.

La détection de l'irrigation a été développée en se basant sur ces produits satellitaires (NDVI dérivé des images S-2 et humidité du sol du modèle WCM) avec des algorithmes de classification (SVM et Arbre de Décision) afin de distinguer entre les parcelles irriguées et non-irriguées. Trois approches de classification sont testées, elles comprennent à chaque fois l'utilisation d'indices spécifiques. Une première approche utilise des moyennes temporelles de NDVI et donne les résultats les moins précis (avec une précision globale de 58 %). Cette méthode, basée sur des données optiques, est aussi limitée par les conditions météorologiques, ce qui réduit la précision de la classification (58 % de précision globale). La deuxième approche additionne à la première des valeurs statistiques obtenues de la série temporelle d'humidité du sol sur l'année agricole 2017, à savoir les variances et les moyennes temporelles. Les résultats s'améliorent pour parvenir à une précision de l'ordre de 70 %. Cependant les meilleurs résultats ont été obtenus en utilisant uniquement les paramètres statistiques de l'humidité du sol avec une précision de l'ordre de 77 %.

# Chapitre 5: Estimation de la texture du sol

*Dans les chapitres précédents, nous avons estimé l'humidité du sol spatialisée sur la plaine de Kairouan, à l'aide d'une synergie de données radars et optiques. A partir de cette approche, on a pu concevoir une série temporelle d'images d'humidité du sol à haute résolution spatiale. Nous avons vu, lors du Chapitre 4, son application pour générer une carte d'irrigation annuelle. On verra dans ce chapitre son intérêt pour la pédologie, précisément pour l'estimation du taux d'argile dans le sol.*

*La démarche adoptée pour la cartographie du contenu en argile est les différents résultats sont décrit dans l'article suivant:*

*Bousbib, S., Zribi, M., Pelletier, C., Gorrah, A., Lili-Chabaane, Z., Baghdadi, N., Ben Aissa, N., Mougnot, B.. Soil texture estimation using radar and optical data from Sentinel-1 and Sentinel-2. Remote Sensing, 2019, 11, 1520 ; doi:10.3390/rs11131520.*

*Publié dans le journal Remote Sensing.*

## Sommaire

---

<b>CHAPITRE 5: ESTIMATION DE LA TEXTURE DU SOL .....</b>	<b>114</b>
5.1. INTRODUCTION .....	115
5.2. METHODOLOGIE.....	115
5.3. ARTICLE .....	116
5.1. SYNTHÈSE ET CONCLUSION PARTIELLE.....	136

---

## 5.1. Introduction

Le sol constitue une ressource naturelle précieuse. En effet, il remplit un certain nombre de fonctions éco systémiques et environnementales. C'est un élément clé pour la production agricole, le cycle de l'eau, le filtrage des polluants et le stockage de carbone. La compréhension et la modélisation des processus biologiques, physiques et chimiques du sol ont fait l'objet de plusieurs travaux scientifiques (Sanchez et al., 2009 ; Von Eynatten et al., 2003 ; Samouëlian et al., 2007). Il est toutefois nécessaire d'utiliser une information précise et spatialisée sur les sols pour des échelles locales et régionale. Entre autre, connaître la texture du sol est primordiale pour les agronomes, hydrologues, géologues et environnementalistes.

Par sa composition, sa structure, sa texture et sa porosité, l'humidité du sol est fortement influencée par la nature du sol. L'objectif à travers cette étude est de réaliser une carte de teneur en argile à partir de données multi-capteurs et de produits d'humidité du sol, à travers des algorithmes de classification. Dans cette partie, une étude est effectuée afin de déterminer les données adéquates (entre optique et radar) permettant de caractériser précisément la teneur en argile. La méthodologie du travail est présentée dans la Sections 5.2. Ensuite les principaux résultats de ce travail et l'article publié sont exposés dans la Section 5.3. La Section 5.4 comporte la synthèse de ce chapitre les principales conclusions.

## 5.2. Méthodologie

Ce chapitre illustre l'utilisation de divers produits issus de données satellitaires multi-capteurs. L'objectif de ce travail est d'établir une spatialisation de la teneur en argile sur la même zone d'étude, la plaine de Kairouan.

Pour ce faire, différents jeux de données sont utilisés, d'abord pour étudier la sensibilité du sol aux données radars et optiques :

- Les bandes optiques issues du capteur S-2, à savoir les bandes B2, B3, B4, B5, B6, B7, B8, B8A, B11 et B12 ;
- Les indices optiques calculés à partir des images S-2 : le SRCI (Simple Ratio Clay Index) et le BI (Brightness Index) ;
- Les produits humidités du sol obtenus par une synergie optique/radar (Chapitre 4).

Les résultats des analyses de sensibilité révèlent que la teneur en argile est plus sensible aux deux bandes B11 et B12 de l'optique et à l'humidité du sol, qu'aux autres données.

Entre les mois de Juillet et Aout, les données optiques (B11 et B12) sont utilisées pour la cartographie de la texture du sol afin de ne prendre confondre l'effet de l'humidité du sol (due généralement à des précipitations) qui influence fortement les données optiques. De ce fait, les mesures ont été effectuées sur des parcelles de sols nus sur toute cette période sèche.

D'autre part, La texture du sol est fonction des fractions d'argile, de limon et de sable et peut être fortement influencée par la rétention d'eau et l'infiltration. Les niveaux

d'humidité des sols étant généralement plus élevés pour les sols argileux que pour les sols sableux, nous avons analysé les données enregistrées à l'automne, entre le mois de Septembre et le mois de Décembre, car cela correspond à une période caractérisée par de fortes précipitations sur la zone d'étude. Cette période correspond notamment à la période du commencement de la saison agricole avec une moyenne présence de la végétation.

Les algorithmes proposés lors de ce travail sont basés sur les méthodes de classification par SVM (Support Vector Machine) et RF (Random Forest).

### **5.3. Article**

Article

# Soil Texture Estimation Using Radar and Optical Data from Sentinel-1 and Sentinel-2

Safa Bousbih <sup>1,2,\*</sup>, Mehrez Zribi <sup>1</sup>, Charlotte Pelletier <sup>3</sup>, Azza Gorrab <sup>2</sup>, Zohra Lili-Chabaane <sup>2</sup>, Nicolas Baghdadi <sup>4</sup>, Nadhira Ben Aissa <sup>2</sup> and Bernard Mougenot <sup>1</sup>

<sup>1</sup> CESBIO (CNRS/UPS/IRD/CNES/INRA), 18 Avenue Edouard Belin, 31401 Toulouse CEDEX 9, France

<sup>2</sup> Université de Carthage/INAT/LR GREEN-TEAM, 43 Avenue Charles Nicolle, Tunis 1082, Tunisia

<sup>3</sup> Faculty of Information Technology, Monash University, Melbourne, VIC 3800, Australia

<sup>4</sup> IRSTEA, University of Montpellier, UMR TETIS, 34093 Montpellier CEDEX 5, France

\* Correspondence: safabousbih1@outlook.fr ; Tel.: +33-56155-8501 (S.B.)

Received: 20 May 2019; Accepted: 25 June 2019; Published: 27 June 2019

**Abstract:** This paper discusses the combined use of remotely sensed optical and radar data for the estimation and mapping of soil texture. The study is based on Sentinel-1 (S-1) and Sentinel-2 (S-2) data acquired between July and early December 2017, on a semi-arid area about 3000 km<sup>2</sup> in central Tunisia. In addition to satellite acquisitions, texture measurement samples were taken in several agricultural fields, characterized by a large range of clay contents (between 13% and 60%). For the period between July and August, various optical indicators of clay content Short-Wave Infrared (SWIR) bands and soil indices) were tested over bare soils. Satellite moisture products, derived from combined S-1 and S-2 data, were also tested as an indicator of soil texture. Algorithms based on the support vector machine (SVM) and random forest (RF) methods are proposed for the classification and mapping of clay content and a three-fold cross-validation is used to evaluate both approaches. The classifications with the best performance are achieved using the soil moisture indicator derived from combined S-1 and S-2 data, with overall accuracy (OA) of 63% and 65% for the SVM and RF classifications, respectively.

**Keywords:** Sentinel-1; Sentinel-2; Soil Moisture; Texture; Clay; SVM; Random Forest

---

## 1. Introduction

Soil properties play a key role in various processes related to continental surface hydrology, describing the distribution of rainwater or irrigation between runoff, seepage, and evapotranspiration [1–3]. In this context, although ground measurements have long been used to estimate the water status or soil texture, they are time-consuming and costly procedures, and are generally considered to be inadequate, since they do not allow spatio-temporal variations in soil moisture to be correctly monitored. The scientific community has thus devoted considerable effort to the development of remote sensing products, in an effort to improve the accuracy and spatio-temporal coverage of these observations when they are interpreted for hydrological applications and water resource management [4–8].

In recent years, remote sensing has been used to retrieve soil properties such as soil moisture, roughness, soil texture. Among these approaches, promising techniques such as spectroscopy in the visible (VIS) and near-infrared (NIR) spectroscopy have been used as proximal sensing techniques and enable the measurement of texture. Indeed, soil components are sensitive to these portions of the electromagnetic spectrum, which allow the assessment of soil textural composition

[9]. Curcio et al. [10] have predicted soil texture (sand, clay, and silt) using VNIR-SWIR band reflectance spectroscopy. High resulting accuracies were found for both of clay, sand silt fraction, using the partial least-squares regression (PLSR) methods with coefficients of determination of 0.87, 0.8 and 0.6, respectively. Tümsavaş et al. [11] used the VIS-NIR spectroscopy to predict and map sand and clay fraction over agricultural fields with a regression coefficient of 0.9 and 0.91, respectively.

Since 2014, Sentinel-1 radar data has been available over Europe and other regions of the globe, with a 6-day repeat cycle and both high and fine spatial resolution (ranging between 5 and 40 m, depending on the acquisition mode and the product type). Various algorithms have been developed for the generation of operational soil moisture products, in particular for agricultural areas. The present authors have computed soil moisture products over agricultural fields with a vegetation cover, using a synergetic combination of optical and radar data, through the use of neural networks, a change detection and the simple inversion of a backscattering model [12–15].

Soil texture is a key parameter in the development of PedoTransfer Functions (PTFs), which are based on soil properties (physical, chemical and biological), and are often used to estimate difficult-to-measure hydraulic soil properties. In particular, clay content has a strong influence on the hydraulic properties of soils, and can be interpreted in terms of the soil's water-holding capacity. Several studies have been proposed for the estimation of soil texture components, using remotely sensed optical images. These techniques rely mainly on optical data and the interpretation of ground reflectance to determine soil color [16–18].

More recently, several techniques have been developed for the interpretation of various types of optical satellite observation (Landsat, SPOT, Sentinel-2, etc.) [19–25]. These are restricted mainly to the analysis of bare soils, since the observation of fields with a vegetation cover can be affected by the noise produced by canopies. For instance, Shabou et al. [26] proposed a method for clay content estimations, based on the mid-infrared index (MID) derived from the TM 5 and TM 7 bands of Landsat data, recorded over central Tunisia. Vaudour et al. [27] recently predicted several topsoil properties (clay, SOC, iron, pH, etc.) from a chemometric model, using Sentinel-2 spectral band observations. Their clay content predictions are correlated with in situ measurements, with a coefficient of determination ( $R^2$ ) equal to 0.39 and 0.42 for the Versailles Plain and the La Peyne Valley (France), respectively. Gomez et al. [21] investigated the clay content sensitivity associated with various different spectral configurations, for the Sentinel-2, ASTER, Landsat-8 OLI and Landsat-7 ETM+ satellites, and used PLSR models with this multi-sensor data. Radar remote sensing, which is generally used to estimate soil moisture and soil roughness, has also been evaluated for its ability to perform texture measurements. Zribi et al. [28] proposed the estimation of soil moisture from TerraSAR-X radar data following a rain event, and were able to relate the drying speed of the surface moisture to the clay content, which was determined with an accuracy of 12 %. Gorrab et al. [29] used a linear regression relationship between soil moisture products (derived from TerraSAR-X radar data), and clay content, which was estimated with a Root Mean Square Error (RMSE) of 108 g/kg.

In this context, the aim of the present study is to make use of multi-sensor data derived from the Sentinel-1 and Sentinel-2 satellites, to evaluate different optical and radar indicators for soil clay content estimations. This analysis is based on field and satellite measurements acquired over the Kairouan Plain, in central Tunisia. We analyze the sensitivity of several indicators to soil texture, and make use of the RF and SVM algorithms to determine clay content classifications.

This paper has four main sections. Section 2 describes the study site, the database, and the methodologies used for clay content mapping, based on two classification algorithms (support vector machine and random forest). The results and discussion are presented in Sections 3 and 4, and the conclusions in Section 5.

## 2. Materials and Methods

### 2.1. Study Site

The study site is located on the Kairouan Plain which covers a surface area in the eastern portion of the Tunisian Atlas (centered on 9°53'57"E and 35°4'51"N). This area has a semi-arid climate and

mean annual precipitation of 300 mm [30]. The landscape is mainly flat. The principal land cover categories are agricultural fields, urban areas, salt flats, water bodies and some low-lying mountains located in the West. The economy of the Kairouan Plain is based on the agricultural sector, in which the dominant crops are mainly olive groves and winter crops [12]. Due to severely limited water resources in the region (annual rainfall of 300 mm and a high rate of evaporation), the management of these resources is essential.

The soils found on the study site are formed mainly by alluvial deposits, with clay and coarse sand formations, and are characterized by a high spatial variability of their texture. The main soil units are poor soils, complex soils (several soil units), calcimagnetic soils and isohumic soils [26]. In this context, the extreme floods of 1969 led to strong spatial heterogeneities in terms of soil texture, as they deposited sandy to sand loamy materials in the upstream and downstream sectors. They also carried large quantities of alluvia which, together with the natural deposit mechanism, changed the spatial distribution of these deposits [31]. Indeed, the thrust of the deposit along the major bed of the wadi, when it overflows, leads to a distribution with the coarsest components remaining upstream whereas the finest alluvia are carried downstream.

On the other hand, the introduction of crop systems and fields has led to cyclical evolutions of the surface conditions and land use over the time. Tillage and farming operations can thus modify the physical characteristics of the soil, resulting in changes in its surface texture.


## 2.2. Ground Texture Measurements

During the autumn of 2017, a texture measurement campaign was carried out over 33 bare soil fields, characterized by a large range of soil textures. For each reference field, 5 to 10 ground sample were collected inside a 30 m diameter circle from the upper soil layer (a depth of 5 cm) based on visual assessment of topsoil textural changes. To reduce the risk of bias and to ensure a uniform distribution of the samples, they were selected randomly for each reference field.

Sieve analyses were used to classify the particles smaller than 2 mm in samples as being clay, silt, or sand. The laboratory technique was based on the international “Robinson” pipette method. Firstly, the experiment relies on the destruction of organic matter by hydrogen peroxide. A dispersing solution of sodium hexametaphosphate is then added to neutralize the flocculating action. After stirring, the fine fractions, silt and clay, are separated by sedimentation. The removal of the latter is based on the relationship, linking the sedimentation time to the particle diameter, given by the Stocks’ law which describes the settling velocity of particles in a suspension as function of the sedimentation rate. A small volume of the suspension is taken with a Robinson pipette, from which the solid residue will be weighed after evaporation of the liquid. Coarse fractions and coarse and fine sands are separated by sieving.

Soil texture is defined as the distribution of the soil’s constituent mineral particles, classified by size. According to the USDA (United States Department of Agriculture) classification, particles smaller than 2  $\mu\text{m}$  in diameter are classed as clay, particles with a diameter between 2 and 50  $\mu\text{m}$  are classed as silt, and particles with a diameter between 0.05 and 2 mm are classed as sand.

From the samples taken during the ground campaign, the measured clay content ranked between 12.7% and 58%, and the sand content between 2% and 73%. The results from the fields analyzed during this campaign are plotted on the soil texture triangle shown in Figure 1. Three dominant soil classes can be distinguished: clay soil, clay loamy soil as a continuous distribution between sandy loam, and sandy clay loam soil. The samples were ranked according to three main classes, depending on their soil clay fraction. The first class corresponds to soils with low clay content (between 13 and 30%), the second class corresponds to clay content values between 30% and 45%, and the third class is used to identify soils with high values of clay content (between 45% and 60%).



**Figure 1.** Soil texture samples over the Kairouan Plain, plotted on the soil texture triangle. A single point, corresponding to the average value of several soil samples, is used to represent each of the 33 reference fields.

### 2.3. Satellite Data

#### 2.3.1. Sentinel-1 Data

The Sentinel-1A (S-1A) and Sentinel-1B (S-1B) satellites were launched in April 2014 and April 2016, as part of the “Copernicus” program, for the observation and monitoring of Earth’s surface, and the development of operational applications for environmental monitoring. The Synthetic Aperture Radars (SARs) carried by these satellites are indifferent to weather conditions and allow data acquisition day and night, in the form of single and dual polarization images (VV, VH, HH, and HV). C-band data (wavelength  $\sim 6$  cm) in the form of Interferometric Wide (IW) swath images, acquired by the Sentinel-1 (S-1) constellation between September and early December 2017, was used for this study in the VV polarization. Fourteen S-1A and S-1B images were thus downloaded from the Copernicus web site (<https://scihub.copernicus.eu/dhus/#/home>) in the form of Level-1 Ground Range Detected (GRD) products, with a spatial resolution of 10 m and a six-day periodicity (Table 1). In the case of the S-1 images, the study site was imaged at an incidence angle ( $\theta$ ) of approximately  $39^\circ$ . To extract the backscattering coefficient, several processing steps were performed on each image comprising thermal noise removal, radiometric calibration, geometric correction and speckle filtering [32].

**Table 1.** Sentinel-1 (S-1) data acquired over the Kairouan Plain, from September 2017 until the beginning of December 2017.

Satellites	Dates	Polarization	Incidence Angle ( $\theta$ )
S-1B	08/09/2017	VV	$39\text{--}40^\circ$
S-1A	14/09/2017	VV	$39\text{--}40^\circ$
S-1B	20/09/2017	VV	$39\text{--}40^\circ$
S-1A	26/09/2017	VV	$39\text{--}40^\circ$
S-1B	02/10/2017	VV	$39\text{--}40^\circ$

Table 1. Cont.

Satellites	Dates	Polarization	Incidence Angle ( $\theta$ )
S-1A	08/10/2017	VV	39–40 °
S-1B	14/10/2017	VV	39–40 °
S-1A	20/10/2017	VV	39–40 °
S-1B	26/10/2017	VV	39–40 °
S-1B	07/11/2017	VV	39–40 °
S-1A	13/11/2017	VV	39–40 °
S-1A	25/11/2017	VV	39–40 °
S-1B	01/12/2017	VV	39–40 °
S-1A	07/12/2017	VV	39–40 °

### 2.3.2. Sentinel-2 Data

Sentinel-2A (S-2A) is a spaceborne spectral imager, which was launched by the European Space Agency (ESA) in June 2015 as part of the “Copernicus” program. It is accompanied by Sentinel-2B (S-2B), launched in March 2017, which allows a repeat cycle of 5 days to be achieved using both satellites. This constellation takes images in 13 spectral bands, at visible and mid-infrared wavelengths and at various spatial resolutions (10, 20, 60 m), as shown in Table 2.

**Table 2.** Sentinel-2 (S-2) spectral band characteristics.

Spectral Bands	Wavelength (nm)	Spatial Resolution (m)
Band 1 (Aerosol)	443	60
Band 2 (Blue)	490	10
Band 3 (Green)	560	10
Band 4 (Red)	665	10
Band 5 (Vegetation Red-Age)	705	20
Band 6 (Vegetation Red-Age)	740	20
Band 7 (Vegetation Red-Age)	783	20
Band 8 (NIR)	842	10
Band 8A (Vegetation Red-Age)	865	20
Band 9 (NIR)	945	60
Band 10 (SWIR)	1375	60
Band 11 (SWIR)	1610	20
Band 12 (SWIR)	2190	20

Eight cloud-free S-2 images acquired between July and August 2017, were used for the present study. These optical images were obtained from the THEIA website at the French Land Data Center (<https://www.theia-land.fr/>), which provides data in the level-2A format, including radiometric and atmospheric corrections, based on the method developed by Hagolle et al. [33].

In this study, bands 4 (B4), 8 (B8), 9 (B9), 11 (B11) and 12 (B12) are used to generate the soil and vegetation indices presented in Section 3.1.


To retrieve bare soil areas and produce soil moisture maps, normalized difference vegetation index (NDVI) maps were derived from the optical images, using B4 and B8. The NDVI pixel values within each reference field were averaged, to characterize the vegetation conditions of that field. Consequently, an NDVI threshold value of 0.25 was used to retain only bare soils. The use of NDVI highlights the difference between crop and soil.

### 2.3.3. Derived Soil Moisture Products

Soil moisture maps were produced at a high spatial resolution, by combining SAR and optical images derived from the S-1 and S-2 constellations, respectively. Backscattering models have been used to retrieve soil moisture over different period. Combined models were used to invert the radar signals for soil moisture estimation: The Water Cloud Model (WCM) [34](Attema & Ulaby, 1978) and Integral Equation Model (IEM) [35], using a Neural Network technique. The WCM has been used for

area covered by the vegetation, while the IEM for bare soils. Both coupled models have considered soil moisture and roughness as soil parameters and vegetation indicator (e.g., vegetation height, biomass, LAI, etc.) derived from optical images. In this study, the NDVI was used to describe the vegetation cover, derived from the red (R) and near infrared (NIR) bands of S-2 images.

These models have been calibrated and validated in previous studies [8,12,32,36], over different study sites. The backscattering coefficient is modeled as the sum of the soil and vegetation contributions. It is then inverted to estimate soil moisture over the study site. Bousbih et al. [12] and El Hajj et al. [14] have shown that the soil moisture can be estimated with an accuracy of 6% vol. over agricultural fields. The 14 images were thus used to produce soil moisture maps, which were averaged over the period of acquisition. Figure 2 shows an example of soil moisture map from 14 of September 2017 with the masked area, presented in white color and corresponding to urban areas, water bodies, and some reliefs. Both maps, presented in the upper right corner of the figure, display two different case of soil moisture. The first one (with green colors) correspond to a wet date (01/12/2017) and the second one (with red colors) to a dry date (20/09/2017).



**Figure 2.** Soil moisture map over the Kairouan Plain, derived from the combined use of Sentinel-1 and Sentinel-2 data, with the upper maps representing 01/12/2017 (in the left) and 20/09/2017 (in the right).

## 2.4. Classifier Algorithms

Several classification methods have already been applied to texture mapping over agricultural fields [37–39]. With these methods, in addition to the selected feature vector, a set of data samples is associated with different class labels. This set is called the training dataset, and is used to estimate the parameters associated with each classifier. The point-based classification used with the SVM is adopted.

SVMs were selected because a simple feature vector can be used as input for the discrimination task. In parallel, the random forest (RF) classifier was trained to compare the soil texture classifications obtained using these two techniques, which are presented in more details in the following subsections.

### 2.4.1. Support Vector Machine

The support vector machine (SVM, also known as a support vector network) has been widely used in the context of remote sensing classification applications. The classifier tries to determine a hyperplane (a decision boundary) that can provide optimal separation between two sets of data, while maximizing the margin between these two sets. The margin is then defined by the minimum distance between a training sample and the decision boundary (the distance between the two samples, which are closest to the hyperplane).

Under these conditions, an SVM is a binary classifier, as it is generally used to separate data points into one or the other of two distinct classes. As the data may not always be linearly separable, the training data can in some cases contain more than two classes. To extend the SVM to a multiclass classification algorithm, by breaking it down into a predefined series of binary problems [40,41], two main strategies have been developed which are: One-against-one [42] and One-against-all [43].

In cases where the data are not linearly separable, a non-linear transformation is applied to the input data, using a kernel function. Various kernel functions have been proposed, of which the most commonly used are the Gaussian and radial basis function (RBF) kernels. The regularization parameter  $C$  for the kernel functions must be tuned. In the present study, a Gaussian radial basis function (SVM-RBF) was chosen.

The major strength of SVMs is their kernel function: through the selection of an appropriate kernel function, any complex problem can be solved. The main disadvantage of the SVM classification technique is that it has a high cost in terms of computing time compared to other classification algorithms such as RF classifier [44,45]. It is also difficult to set the critical parameters, for which cross-validation optimization can be needed [36].

#### 2.4.2. Random Forests

A RF classification algorithm is based on the construction of several decision trees, by (randomly) selecting just one subset among all available samples (the Forest). Each tree votes for a class, and the majority vote determines the final class. This means that RF is an improved version of the Decision Tree classification. This technique has also been widely used in the context of remote sensing classifications, where it has been applied to multispectral data, multitemporal images, and SAR and optical data.

The method adopted in the present study was proposed by Breiman [46]. In its most classical form, it uses a randomly built multiple decision tree, with training on different subsets of data. Specifically, each tree of the RF is trained on a random subset of data (called features). The RF algorithm is known to be one of the most efficient classifiers, and has been widely reported in remote sensing literature in recent decades. This algorithm has been used for various applications, including the analysis and classification of soil texture and land use in the agricultural sector.

The development of a RF classifier involves the construction of Classification And Regression Trees (CART) from the samples. A subset of input features (also called attributes) is randomly selected to form a set of predictor variables. Each tree is built by performing an individual learning algorithm that splits the set of input variables into subsets, based on an attribute value test. For the classification, each tree gives a unit of vote for the most popular class in each instance. A majority vote of all the trees determines the final label.

The RF classifier has three important parameters affecting its performance: the number of trees ( $K$ ) (typically, the greater the number of trees, the better the accuracy), the maximum depth of the tree (a tree cannot have a depth exceeding 25), and the minimum number of samples in each node.

The computational complexity of a RF is reduced by limiting the number of features it has. The split RF process is repeated on each derived subset, until the score contains very similar samples, or the splitting no longer adds value to the predictions. For implementation purposes, it is indeed unlikely that the RF reaches this maximum depth. During the decision phase, each tree classifies the input feature data. Then, the RF outputs the class label that has received the majority vote. In the case of a RF, the parameters have a very weak influence on the results of the classifications. In the present study, the parameters were set as shown in Table 3.

**Table 3.** Parameterization of random forest classifier.

Parameters	Configurations
Number of trees (k)	100
Maximum depth of the tree	5
Minimum number of samples in each node	2


One of the great strengths of a RF is its ability to determine the information that is useful in each of the features. RFs are also extremely flexible and highly accurate. The RF classifier has the highest efficiency in terms of the accuracy it can achieve with a large volume of data, for a given computer processing time. In practice, RF runtimes are quite fast, when compared to SVM classifiers. The main weakness of RFs is their complexity. They require a large number of features and training samples, and data over-fitting can easily occur [44,45].

### 2.4.3. Evaluation

The aim of this section is to compare two approaches, using two different classifiers (RF and SVM) with their parameterization.

The classifier test should be valid, and should demonstrate the classifier's performance under conditions as close as possible to the production environment. The results obtained are averaged over three random, uniformly distributed trials, from the training and validation samples. This approach ensures that the results are not influenced by any specific split between the training and validation samples. Optimization of the two classifiers is performed using three-fold cross-validation. The basic idea of this validation is to divide the training dataset into 3 subsets of equal size, with the ratios 2/3 and 1/3 being used for the training and validation sets, respectively. For each two subsets, the classifier is trained, and the remaining subset is used for validation.

As shown in Figure 3, the database is split into separate 3 sets. The classifier is trained and validated 3 times. Finally, the results are collected from each cross-validation run, for statistical analysis, and the predictions are compared. The training and the validation steps are then applied on the whole database. As with any supervised classification, validation is an essential step when evaluating the quality of the classification results, and is performed by comparing the classified data with the reference data (ground-truth measurements). This comparison is often expressed by means of a confusion matrix, which facilitates the understanding of the results, and provides detailed information concerning the effects of incorrect predictions.

**Figure 3.** Three-fold cross-validation.

The confusion matrix is represented by a square array, whose columns correspond to the predicted values, according to the classification, and whose rows represent the reference data. The

correctly classified pixels' numbers in each class are represented in the matrix diagonal, whereas the elements lying outside the diagonal correspond to confusions. Two main indices are then computed from the matrix, to evaluate its classification:

- The overall accuracy, which is the ratio of the well-ranked pixels to the total number of validation pixels. This index varies between 0 (no pixel correctly classified) and 1 (100 % of pixels are well classified)

- The Kappa coefficient (Kc) is a measure of the accuracy, which takes into account positive results that occur at random. The quality of the classification is assessed according to the value of this coefficient, which can vary over the range between -1 (very poor) and 1 (excellent).


To evaluate the influence of the class label, using RF and SVM, the OA and Kc are computed from each confusion matrix, over a set of different simulations.

### 3. Results

#### 3.1. Satellite Data Sensitivity to Soil Texture

##### 3.1.1. Sentinel-2 Sensitivity Analysis

Clay minerals and carbonates have characteristic absorption bands in the SWIR [47], which correspond to bands 11 and 12 of the S-2 satellite. Figure 4 plots the reflectance of the S-2 bands over three classes of soil observed in the study area from ground soil measurements (with soil clay contents lying in one of the following 3 ranges: Class 1 for 15% to 30%; Class 2 for 30% to 45% and Class 3 for 45% to 60%). For each class, we compute the mean value of the measurements recorded over the reference fields.



**Figure 4.** Soil reflectance observed in the Sentinel-2 (S-2) spectral bands, for three different soil textures (distinguished by different ranges of clay content) on the Kairouan Plain site: Class 1 (15–30%), Class 2 (30–45%) and Class 3 (45–60%).

The optical data selected for sensitivity analysis was recorded in the summer (July–August 2017) over bare soils only. The summer period was considered to be the best suited to these observations, as it is well separated from the end of the winter cereal production season, with no vegetation, during the autumn period. For many fields, this period can be extended from July to October. For this reason, only those crops with an NDVI lower than 0.25 were selected. As this takes place more than four weeks after wheat harvesting, there are no crop residues remaining on the surface of the fields, we are rather in a context of low presence of straw, indeed this effect could appear in early July. Moreover, surface spectral data are also generally affected by the confounding effects of soil moisture and soil

roughness. For instance, some colored soils, revealed by optical data, could be explained by high roughness dating from later summer plowing.

The summer period, which is the driest in the year, also has the advantage of minimizing reflectance noise that can be produced by changes in soil moisture, following rainfall events.


The soil reflectances derived for the spectral bands observed by Sentinel-2 are compared, as shown in Figure 4, in order to determine those, which are the most sensitive to soil texture: the B11 and B12 bands can be seen to have the highest sensitivity to variations in clay content. The reduced reflectance at 2190 nm (B12) may be caused by a loss of crystallinity in clayey minerals.

This analysis was repeated on eight different dates, between July and August. Bands B11 and B12 are found to have similar linear regressions, and nearly identical values of  $R^2$ , and the reflectance in these two bands can be seen to decrease when the clay content increases.

Table 4 lists the coefficients of determination computed between clay content and reflectance in these two bands, for each date of observation, showing that the observations with the highest coefficients of determination (close to 0.4) were made on 4 August 2017 (Figure 5), and the lowest P-value which shows a statistically significant correlation. The lowest correlation was observed for the month of July with the lowest coefficient of determination (under 0.35) and almost highest P-value. The observations made on this date were thus selected, for the computation of all soil indices, as described in the following sections.

**Table 4.** Coefficients of determination for the linear regressions computed between clay content and optical reflectance, in bands B11 and B12 of the S-2 images recorded on eight different dates during the summer of 2017; bolded numbers correspond to the best accuracy.

Dates	$R^2$ (B11)	P-Value (B11)	$R^2$ (B12)	P-Value (B12)
05/07/2017	0.29	0.0013	0.30	0.0011
10/07/2017	0.31	0.0009	0.32	0.0003
20/07/2017	0.32	0.0008	0.39	0.00008
25/07/2017	0.30	0.0011	0.32	0.0004
30/07/2017	0.35	0.0003	0.39	0.00008
04/08/2017	<b>0.39</b>	<b>0.00002</b>	<b>0.4</b>	<b>0.00006</b>
19/08/2017	0.38	0.0001	0.38	0.0001
24/08/2017	0.38	0.0001	0.37	0.0001



**Figure 5.** Soil clay content as a function of the SWIR bands of S-2, analyzed on August 4<sup>th</sup>, 2017: (a) Band 11 (B11); (b) Band 12 (B12).

### 3.1.2. Optical Indices and Sensitivity Analysis


For the purposes of soil texture analysis, two soil-related indices were also tested, using the data recorded in certain S-2 bands, in an attempt to distinguish between different textural classes. These indices are described as follows:

#### Simple ratio Clay Index (SRCI)

The SRCI is defined as the reflectance ratio of two SWIR bands, namely B11 (SWIR 1) and B12 (SWIR 2), derived from S-2 images [48,49]. It is expressed as:

$$SRCI = \frac{SWIR\ 1}{SWIR\ 2} \quad (1)$$

The SRCI was computed for the images recorded on 04/08/2017 (the driest day, and the date on which bands B11 and B12 had their highest sensitive to clay content). Although the overall trend is for the SRCI to decrease with increasing clay content, these variables are not strongly correlated, with  $R^2$  equal to just 0.19 (Figure 6).



**Figure 6.** Clay content as a function of the simple ratio clay index (SRCI).

#### Brightness Index (BI)


The BI [50] combines information from the Red and Near-Infrared bands, represented by bands B4 and B9, respectively, in the case of S-2 data. This index provides an indication of changes in the average level of reflectance. The BI is used to assess whether an observed surface is bright or dark, and is often used for the mapping of soil characteristics, such as roughness, texture, salinity, and moisture [51–54].

Dry soils with low clay content tend to be strongly reflective, whereas dark soils have low radiometric values in both bands, due to their high clay content. The BI is expressed as

$$BI = \sqrt{R^2 + NIR^2} \quad (2)$$

Where R and NIR are the red and near infrared bands, respectively.

Although the BI is used to distinguish between bright and dark zones, which in principle correspond to sandy and clayey soils, respectively, Figure 7 shows that in the case of the present study, this index does not provide a clear separation between these classes of soil. The low value of  $R^2$  shown in this figure is partly due to confusion between plowed and clay soils.




**Figure 7.** Brightness index as a function of clay content.

### 3.1.3. Analysis of the Sensitivity of Soil Moisture to Clay and Sand Content

Soil texture is a function of its constituent clay, silt, and sand fractions, and can be strongly affected by water retention and infiltration. Conversely, soil moisture is strongly influenced by the texture of the soil—sandy soils have a porous texture that acts as a filter, allowing water to percolate. Although this soil type is common towards the North-East of the Kairouan Plain, the loamy clay soils dominating the study area retain rain and irrigation water more readily, thanks to their compact texture. This type of soil thus dries more slowly than sandy soil, and can remain wet for several days.

The method applied for this analysis involves the monitoring of dynamic changes in the soil moisture profile (directly related to rainfall events), and relies on the observation of a relationship between the soil's mean level of moisture and its texture (clay and sand contents). For this analysis, 14 soil moisture maps were derived from radar and optical data.


As soil moisture levels are generally higher for clay soils (slow drying) than for sandy soils (fast drying), we analyzed data recorded during the autumn, between September and December, since this corresponds to a period characterized by relatively strong precipitation events on the Kairouan Plain. The period following the month of December is less suitable for this analysis, as it corresponds to the beginning of the agricultural season for most crops, and is generally accompanied by irrigation, which could affect the soil's natural drying regime. The Figure 8a,b represent soil moisture mean values derived from the soil moisture maps retrieved the neural networks algorithm based on the inversion of the backscattering models (WCM and IEM, as function of the clay content from the ground measurements. As shown in the figures, the relationship between soil moisture and clay or sand content is linear in both cases: the mean moisture content clearly increases with increasing clay fraction ( $R^2 = 0.54$ ), and decreases with increasing sand content ( $R^2 = 0.43$ ).



**Figure 8.** Temporal mean of soil moisture over the reference fields, computed for the period between September and the beginning of December as a function of soil texture computed from ground measurements: (a) for clay content; (b) for sand content.

### 3.2. Classification Scheme

Four indicators were used to estimate the soil clay content: S-2 images in two different SWIR bands (B11 and B12), the temporal average of soil moisture, and a combination of SWIR data and soil moisture. From the sensitivity analysis, the reflectance indicators derived from optical band data (B11 and B12) are found to be more sensitive to soil clay content than the optical indices (SRCI and BI) computed from the S-2 images. As shown in Section 3.1.1, B11 and B12 provide the best sensitivity, with an  $R^2$  equal to approximately 0.4. For this reason, only the optical SWIR bands were selected for the classification process. The classification workflow used to determine the clay content distribution over the study site is shown in Figure 9.



**Figure 9.** Classification workflow for clay content mapping.


### 3.3. Validation and Clay Fraction Mapping

A three-fold cross-validation procedure is used to obtain predictions from the different classifiers (SVM and RF) and the different indicators. Table 5 lists the results obtained from the confusion matrices with these simulations. Low accuracies are obtained with optical data in the B11 and B12 bands, with an OA of 0.41 and an Kc of 0.15. On the other hand, the soil moisture indicator produces good results, with an OA as high as 0.65 obtained with the RF algorithm. The results obtained with optical data (bands B11 and B12) are clearly enhanced when they are combined with the soil moisture indicator, and the RF is found to be a more robust classifier than the SVM, for all of the simulations carried out during this study.

**Table 5.** Overall accuracy (OA) and kappa Coefficient (Kc) results derived from the confusion matrix, using three-fold cross-validation with the SVM and RF classifiers, based on optical data (B11 and B12), soil moisture products, and a combination of soil moisture and optical data.


		OA	Kc
<b>B11</b>	SVM	0.41	0.15
	RF	0.42	0.15
<b>B12</b>	SVM	0.41	0.1
	RF	0.42	0.1
<b>Mv</b>	SVM	<b>0.63</b>	<b>0.44</b>
	RF	<b>0.65</b>	<b>0.46</b>
<b>Mv+B11</b>	SVM	0.52	0.27
	RF	0.54	0.3
<b>Mv+B12</b>	SVM	0.57	0.34
	RF	0.58	0.37

The clay maps generated by both algorithms are shown in Figure 10. All non-agricultural areas (urban areas, reliefs, water bodies) have been masked in these maps, using a GIS (Geographic Information Systems) shape file. Three classes of clay content are presented according to the following partition: Class 1: clay content between 15% and 30%, Class 2: clay content between 30% and 45%, and Class 3: clay content between 45% and 60%. These two maps are very similar in appearance, showing the same distribution of soil texture across the region. The third class, representing the highest value of clay content, can be seen to dominate the entire area, and to be strongly present at the center of this site, where irrigated and winter/summer vegetables are cultivated. Sandy soils are present mainly in the south-western portion of the site, where olive orchards are widely cultivated.



(a)

Figure 10. Cont.



**Figure 10.** Clay maps using soil moisture products, using: (a) the SVM classifier; (b) the RF classifier.

Tables 6 and 7 present the confusion matrices for each clay map. These matrices compare the classes predicted by the models with the reference classes. As shown in Table 5, the random forest algorithm performs better than the SVM, with an OA equal to 0.63 for the SVM classification, and 0.65 for the RF classification.

**Table 6.** Confusion matrix for the SVM classification, using soil moisture products for clay content mapping.

		Predicted Label Percentages		
		Classes of clay content	1 (15–30%)	2 (30–45%)
Reference label percentages	1 (15–30%)	70.46%	6.67%	0
	2 (30–45%)	28.27%	52.82%	35.92%
	3 (45–60%)	1.27%	40.51%	64.08%
OA= 0.63				

**Table 7.** Confusion matrix for the RF classification, using soil moisture products for clay content mapping.

		Predicted Label Percentages		
		Classes of clay content	1 (15–30%)	2 (30–45%)
Reference label percentages	1 (15–30%)	86.34%	14.1 %	0
	2 (30–45%)	13.66%	53.98%	35.5%
	3 (45–60%)	0	31.83%	64.5%
OA= 0.65				

#### 4. Discussion

Information on the variability of soil properties leads to an increased ability for agronomic management implications. In particular, soil texture is a key agro-ecosystem variable, for a full knowledge of fertility and water-holding capacity of the soils. For instance, the knowledge of soil texture variability is central for the implementation of farming management strategies that allow for a more efficient use of resources, such as water and fertilizers; therefore, reducing costs and environmental impact.

Due to a difficulty of estimation soil fraction, the results of this study illustrate the potential advantages of using combined optical and radar data for soil texture monitoring. These results are within expected ranges of variability compared to those obtained using optical data.

In the context of our study site, the use of optical data only (corresponding to the texture analysis technique generally reported in the literature) leads to a lower accuracy in the estimation of clay content. This outcome could be related initially to weather conditions reducing the performance of optical data. Local tillage conditions, with frequent residues occurring after the cereal harvest, precisely during early summer season (June–July), is also affecting reflectance. For instance, Vaudour et al. [27] have found similarly modest correlations between observed and predicted clay content, using PLSR model, with an  $R^2$  between 0.39 and 0.5. In Castaldi et al. [55], clay spectral indices entail a decrease of accuracy according to soil moisture classes (a coefficient of correlation less than 0.65). The investigation on the wavelengths most correlated with clay content at different moisture levels, showed that the most suitable spectral features are strongly affected by soil moisture. This showed that the knowledge of soil moisture is essential for a better estimation of clay content. In the same investigation, others studies showed that multispectral data provide modest performances of clay estimations, controlled by others soil's parameters (soil roughness and crop residues) and due to atmospheric effects [21,56,57].

Radar data thus appears to contribute an improvement in overall accuracy, although scientific studies are very limited in this area. In practice, soil moisture conditions can be derived from radar data independently of local weather conditions, and even in the presence of a vegetation cover. Therefore, soil moisture estimation could hamper the estimation of soil component such as clay content from remote sensing data, reducing the strength of the relevant spectral absorption features. This capability broadens the potential for characterizing soil texture in areas where optical satellite sensors are unable to observe the ground, due to the presence of a vegetation cover. As in the case of optical observations, the proposed radar technique would clearly be disturbed by irrigation, which affects the relationship between the average seasonal values of soil moisture and soil clay content.

The RF algorithm is found to have the most accurate results, using different indicators. Nevertheless, similar results are obtained for both the RF and SVM techniques. In the present study, a relatively small number of features are used as inputs for the classification algorithm. It would be interesting to use a greater number of samples for the validation process. The computing time needed for the learning process is also an important criterion, when comparing different classification algorithms. The parametric configuration of the SVM often requires an optimization phase, which may take longer than in the case of the RF. Conversely, the RF is less sensitive to its parametric configuration, thus reducing the required training time.

Furthermore, recent advance techniques have been proposed to increase the predictive power of models. Tziolas et al. [58] have proposed an accurate estimation of soil texture components (clay, silt, and sand). They showed that with a combination of geographical proximity and spectral similarity in regression analysis will increase the predictive power of a novel memory based on learning algorithm. They predicted clay content with an  $R^2$  of 0.84 and an RMSE of 6.32%.

Moreover, Demattê et al. [59] have designed a Geospatial Soil Sensing System (GEOS3) based on Landsat TM5 products to retrieve soil spectral reflectance from several years with creating a Temporal Synthetic Spectral Reflectance (TESS), which is a synthetic spectral fingerprint of the soil surface. The functionality of GEOS3 is evident, as it could be used to support soil surveys, digital soil mapping (e.g., mapping of clay contents), precision agriculture, soil sampling allocation, soil management zones, soil conservation, and for improvements to existing soil maps. They also proposed the use of Normalized Burn Ratio 2 (NBR2), as an auxiliary index to decrease the similarities found on the multispectral patterns between sandy soils and straw cover.

## 5. Conclusions

The aim of this study is to develop an approach for topsoil clay content estimations, based on the interpretation of multi-sensor satellite data. Our results show that remote sensing is an efficient tool, which can be used to generate soil texture maps at the field scale. This study was carried out over the

Kairouan Plain, in central Tunisia. Satellite acquisitions were accompanied by field measurements, from which each soil sample was assigned to a predefined class, according to its measured clay content. Three main classes are defined, with clay content values ranging between 15% and 60%.

The classical RF and SVM classifiers are used with different indicators, derived from the Sentinel constellations (S-1 and S-2). Simulations were carried out with several datasets, thus allowing three-fold cross-validation to be applied. Several studies have shown that optical data have considerable potential for the retrieval of soil texture. We thus tested several indices and SWIR bands for their ability to estimate clay content. As the results were relatively poor, with an OA below 0.4, a second simulation was performed by testing various soil moisture products, which have a significant correlation with clay content, as input data for the classification process. This indicator improves the classification performance. The original aspect of this study lies in the fact that soil moisture products derived from the WCM could be used to estimate clay content, even in areas covered by vegetation, since this approach has been validated on several sites under different climatic conditions.

The behaviors of the SVM and RF have been analyzed, showing that both algorithms can be used as robust classifiers for clay content estimations, even when relatively small volumes of training data are used. The RF is more accurate than the SVM. A small drawback of this algorithm is that it is difficult to parameterize.

Future studies should focus on collecting a larger number (at least 100) of soil samples, to improve the results, and allow a much finer classification to be achieved. These techniques could also be tested over other areas, characterized by different climatic conditions, and could also be used to produce texture maps of sand content. It is important to mention the critical impact of irrigation on soil color: meaningful optical observations can be made only at certain times of the year, to avoid the influence of irrigation on soil moisture. Another limitation of the use of optical data arises from the prevailing atmospheric conditions, which can restrict the number of useful images taken over a given area of interest. The fact that the quality and performance of optical data can be perturbed by several different factors highlights the importance of SAR product use.

**Author Contributions:** S.B. and M.Z. designed and developed the experimental procedures; S.B., N.B.A. and A.G. performed the experiments; S.B., M.Z. B.M. analyzed the data; Z.L.C., C.P. and N.B. contributed to the materials and analysis tools; M.Z. and S.B. wrote the paper.

**Funding:** This study was funded by the CHAAMS (ERANET-MED 03-62 CHAAMS) and TOSCA/CNES projects

**Acknowledgments:** We extend our warm thanks to the technical teams at the IRD and INAT (Institut National Agronomique de Tunisie), for their invaluable collaboration and support during the ground-truth measurement campaigns and data processing activities.

**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, P.T.; 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. 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* 2010, 3, 155–165. [CrossRef]
4. Korres, W.; Reichenau, T.G.; Fiener, P.; Koyama, C.N.; Bogena, H.R.; Cornelissen, T.; Baatz, R.; Herbst, M.; Diekkrüger, B.; Vereecken, H.; et al. Spatio-temporal soil moisture patterns - A meta-analysis using plot to catchment scale data. *J. Hydrol.* 2015, 520, 326–341. [CrossRef]
5. Brocca, L.; Melone, F.; Moramarco, T.; Morbidelli, R. Spatial-temporal variability of soil moisture and its estimation across scales. *Water Resour. Res.* 2010, 46, 1–14. [CrossRef]

6. Alexandridis, T.K.; Cherif, I.; Bilas, G.; Almeida, W.G.; Hartanto, I.M.; van Andel, S.J.; Araujo, A. Spatial and temporal distribution of soil moisture at the catchment scale using remotely-sensed energy fluxes. *Water* 2016, 8, 32. [CrossRef]
7. Zribi, M.; Pardé, M.; Botin, J.; Fanise, P.; Hauser, D.; Dechambre, M.; Kerr, Y.; Leduc-Leballeur, M.; Reverdin, G.; Skou, N.; et al. CAROLS: A New Airborne L-Band Radiometer for Ocean Surface and Land Observations. *Sensors* 2011, 11, 719–742. [CrossRef]
8. Baghdadi, 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.* 2015, 99, 1–15.
9. Knadel, M.; Arthur, E.; Weber, P.; Moldrup, P.; Greve, M.H.; Chrysodonta, Z.P.; de Jonge, L.W. Soil specific surface area determination by Visible Near-Infrared spectroscopy. *Soil Sci. Soc. Am. J.* 2018, 82, 1046–1056. [CrossRef]
10. Curcio, D.; Ciraolo, G.; D’Asaro, F.; Minacapilli, M. Prediction of soil texture distributions using VNIR-SWIR reflectance spectroscopy. *Procedia Environ. Sci.* 2013, 19, 494–503. [CrossRef]
11. Tümsavaş, Z.; Tekin, Y.; Ulusoy, Y.; Moazen, A.M. Prediction and mapping of soil clay and sand contents using visible and near-infrared spectroscopy. *Biosyst. Eng.* 2018, 177, 90–100. [CrossRef]
12. Bousbih, S.; Zribi, M.; El Hajj, M.; Baghdadi, N.; Lili-Chabaane, Z.; Gao, Q.; Fanise, P.; Bousbih, S.; Zribi, M.; El Hajj, M.; et al. 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]
13. Gao, Q.; Zribi, M.; Escorihuela, M.J.; Baghdadi, N.; Quintana-Segui, P. Irrigation mapping using statistics of Sentinel-1 time series. *Remote Sens.* 2018, 10, 1495. [CrossRef]
14. 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]
15. 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]
16. Escadafal, R.; Girard, M.; Courault, D. Munsell soft color and soil reflectance in the Visible spectral bands of Landsat MSS and TM data. *Remote Sens. Environ.* 1989, 277, 37–46. [CrossRef]
17. Sinha, A.K. Spectral reflectance characteristics of soils and its correlation. *J. Indian Soc. Remote Sens.* 1986, 14, 1–9. [CrossRef]
18. Mattikalli, N.M. Soil color modeling for the Visible and Near-Infrared bands of Landsat sensors using laboratory spectral measurements. *Remote Sens. Environ.* 1997, 59, 14–28. [CrossRef]
19. Casa, R.; Castaldi, F.; Pascucci, S.; Palombo, A.; Pignatti, S. A comparison of sensor resolution and calibration strategies for soil texture estimation from hyperspectral remote sensing. *Geoderma* 2013, 197–198, 17–26. [CrossRef]
20. Liu, F.; Geng, X.; Zhu, A.X.; Fraser, W.; Waddell, A. Soil texture mapping over low relief areas using land surface feedback dynamic patterns extracted from MODIS. *Geoderma* 2011, 171–172, 44–52. [CrossRef]
21. Gomez, C.; Adeline, K.; Bacha, S.; Driessen, B.; Gorretta, N.; Lagacherie, P.; Roger, J.M.; Briottet, X. Sensitivity of clay content prediction to spectral configuration of VNIR/SWIR imaging data, from multispectral to hyperspectral scenarios. *Remote Sens. Environ.* 2018, 204, 18–30. [CrossRef]
22. Gomez, C.; Lagacherie, P.; Coulouma, G. Continuum removal versus PLSR method for clay and calcium carbonate content estimation from laboratory and airborne hyperspectral measurements. *Geoderma* 2008, 148, 141–148. [CrossRef]
23. Walker, E.; Monestiez, P.; Gomez, C.; Lagacherie, P. Combining measured sites, soilscape map and soil sensing for mapping soil properties of a region. *Geoderma* 2017, 300, 64–73. [CrossRef]
24. Viscarra Rossel, R.A.; Chappell, A.; De Caritat, P.; McKenzie, N.J. On the soil information content of visible-near infrared reflectance spectra. *Eur. J. Soil Sci.* 2011, 62, 442–453. [CrossRef]
25. Viscarra Rossel, R.A.; Walvoort, D.J.J.; McBratney, A.B.; Janik, L.J.; Skjemstad, J.O. Visible, near infrared, mid infrared or combined di\_use reflectance spectroscopy for simultaneous assessment of various soil properties. *Geoderma* 2006, 131, 59–75. [CrossRef]
26. Shabou, M.; Mougenot, B.; Lili-Chabaane, Z.; Walter, C.; Boulet, G.; Aissa, N.; Zribi, M. Soil Clay Content Mapping Using a Time Series of Landsat TM Data in Semi-Arid Lands. *Remote Sens.* 2015, 7, 6059–6078. [CrossRef]

27. Vaudour, E.; Gomez, C.; Fouad, Y.; Lagacherie, P. Sentinel-2 image capacities to predict common topsoil properties of temperate and Mediterranean agroecosystems. *Remote Sens. Environ.* 2019, 223, 21 [CrossRef]
28. Zribi, M.; Kotti, F.; Baghdadi, N.; Issa, N.B.; Amri, R. Soil Texture Estimation Over a Semiarid Area Using TerraSAR-X Radar Data. *IEEE Geosci. Remote Sens. Lett.* 2012, 9, 353–357. [CrossRef]
29. Gorrab, A.; Zribi, M.; Baghdadi, N.; Mougnot, B.; Fanise, P.; Lili-Chabaane, Z. Retrieval of both soil moisture and texture using TerraSAR-X images. *Remote Sens.* 2015, 7, 10098–10116. [CrossRef]
30. 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]
31. Batjes, N.H. Soil Property Estimates for the Upper Tana, Kenya, Derived from SOTER and WISE; ISRIC-World Soil Information: Wageningen, The Netherlands, 2010; p. 41.
32. Bousbih, S.; Zribi, M.; Lili-Chabaane, Z.; Baghdadi, N.; El Hajj, M.; Gao, Q.; Mougnot, B. Potential of Sentinel-1 radar data for the assessment of soil and cereal cover parameters. *Sensors* 2017, 17, 2617. [CrossRef] [PubMed]
33. Hagolle, O.; Huc, M.; David, V.P.; Dedieu, G. A multi-temporal method for cloud detection, applied to FORMOSAT-2, VENUS, LANDSAT and SENTINEL-2 images. *Remote Sens. Environ.* 2010, 114, 1747–1755. [CrossRef]
34. Attema, E.P.W.; Ulaby, F.T. Vegetation modeled as a water cloud. *Radio Sci.* 1978, 13, 357–364. [CrossRef]
35. Baghdadi, N.; Abou Chaaya, J.; Zribi, M. Semi-empirical 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]
36. 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]
37. Avery, B.W. Soil classification in the soil survey of England and Wales. *J. Soil Sci.* 1973, 24, 324–338. [CrossRef]
38. Barnes, E.M.; Baker, M.G. Multispectral data for mapping soil texture: Possibilities and Limitations. *Am. Soc. Agric. Eng.* 2000, 16, 731–741. [CrossRef]
39. Kovačević, M.; Bajat, B.; Boško, G. Soil type classification and estimation of soil properties using support vector machines. *Geoderma* 2010, 154, 340–347. [CrossRef]
40. Wang, Z.; Xue, X. Multi-Class Support Vector Machine. In *Support Vector Machines Applications*; Ma, Y., Guo, G., Eds.; Springer International Publishing: Basel, Switzerland, 2014; pp. 23–49. ISBN 9783319023007.
41. Milgram, J.; Cheriet, M.; Sabourin, R. “One Against One” or “One Against All”: Which One is Better for Handwriting Recognition with SVMs? Tenth Int. Workshop Front. Handwrit. Recognit. 2006. Available online: <https://hal.inria.fr/inria-00103955/> (accessed on 26 June 2019).
42. Cortes, C.; Vapnik, V. Support-Vector Networks. *Mach. Learn.* 1995, 20, 275–297. [CrossRef]
43. Rifkin, R.; Klautau, A. In defense of One-Vs-All classification. *J. Mach. Learn. Res.* 2004, 5, 101–141.
44. Pal, M. Random forest classifier for remote sensing classification. *Int. J. Remote Sens.* 2005, 26, 217–222. [CrossRef]
45. Pelletier, C.; Valero, S.; Inglada, J.; Champion, N.; Dedieu, G. Assessing the robustness of Random Forests to map land cover with high resolution satellite image time series over large areas. *Remote Sens. Environ.* 2016, 187, 156–168. [CrossRef]
46. Breiman, L.E.O. Random Forests. *Mach. Learn.* 2001, 45, 5–32. [CrossRef]
47. Chabrillat, S.; Goetz, A.F.H.; Krosley, L.; Olsen, H.W. Use of hyperspectral images in the identification and mapping of expansive clay soils and the role of spatial resolution. *Remote Sens. Environ.* 2002, 82, 431–445. [CrossRef]
48. Sabins, F.F. Remote sensing for mineral exploration. *Ore Geol. Rev.* 1999, 14, 157–183. [CrossRef]
49. Danoedoro, P.; Zukhrufiyati, A. Integrating spectral indices and geostatistics based on Landsat-8 imagery for surface clay content mapping in Gunung Kidul area, Yogyakarta, Indonesia. In *Proceedings of the 36<sup>th</sup> Asian Conference on Remote Sensing, Asia Quezon, Metro Manila, Philippines, 12 May 2015.*

50. Khan, N.M.; Rastokuev, V.V.; Sato, Y.; Shiozawa, S. Assessment of hydrosaline land degradation by using a simple approach of remote sensing indicators. *Agric. Water Manag.* 2005, 77, 96–109. [CrossRef]
51. Asfaw, E.; Suryabagavan, K.V.; Argaw, M. Soil salinity modeling and mapping using remote sensing and GIS: The case of Wonji sugar cane irrigation farm, Ethiopia. *J. Saudi Soc. Agric. Sci.* 2018, 17, 250–258. [CrossRef]
52. Mandal, U.K. Spectral color indices based geospatial modeling of soil organic matter in Chitwan District, Nepal. In Proceedings of the International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2016 XXIII ISPRS Congress, Prague, Czech Republic, 12–19 July 2016; Volume XLI, pp. 43–48.
53. Forkuor, G.; Hounkpatin, O.K.L.; Welp, G.; Thiel, M. High resolution mapping of soil properties using remote sensing variables in South-Western Burkina Faso: A comparison of machine learning and multiple linear regression models. *PLoS ONE* 2017, 12, e0170478. [CrossRef]
54. Caloz, R.; Abednego, B.; Collet, C. The Normalisation of a Soil Brightness Index for the Study of Changes in Soil Conditions. In Proceedings of the the 4th International Colloquium on Spectral Signatures of Objects in Remote Sensing, Aussois, France, 18–22 January 1988.
55. Castaldi, F.; Palombo, A.; Pascucci, S.; Pignatti, S.; Santini, F.; Casa, R. Reducing the influence of soil moisture on the estimation of clay from hyperspectral data: A case study using simulated PRISMA data. *Remote Sens.* 2015, 7, 15561–15582. [CrossRef]
56. Liao, K.; Xu, S.; Wu, J.; Zhu, Q. Spatial estimation of surface soil texture using remote sensing data. *Soil Sci. Plant Nutr.* 2013, 59, 488–500. [CrossRef]
57. Castaldi, F.; Palombo, A.; Santini, F.; Pascucci, S.; Pignatti, S.; Casa, R. Evaluation of the potential of the current and forthcoming multispectral and hyperspectral imagers to estimate soil texture and organic carbon. *Remote Sens. Environ.* 2016, 179, 54–65. [CrossRef]
58. Tziolas, N.; Tsakiridis, N.; Ben-Dor, E.; Theocharis, J.; Zalidis, G. A memory-based learning approach utilizing combined spectral sources and geographical proximity for improved VIS-NIR-SWIR soil properties estimation. *Geoderma* 2019, 340, 11–24. [CrossRef]
59. Demattê, J.A.M.; Fongaro, C.T.; Rizzo, R.; Safanelli, J.L. Geospatial Soil Sensing System (GEOS3): A powerful data mining procedure to retrieve soil spectral reflectance from satellite images. *Remote Sens. Environ.* 2018, 212, 161–175. [CrossRef]



© 2018 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).

## 5.4. Synthèse et conclusion partielle

L'approche proposée pour cette étude repose sur une estimation du contenu en argile à la surface du sol à partir de données satellitaires multi-capteurs. Concernant la texture de sol, peu de travaux proposent une spatialisation de l'un de ces différents composants. Ces études sont généralement basées sur des mesures ponctuelles. Entre autre, les observations sur le terrain ou les analyses en laboratoires sont très coûteuses et sont peu représentatives. En effet, la texture du sol présente une forte hétérogénéité même à l'échelle d'une parcelle.

La présente étude est réalisée sur la plaine de Kairouan, où campagnes expérimentales et analyses en laboratoire ont permis de rassembler une base données couvrant les différents types de sol dans cette région. La pédologie de cette région est caractérisée par une forte variabilité de la texture du sol. En effet, la texture varie entre des sols argileux, à limono-sableux. Ces mesures ont été accompagnées par des données satellitaires à partir de bandes et d'indices spectraux et de produits radars. Afin d'évaluer le comportement des capteurs (optiques et radars) par rapport à la texture du sol, une analyse de sensibilité est réalisée sur les parcelles de références. La teneur en argile se voit plus en corrélation à l'humidité du sol (avec des  $R^2$  de l'ordre de 0.5) restituée à partir de la synergie de données optiques et radars, comparée aux données issues de l'optique (avec des  $R^2$  inférieur à 0.4 pour les bandes spectrales).

L'approche adoptée pour la cartographie de la teneur en argile, s'appuie alors sur des algorithmes de classification (Random Forest et Support Vector Machine). Ces algorithmes ont été évalués sur les deux bandes B11 et B12 de Sentinel-2, de l'humidité du sol, et de la combinaison des deux indicateurs.

Afin d'évaluer les différentes approches, la validation croisée sur 3 partitions des données a été utilisée. Les résultats obtenus utilisant les bandes SWIR sont les moins satisfaisants comparés à ceux obtenus pour l'humidité du sol, ce qui permet d'approuver les résultats de l'analyse de sensibilité. Avec des précisions globales de 63% et 65% pour la classification par SVM et RF respectivement, l'humidité du sol semble être un bon indicateur pour estimer la texture du sol.

Les résultats ont aussi montré que les RF et SVM sont des classificateurs robustes pour l'estimation de la texture malgré le faible nombre de données d'apprentissage. Cependant, le RF affiche une plus grande précision et une rapidité de simulation comparé au SVM.

# Conclusion générale et perspectives

## Synthèse et conclusion

L'agriculture en Tunisie revêt une importance cruciale de par sa contribution à la sécurité alimentaire, son importance pour le secteur économique et à la garantie d'une activité et d'une source de revenu à la population rurale. La céréaliculture et l'oléiculture occupent plus de 3 millions d'hectares. En raison de sa position géographique, la Tunisie est soumise à l'influence de la variabilité accentuée du climat et à la rareté des ressources en eau. La pénurie d'eau est alors l'un des principaux facteurs limitant le développement agricole particulièrement dans les zones semi-arides. La zone d'étude, la plaine de Kairouan, fait partie des zones typiques où la crise de l'eau est très aiguë, ce qui impose de converger vers des stratégies de gestions rapides et efficaces. L'objectif à travers ce travail tend à améliorer les outils d'aide à la décision pour les différents gestionnaires, à l'échelle de la parcelle et à grande échelle à partir de données satellitaires. On ouvrira à la fin les conclusions et les perspectives de ce travail.

Cette thèse s'est essentiellement intéressée à l'évaluation de l'apport des données radars (Sentinel-1) et optiques (Sentinel-2) pour le suivi des états de surface (état hydrique de surface et texture du sol) avec un temps de revisite très court adapté pour un suivi des dynamiques. Les acquisitions satellitaires durant les années 2015-2016 et 2016-2017 ont permis de constituer des séries temporelles dans le domaine micro-ondes et optiques à haute résolution spatiale pour la mise en place d'approches multi-capteurs.

Le site d'étude a été caractérisé à l'échelle d'un grand nombre de parcelles (plus d'une vingtaine de parcelles entre sols nus et céréales), avec des mesures expérimentales concernant les propriétés du sol et de la végétation (les céréales), présentées dans le Chapitre 2. Une forte dynamique des conditions de surface est observée pour les sols nus et pour les parcelles de céréale. Une grande partie de la thèse repose sur les mesures et observations sur le terrain que j'ai coordonné durant deux saisons agricoles, accompagné d'acquisitions satellitaires. A travers des études de sensibilité, le comportement du signal radar a été étudié dans le but d'évaluer le potentiel de données Sentinel-1 à restituer les états des surfaces, et à valider les modèles de rétrodiffusion, décrits dans le Chapitre 3. Les résultats des analyses révèlent que le signal radar est très sensible aux paramètres du sol (humidité et rugosité du sol). Pour les paramètres de la végétation (LAI, hauteur et contenu en eau de la végétation), le signal radar présente un comportement qui reflète l'atténuation du signal sol par le couvert végétal, ainsi que la diffusion de volume provenant du couvert végétal. Par ailleurs, la polarisation VV semble être la configuration optimale pour la caractérisation des états de surface sur les parcelles de céréales et de sols nus avec de meilleurs résultats comparés à la polarisation VH.

Les résultats de la modélisation de la rétrodiffusion sont aussi présentés dans le même chapitre afin de décrire correctement le comportement du signal radar avec un modèle empirique pour les sols nus et le modèle « Water Cloud Model » pour la végétation. Les résultats obtenus pour les simulations présentent des fortes similitudes avec ce qui existe dans la littérature. Ces modèles ont notamment été validés selon les différentes conditions météorologiques qu'a subies la région (une première année 2015-2016 sèche et une deuxième année 2016-2017 relativement humide). L'objectif à travers cette modélisation était de pouvoir inverser le signal radar afin de restituer l'humidité du sol. Le Chapitre 4 est basé essentiellement sur la restitution de l'humidité du sol à travers une synergie optique/radar et la spatialisation (cartographie) de ce paramètre sur toute la plaine de Kairouan. Le signal radar en polarisation VV couplé au NDVI dérivé des images Sentinel-

2 a permis d'estimer l'humidité avec des RMSE de l'ordre de 6 vol. %. Cette méthode opérationnelle pour l'estimation de l'humidité a été validée par des mesures in situ par sonde Thetaprobe sur les parcelles de référence dans un premier temps, puis comparée à des produits issus de l'inversion du WCM couplé au modèle IEM mais utilisant un algorithme de réseaux de neurones.

Au cours de cette thèse, on a également exploré d'autres applications de cette synergie entre le radar et l'optique. A travers les produits des deux capteurs, j'ai proposé une cartographie des zones agricoles conduites en pluvial et de celles conduite en irrigué. L'originalité de cette partie réside dans l'intégration et la valorisation des produits humidité du sol issus des mesures satellites dans des algorithmes pour générer d'autres utilisations. La première approche (Chapitre 4) s'est basée sur des algorithmes de classification (SVM et Arbre de Décision) pour séparer entre les parcelles irriguées et non-irriguées. En effet, trois cas ont été testés afin de détecter l'irrigation à partir de trois indicateurs : une moyenne du NDVI sur la période du maximum de développement de la culture (le mois de Mars), les moyennes et les variances de l'humidité du sol et enfin la combinaison des trois indicateurs. Les meilleurs résultats ont été observés en utilisant uniquement les indices d'humidité du sol basés sur des valeurs moyennes et des variances temporelles.

La deuxième partie est également développée à partir des états de surface estimés par la synergie Sentinel-1 et Sentinel-2. Il s'agit de la cartographie de la texture du sol, précisément de la teneur en argile. Pareillement à la modélisation de la rétrodiffusion, une étude de sensibilité est menée afin d'établir une relation entre les données optiques (les bandes spectrales) et radars (l'humidité du sol) d'une part et les textures des parcelles tests d'autres parts. Les bandes spectrales optiques les plus sensibles à la texture du sol sont les bandes SWIR (Short-Wave Infrared ; B11 et B12). Ces deux bandes n'ont été testées que sur des sols nus et sur la période estivale afin de ne pas intégrer des bruits provenant de la végétation ou des variations de l'humidité du sol. La sensibilité des produits de l'humidité du sol a été testée sur la période entre Septembre et Décembre, une période caractérisée par une forte dynamique temporelle de l'état hydrique en raison des précipitations d'automne et par une faible présence de la végétation. Une forte corrélation est observée entre la moyenne temporelle de l'humidité du sol et les composants argile et sable. Deux types d'algorithmes ont été utilisés pour produire des cartes de teneur en argile, le premier se base sur une classification par SVM et le second par RF. Faisant intervenir à la fois une information optique (réflectances de deux bandes spectrales) et une information radar (moyenne de l'humidité du sol), les différentes approches testées montrent que les meilleurs résultats ont été obtenus par l'algorithme RF et en considérant uniquement les produits humidité du sol. Cette partie de la thèse a démontré le potentiel d'utiliser les estimations de l'humidité du sol dans la cartographie du contenu en argile. Cette estimation ouvre une application sans contrainte météorologique et même dans un contexte de surfaces agricoles avec une couverture végétale.

## **Perspectives**

Nous avons mis en évidence lors de ce présent travail que la caractérisation des états de surface était l'une des bases fondamentales pour une bonne gestion des ressources en eau et en sol. Parallèlement aux travaux de modélisation et de validation, les activités entreprises sur le terrain ont enrichi cette thèse. Dans cette dernière partie, nous

présentons quelques perspectives de recherche envisagées, encourageant de nouveaux travaux en lien avec les méthodologies et les résultats de cette thèse.

Les données utilisées se résument aux données radars issus de Sentinel-1 en polarisation VV vu leur sensibilité au couvert végétal. Il est toutefois possible d'inclure de nouvelles analyses pour la polarisation VH. Plus d'acquisitions radar seront utilisées dans des travaux futurs, avec des modèles de rétrodiffusion et des paramètres plus adaptés.

Dans une autre perspective d'élargissement de la base de données, il serait également intéressant de travailler sur d'autres types de cultures (maraichages, arboricultures, oliviers, etc.), ce qui permettra d'étudier le comportement du signal sur plusieurs types de couverts avec différentes caractéristiques. Cependant, la prise en compte de nouvelles cultures conduit à des nouvelles problématiques liées à la fraction ou la densité de couverture par exemple l'oléiculture. En outre, étant donné que les effets de la végétation sur le signal radar proviennent à la fois de la quantité de biomasse et de la structure de la végétation, il faut rechercher un meilleur indice de végétation plus approprié à la place du NDVI, qui est uniquement sensible à la quantité de végétation photosynthétiquement active.

Dans la présente étude, les cartes d'irrigation ont été établies pour fournir des informations qualitatives pour distinguer entre les parcelles irriguées et non irriguées. Il serait judicieux de produire notamment les informations quantitatives liées à l'estimation des doses d'irrigation et aux apports d'eau nécessaires à la culture. En effet, l'assimilation de données radar a montré son intérêt dans le contexte de modélisations hydrologiques ou agronomiques. Particulièrement, l'assimilation des produits d'humidité du sol dans un modèle agro-météorologique tel que SAFY ou un modèle SVAT tel que ISBA pour le suivi de l'évapotranspiration à grande échelle (Amri et al., 2013). De plus, pour produire des cartes multi-annuelles, il est indispensable d'utiliser plusieurs séries temporelles qui nécessitent un algorithme adapté comme les Random Forest ou les réseaux de neurones. D'autre part, à l'heure actuelle, peu de travaux se sont basés sur l'estimation de l'humidité du sol dans la zone racinaire par télédétection radar. En effet l'humidité dans la zone racinaire est l'un des paramètres clés pour le pilotage de l'irrigation. Des productions de cartes d'humidité dans la zone racinaire peuvent être envisagées par exemple à l'aide d'une synergie Sentinel-1 et SMOS. Avec un si haute répétitivité spatiale (5 jours pour S-1 et 3 jours pour SMOS), le suivi de l'irrigation avec uniquement des données micro-ondes sera plus effectif, notamment pour les effets atmosphériques. Le seul point faible reposerait sur la résolution spatiale vu que SMOS offre des produits à résolution très basse et Sentinel des une haute résolution spatiale.

En outre, les journées non-pluvieuses n'ont pas été prises en compte lors de la cartographie de l'irrigation. Pour lever l'ambiguïté entre l'effet de la pluviométrie et l'irrigation, des analyses en composantes principales sur les indicateurs statistiques du signal radar peuvent être envisagées (Bazzi et al., 2019). Dans les travaux futurs, il est intéressant de produire plusieurs cartes d'irrigation selon des dates plus précises.

Concernant le deuxième défi abordé dans ces travaux, la production de la carte de texture du sol, précisément de teneur en argile a permis de mettre en évidence le potentiel des produits d'humidité du sol. Par ailleurs, il semble également pertinent d'étudier l'effet de l'humidité du sol sur les techniques culturales (labour du sol, présence de résidus, etc.) en prenant en compte la rugosité du sol. Cela permettra en conséquence de suivre les différents changements d'état du sol en fonction du temps à partir de séries temporelles satellitaires.

# Acronymes

BI: Brightness Index  
CESBIO: Centre des Etudes Spatiales de la BIOSphère  
CNES: Centre National des Etudes Spatiales  
ESA: European Space Agency  
FAO: Food and Agriculture Organization  
Fc: Fraction de couvertures  
Hrms: root mean-squared height  
GDA: Groupements de Développement Agricole  
GOM: Geometrical Optics Model  
IA: Indice d'Aridité  
IEM: Integral Equation Model  
INM : Institut National Météorologique  
ISBA : Interaction Sol-Biosphère-Atmosphère  
LAI: Leaf Area Index  
LDCM: Landsat Data continuity Mission  
LEDAPS: Landsat Ecosystem Disturbance Adaptive Processing System  
MAJA: MACCS-ATCOR Joint Algorithm  
MIMICS: MICHigan MICrowave Canopy Scattering  
NASA: National Aeronautics and Space Administration  
NDVI: Normalized Difference Vegetation Index  
PIR: Proche-Infrarouge  
PNUE: Programme des Nations Unies pour l'Environnement  
POM: Physical Optics Model  
RADAR: RADio Detection And Ranging  
RF: Random Forest  
RMSE: Root Mean Square Error  
ROI : Region Of Interest  
RSO: Radar à Synthèse d'Ouverture  
S-1: Sentinel-1  
S-2: Sentinel-2  
SiSPAT: Simple Soil Plant Atmosphere Transfer

SMAP: Soil Moisture Active Passive  
SMOS: Soil Moisture and Ocean Salinity  
SPM: Small Perturbation Model  
SRCI: Simple Ratio Clay Index  
SURFEX: SURface EXternalisée  
SVAT: Soil Vegetation Atmosphere Transfer  
SVM: Support Vector Machine  
SWDI: Soil Water Deficit Index  
SWI: Soil Water Index  
SWIR: Short-Wave Infrared  
TDR: Time Domain Reflectometry  
UNCCD: United Nations Convention to Combat Desertification  
USGC: United States Geological Survey  
WCM: Water Cloud Model

# Références

## Référence électroniques

USGS (2016). How much water is there on, in, and above the Earth?, <https://water.usgs.gov/edu/earthhowmuch.html>, [Online ; accessed 10 September 2018]

La Banque Mondiale (2018). Eau, <https://www.banquemondiale.org/fr/topic/water/overview>, [Online ; accessed 11 September 2018]

UNEP-WCMC. Spatial analysis approach to the global delineation of dry land areas of relevance to the CBD Programme of Work on Dry and Sub humid Lands (2007). Dataset based on spatial analysis between WWF terrestrial ecoregions (WWF-US, 2004) and aridity zones (CRU/UEA; UNEPGRID, 1991), <https://www.unep-wcmc.org/resources-and-data/a-spatial-analysis-approach-to-the-global-delineation-of-dryland-areas-of-relevance-to-the-cbd-programme-of-work-on-dry-and-subhumid-lands>, [Online ; accessed 13 September 2018]

FAO (2015). Foresterie dans les terres arides, <http://www.fao.org/dryland-forestry/background/what-are-drylands/fr/>, [Online ; accessed 15 September 2018]

FAO (2015). AQUASTAT Food and Agriculture Organization of the United Nations, [http://www.fao.org/nr/water/aquastat/countries\\_regions/africa/index.stm](http://www.fao.org/nr/water/aquastat/countries_regions/africa/index.stm), [Online ; accessed 11 November-2015].

ESA (2017). Acquisition Modes, <https://sentinel.esa.int/web/sentinel/user-guides/sentinel-1-sar/acquisition-modes>, [Online ; accessed 20 November 2017]

## Références

Aguilar, J., Rogers, D., & Kisekka, I. (2015). Irrigation scheduling based on soil moisture sensors and evapotranspiration. In *Kansas Agricultural Experiment Station Research Reports*. <https://doi.org/10.4148/2378-5977.1087>

Al-Kayssi, A. W., Al-Karaghoul, A. A., Hasson, A. M., & Beker, S. A. (1990). Influence of soil moisture content on soil temperature and heat storage under greenhouse conditions. *Journal of Agricultural Engineering Research*, *45*, 241–252.

Albergel, C., Rosnay, P. De, Gruhier, C., Munoz-Sabater, J., Hasenauer, S., Isaksen, L., ... Wagner, W. (2012). Evaluation of remotely sensed and modelled soil moisture products using global ground-based in situ observations. *Remote Sensing of Environment*, *118*, 215–226. <https://doi.org/10.1016/j.rse.2011.11.017>

Alexakis, D. D., Mexis, F. D. K., Vozinaki, A. E. K., Daliakopoulos, I. N., & Tsanis, I. K. (2017). Soil moisture content estimation based on Sentinel-1 and auxiliary earth observation products. A hydrological approach. *Sensors*, *17*(6), 1–16. <https://doi.org/10.3390/s17061455>

Amazirh, A., Merlin, O., Er-Raki, S., Gao, Q., Rivalland, V., Malbeteau, Y., ... 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(November 2017), 321–337. <https://doi.org/10.1016/j.rse.2018.04.013>
- Amri, R., Zribi, M., Boulet, G., Calvet, J. C., Szczypta, C., & Lili-Chabaane, Z. (2013). FAO-56 dual approach combined with multi-sensor remote sensing for regional evapotranspiration estimations. *Hydrology and Earth System Sciences Discussions*, 10(6), 8117–8144. <https://doi.org/10.5194/hessd-10-8117-2013>
- Amri, R., Zribi, M., Chabaane, Z. L., Wagner, W., & 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.
- Amri, R., Zribi, M., Lili-Chabaane, Z., Duchemin, B., Gruhier, C., & Chehbouni, A. (2011). Analysis of vegetation behavior in a North African semi-arid region, Using SPOT-VEGETATION NDVI data. *Remote Sensing*, 3(12), 2568–2590. <https://doi.org/10.3390/rs3122568>
- Amri, R., Zribi, M., Lili-Chabaane, Z., Szczypta, C., Calvet, J. C., & Boulet, G. (2014). FAO-56 dual model combined with multi-sensor remote sensing for regional evapotranspiration estimations. *Remote Sensing*, 6(6), 5387–5406. <https://doi.org/10.3390/rs6065387>
- Anguela, T. P., Zribi, M., Baghdadi, N., & Loumagne, C. (2010). Analysis of local variation of soil surface parameters with TerraSAR-X radar data over bare agricultural fields. *IEEE Transactions on Geoscience and Remote Sensing*, 48(2), 874–881.
- Attema, E. P. W., & Ulaby, F. T. (1978). Vegetation modeled as a water cloud. *Radio Science*, 13(2), 357–364. Retrieved from [http://onlinelibrary.wiley.com/doi/10.1029/RS013i002p00357/epdf?r3\\_referer=wol&tracking\\_action=preview\\_click&show\\_checkout=1&purchase\\_referrer=www.google.nl&purchase\\_site\\_license=LICENSE\\_EXPIRED](http://onlinelibrary.wiley.com/doi/10.1029/RS013i002p00357/epdf?r3_referer=wol&tracking_action=preview_click&show_checkout=1&purchase_referrer=www.google.nl&purchase_site_license=LICENSE_EXPIRED)
- Aubert, D., Loumagne, C., & Oudin, L. (2003). Sequential assimilation of soil moisture and streamflow data in a conceptual rainfall – runoff model. *Journal of Hydrology*, 280, 145–161. [https://doi.org/10.1016/S0022-1694\(03\)00229-4](https://doi.org/10.1016/S0022-1694(03)00229-4)
- Aubert, M., Baghdadi, N., Zribi, M., Douaoui, A., Loumagne, C., Baup, F., ... Garrigues, S. (2011). Analysis of TerraSAR-X data sensitivity to bare soil moisture, roughness, composition and soil crust. *Remote Sensing of Environment*, 115(8), 1801–1810. <https://doi.org/10.1016/j.rse.2011.02.021>
- Aubert, M., Baghdadi, N., Zribi, M., Ose, K., El, 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.
- Baghdadi, N., Abou Chaaya, J., & Zribi, M. (2011). Semi-empirical 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., Aubert, M., Cerdan, O., Franchistéguy, L., Viel, C., Eric, M., ... Desprats, J. (2008). Operational mapping of soil moisture using Synthetic Aperture Radar data: Application to the Touch basin (France). *Sensors*, 7(10), 2458–2483. <https://doi.org/10.3390/s7102458>
- Baghdadi, N., Choker, M., Zribi, M., El Hajj, M., Paloscia, S., Verhoest, N., ... Mattia, F. (2016). A New Empirical Model for Radar Scattering from Bare Soil Surfaces. *Remote Sensing*, 8, 920. <https://doi.org/10.3390/rs8110920>
- Baghdadi, N., Cresson, R., Todoroff, P., & Moinet, S. (2010). Multitemporal observations

- of sugarcane by TerraSAR-X images. *Sensors*, *10*, 8899–8919. <https://doi.org/10.3390/s101008899>
- Baghdadi, N., El-Hajj, M., Choker, M., Zribi, M., Bazzi, H., Vaudour, E., ... Ebengo, D. M. (2018). Potential of Sentinel-1 images for estimating the soil roughness over bare agricultural soils. *Water*, *10*(2), 1–14. <https://doi.org/10.3390/w10020131>
- 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*, *9*, 969. <https://doi.org/10.3390/rs9090969>
- Baghdadi, N., El Hajj, M., Zribi, M., & Fayad, I. (2015). Coupling SAR C-Band and optical data for soil moisture and Leaf Area Index retrieval over irrigated grasslands. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, *99*, 1–15. <https://doi.org/10.1109/JSTARS.2015.2464698>
- 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., Holah, N., & Zribi, M. (2006a). 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., Holah, N., & Zribi, M. (2006b). Soil moisture estimation using multi-incidence and multi-polarization ASAR data. *International Journal of Remote Sensing*, *27*(10), 1907–1920. <https://doi.org/10.1080/01431160500239032>
- 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. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 2000–2003. <https://doi.org/10.1109/IGARSS.2015.7326190>
- Bao, Y., Zhang, Y., Wang, J., & Min, J. (2014). Surface soil moisture estimation over dense crop using Envisat ASAR and Landsat TM imagery: an approach. *International Journal of Remote Sensing*, *35*(16), 6190–6212. <https://doi.org/10.1080/01431161.2014.951098>
- Baret, F., Solan, B. De, Lopez-lozano, R., Ma, K., & Weiss, M. (2010). GAI estimates of row crops from downward looking digital photos taken perpendicular to rows at 57.5° zenith angle : Theoretical considerations based on 3D architecture models and application to wheat crops. *Agricultural and Forest Meteorology*, *150*(11), 1393–1401. <https://doi.org/10.1016/j.agrformet.2010.04.011>
- Barrett, B. W., Dwyer, E., & Whelan, P. (2009). Soil moisture retrieval from active spaceborne microwave observations: An evaluation of current techniques. *Remote Sensing*, *1*(3), 210–242. <https://doi.org/10.3390/rs1030210>
- Barrick, D. E. (1968). Rough surface scattering based on the specular point theory. *IEEE Transactions on Antennas and Propagation*, *AP-16*(4), 449–454.
- Basist, A., Grody, N. C., Peterson, T. C., & Williams, C. N. (1997). Using the special sensor microwave / imager to monitor land surface temperatures, wetness, and snow cover. *Journal of Applied Meteorology*, *37*, 888–911.
- Batjes, N. H. (2010). Soil property estimates for the Upper Tana , Kenya , derived from SOTER and WISE. *ISRIC-World Soil Information*, (May), 1–34. Wageningen, The

Netherlands.

- Bazzi, H., Baghdadi, N., Ienco, D., Hajj, M. El, Zribi, M., Belhouchette, H., ... Demarez, V. (2019). Mapping irrigated areas using Sentinel-1 time series in Catalonia, Spain. *Remote Sensing*, *11*, 1836.
- Beriaux, E., Lucau-Danila, C., Auquier, E., & Defourny, P. (2013). Multiyear independent validation of the water cloud model for retrieving maize leaf area index from SAR time series. *International Journal of Remote Sensing*, *34*(12), 4156–4181. <https://doi.org/10.1080/01431161.2013.772676>
- Bindlish, R., & Barros, A. P. (2000). Multifrequency soil moisture inversion from SAR measurements with the use of IEM. *Remote Sensing of Environment*, *71*(1), 67–88. [https://doi.org/10.1016/S0034-4257\(99\)00065-6](https://doi.org/10.1016/S0034-4257(99)00065-6)
- Bindlish, R., & Barros, A. P. (2001). Parameterization of vegetation backscatter in radar-based, soil moisture estimation. *Remote Sensing of Environment*, *76*(1), 130–137. [https://doi.org/10.1016/S0034-4257\(00\)00200-5](https://doi.org/10.1016/S0034-4257(00)00200-5)
- Bisselink, B., Van Meijgaard, E., Dolman, A. J., & De Jeu, R. A. M. (2011). Initializing a regional climate model with satellite-derived soil moisture. *Journal of Geophysical Research Atmospheres*, *116*(D02121), 1–13. <https://doi.org/10.1029/2010JD014534>
- Bousbih, S., Zribi, M., El Hajj, M., 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 and Sentinel-2 data. *Remote Sensing*, *10*(12), 1953. <https://doi.org/10.3390/rs10121953>
- Bovik, A. C., Huang, T., & Munson. (1983). A generalization of median filtering using linear combinations of order statistics. *IEEE TRANSACTIONS ON ACOUSTICS, SPEECH, AND SIGNAL PROCESSING, ASSP-31*(6), 1342–1350.
- Brocca, L., Ciabatta, L., Massari, C., Moramarco, T., Hahn, S., Hasenauer, S., ... Levizzani, V. (2014). Soil as a natural rain gauge: Estimating global rainfall from satellite soil moisture data. *J. Geophys. Res. Atmos.*, *119*, 5128–5141. <https://doi.org/10.1002/2014JD021489>.Received
- Brocca, L., Crow, W. T., Ciabatta, L., Massari, C., Rosnay, P. De, Enenkel, M., ... Member, S. (2017). A review of the applications of ASCAT soil moisture products. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, *10*(5), 2285–2306.
- 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*, 1881–1893. <https://doi.org/10.5194/hess-14-1881-2010>
- Chahbi, A., Zribi, M., Chabaane, Z. L., Duchemin, B., & Shabou, M. (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*, 1004–1028. <https://doi.org/10.1080/01431161.2013.875629>
- Chauhan, S., Srivastava, H. S., & Patel, P. (2017). Improved parametrization of Water Cloud Model for hybrid-polarized backscatter simulation using interaction factor. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, *XLII*(4), 61–66.
- Chen, K. S., Yen, S. K., & Huang, W. P. (1995). A simple model for retrieving bare soil moisture from radar-scattering coefficients. *Remote Sensing of Environment*, *54*(2), 121–126. [https://doi.org/10.1016/0034-4257\(95\)00129-O](https://doi.org/10.1016/0034-4257(95)00129-O)
- Choker, M., Baghdadi, N., Zribi, M., El Hajj, M., Paloscia, S., Verhoest, N. E. C., ...

- 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(38), 1–27. <https://doi.org/10.3390/w9010038>
- Cochran, C. C. (2010). Soil moisture-temperature correlation and classification model. *19th World Congress of Soil Science, Soil Solutions for a Changing World*, 1–6. Australia.
- Crow, W. T., & Ryu, D. (2009). A new data assimilation approach for improving runoff prediction using remotely-sensed soil moisture retrievals. *Hydrology and Earth System Sciences*, 13, 1–16.
- 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, 139–148. <https://doi.org/10.1016/j.asr.2006.02.032>
- De Roo, R. D., Du, Y., Ulaby, F. T., & Craig Dobson, M. (2001). A semi-empirical backscattering model at L-band and C-band for a soybean canopy with soil moisture inversion. *IEEE Transactions on Geoscience and Remote Sensing*, 39(4), 864–872. <https://doi.org/10.1109/36.917912>
- De Wit, A. J. W., & Diepen, C. A. Van. (2007). Crop model data assimilation with the Ensemble Kalman filter for improving regional crop yield forecasts. *Agricultural and Forest Meteorology*, 146, 38–56. <https://doi.org/10.1016/j.agrformet.2007.05.004>
- Demarez, V., Duthoit, S., Frederic, B., Weiss, M., & Dedieu, G. (2008). Estimation of leaf area and clumping indexes of crops with hemispherical photographs. *Agricultural and Forest Meteorology*, 148, 644–655. <https://doi.org/10.1016/j.agrformet.2007.11.015>
- Dobson, M. C., & Ulaby, F. T. (1986). Active microwave soil moisture reaseach. *IEEE Geoscience and Remote Sensing*, 24(1), 28–35.
- Dong, L., Baghdadi, N., & Ludwig, R. (2012). Validation of the AIEM through correlation length parameterization at field scale using radar imagery in a semi-arid environment. *IEEE Geoscience and Remote Sensing Letters*, 10(3), 461–465. <https://doi.org/10.1109/LGRS.2012.2209626>
- Dubois, P. C., van Zyl, J., & Engman, T. (1995). Measuring soil moisture with imaging radars. *IEEE Transactions on Geoscience and Remote Sensing*, 33(4), 915–926. <https://doi.org/10.1109/36.406677>
- Duchemin, B., Hagolle, O., Mougenot, B., Benhadj, I., Hadria, R., Simonneaux, V., ... Chehbouni, A. G. (2008). Agrometeorological study of semi-arid areas: an experiment for analysing the potential of time series of FORMOSAT-2 images (Tensift-Marrakech plain). *International Journal of Remote Sensing*, 29(17–18), 5291–5300. <https://doi.org/10.1080/01431160802036482>
- 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>
- Eltahir, E. A. B. (1998). A soil moisture-rainfall feedback mechanism. *Water Resources Research*, 34(4), 765–776.
- Entekhabi, D., Njoku, E. G., O'Neill, P. E., Kent, H. K., Crow, W. T., Edelstein, W. N., ... van Zyl, J. (2010). The Soil Moisture Active and Passive ( SMAP ) mission. *IEEE*,

- (98, No. 5), 704–716. <https://doi.org/10.1109/JPROC.2010.2043918>
- 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), 1–17. <https://doi.org/10.1117/1.JRS.11.016002>
- Fieuzal, R., & Baup, F. (2016). Estimation of leaf area index and crop height of sunflowers using multi-temporal optical and SAR satellite data. *International Journal of Remote Sensing*, 37(12), 2780–2809. <https://doi.org/10.1080/01431161.2016.1176276>
- Fieuzal, R., Baup, F., & Marais-Sicre, C. (2013). Monitoring wheat and rapeseed by using synchronous optical and radar satellite Data—From temporal signatures to crop parameters estimation. *Advances in Remote Sensing*, 02, 162–180. <https://doi.org/10.4236/ars.2013.22020>
- Fieuzal, R., Duchemin, B., Jarlan, L., Zribi, M., Baup, F., Merlin, O., ... Garatuza-Payan, J. (2011). Combined use of optical and radar satellite data for the monitoring of irrigation and soil moisture of wheat crops. *Hydrology and Earth System Sciences*, 15(4), 1117–1129. <https://doi.org/10.5194/hess-15-1117-2011>
- Fontanelli, G., Paloscia, S., Zribi, M., & Chahbi, A. (2013). Sensitivity analysis of X-band SAR to wheat and barley leaf area index in the Merguellil Basin. *Remote Sensing Letters*, 4(11), 1107–1116. <https://doi.org/10.1080/2150704X.2013.842285>
- Frost, V. S., Abbott Stiles, J., Shanmugan, K. S., & Holtzman, J. C. (1982). A Model for radar images and its application to adaptive digital filtering of multiplicative noise. *IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE*, 4(2), 157–166.
- 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.
- Gao, B. (1996). NDWI\_A Normalized Difference Water Index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 266, 257–266.
- Gherboudj, I., Magagi, R., Berg, A. A., & Toth, B. (2011). Soil moisture retrieval over agricultural fields from multi-polarized and multi-angular RADARSAT-2 SAR data. *Remote Sensing of Environment*, 115(1), 33–43. <https://doi.org/10.1016/j.rse.2010.07.011>
- Ghulam, A., Qin, Q., & Zhan, Z. (2007). Designing of the perpendicular drought index. *Environ. Geol.*, 52, 1045–1052. <https://doi.org/10.1007/s00254-006-0544-2>
- Gillies, R. R., & Carlson, T. N. (1995). Thermal remote sensing of surface water content with partial vegetation cover for incorporation into climate models. *Journal of Applied Meteorology*, 14, 745–755.
- Gorrab, A., Zribi, M., Baghdadi, N., Mougenot, B., & Chabaane, Z. L. (2015). Potential of X-band TerraSAR-X and COSMO-SkyMed SAR data for the assessment of physical soil parameters. *Remote Sensing*, 7(1), 747–766. <https://doi.org/10.3390/rs70100747>
- 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., & Harris, R. (2003). Constructing a water-use model for input to the water cloud backscatter model. *Agronomie*, 23(8), 711–718. <https://doi.org/10.1051/agro>
- Guillaud, C., & Trabelsi, M. (1991). Gestion des ressources hydriques en Tunisie centrale: les projets Sidi Saad et El Haouared. *Proceedings of the Vienna Symposium, Hydrology for the Water Management of Large River Basins*, (201), 129–138.
- Guillod, B. P., Orłowsky, B., Miralles, D. G., Teuling, A. J., & Seneviratne, S. I. (2015).

- Reconciling spatial and temporal soil moisture effects on afternoon rainfall. *Nature Communications*, 6, 1–6. <https://doi.org/10.1038/ncomms7443>
- Hagolle, O., Huc, M., David, V. P., & Dedieu, G. (2010). A multi-temporal method for cloud detection, applied to FORMOSAT-2, VEN $\mu$ s, LANDSAT and SENTINEL-2 images. *Remote Sensing of Environment*, 114(8), 1747–1755. <https://doi.org/10.1016/j.rse.2010.03.002>
- Hassan-Esfahani, L., Torres-Rua, A., Jensen, A., & McKee, M. (2015). Assessment of surface soil moisture using high-resolution multi-spectral imagery and artificial neural networks. *Remote Sensing*, 7(3), 2627–2646. <https://doi.org/10.3390/rs70302627>
- Hawke, R., & McConchie, J. (2011). In situ measurement of soil moisture and pore-water pressures in an ‘incipient’ landslide: Lake Tutira, New Zealand. *Journal of Environmental Management*, 92, 266–274. <https://doi.org/10.1016/j.jenvman.2009.05.035>
- 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>
- Helman, D., Lensky, I. M., & Bonfil, D. J. (2019). Early prediction of wheat grain yield production from root-zone soil water content at heading using Crop RS-Met. *Field Crops Research*, 232, 11–23. <https://doi.org/10.1016/j.fcr.2018.12.003>
- Holah, N., Baghdadi, N., Zribi, M., Bruand, A., & King, C. (2005). Potential of ASAR/ENVISAT for the characterization of soil surface parameters over bare agricultural fields. *Remote Sensing of Environment*, 96(1), 78–86. <https://doi.org/10.1016/j.rse.2005.01.008>
- Hosseini, M., McNairn, H., Merzouki, A., & Pacheco, A. (2015). Estimation of Leaf Area Index (LAI) in corn and soybeans using multi-polarization C- and L-band radar data. *Remote Sensing of Environment*, 170, 77–89. <https://doi.org/10.1016/j.rse.2015.09.002>
- Jackson, R. D., Dso, B., & Reginato, R. J. (1976). Calculation of evaporation rates during the transition from energy-limiting to soil-limiting phases using albedo data. *Water*, 12(1), 23–26.
- Jiang, H., & Cotton, W. R. (2004). Soil moisture estimation using an artificial neural network: A feasibility study. *Canadian Journal of Remote Sensing*, 30(5), 827–839. <https://doi.org/10.5589/m04-041>
- Jiao, X., McNairn, H., Shang, J., & Liu, J. (2010). The sensitivity of multi-frequency (X, C and L-band) radar backscatter signatures to bio-physical variables (LAI) over corn and soybean fields. *The 100 International Society for Photogrammetry and Remote Sensing Symposium, XXXVIII(7B)*, 317–321. Vienna-Austria.
- Jin, X., Kumar, L., Li, Z., Feng, H., Xu, X., Yang, G., & Wang, J. (2018). A review of data assimilation of remote sensing and crop models. *European Journal of Agronomy*, 92, 141–152. <https://doi.org/10.1016/j.eja.2017.11.002>
- Kerr, Y. H., Waldteufel, P., Wigneron, J., Delwart, S., Cabot, F., Boutin, J., ... Mechlenburg, S. (2010). The SMOS Mission: New tool for monitoring key elements of the global water cycle. *IEEE Geoscience and Remote Sensing*, 98(5), 666–687.
- Khabazan, S., Motagh, M., & Hosseini, M. (2013). Evaluation of radar backscattering models IEM, OH, and Dubois using L and C-Bands SAR data over different vegetation canopy covers and soil depths. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 5-8 October 2013, XL-1/W3(October)*, 225–230. <https://doi.org/10.5194/isprsarchives-xl-1-w3-225-2013>
- Koster, R. D., Brocca, L., Crow, W. T., Burgin, M. S., & Gabrielle, J. M. (2016).

- Precipitation estimation using L-Band and C-Band soil moisture retrievals. *Water Resources Research*, 52(7213–7225).
- Koster, R. D., Dirmeyer, P. A., Guo, Z., Bonan, G., Chan, E., Cox, P., ... Yamada, T. (2004). Regions of strong coupling between soil moisture and precipitation. *Science*, 305(5687), 1138–1140. <https://doi.org/10.1126/science.1100217>
- Koster, R. D., & Suarez, M. J. (2001). Soil moisture memory in climate models. *Journal of Hydrometeorology*, 2(6), 558–570. [https://doi.org/10.1175/1525-7541\(2001\)002<0558:smmicm>2.0.co;2](https://doi.org/10.1175/1525-7541(2001)002<0558:smmicm>2.0.co;2)
- Kseneman, M., & Gleich, D. (2013). Soil-moisture estimation from X-band data using Tikhonov regularization and Neural Net. *IEEE Transactions on Geoscience and Remote Sensing*, 51(1), 3885–3898. <https://doi.org/10.1109/TGRS.2012.2228486>
- Kseneman, M., Gleich, D., & Potočnik, B. (2012). Soil-moisture estimation from TerraSAR-X data using neural networks. *Machine Vision and Applications*, 23(5), 937–952. <https://doi.org/10.1007/s00138-011-0375-3>
- Kumar, K., Hari Prasad, K. S., & Arora, M. K. (2012). Estimation of water cloud model vegetation parameters using a genetic algorithm. *Hydrological Sciences Journal*, 57(4), 776–789. <https://doi.org/10.1080/02626667.2012.678583>
- Kweon, S., Member, S., & Oh, Y. (2015). A modified Water-Cloud Model with leaf angle parameters for microwave backscattering from agricultural fields. *IEEE Transactions on Geoscience and Remote Sensing*, 53(5), 2802–2809. <https://doi.org/10.1109/TGRS.2014.2364914>
- Lakshmi, V., Jackson, T. J., & Zehrhuhs, D. (2003). Soil moisture – temperature relationships: results from two field experiments. *Hydrological Processes*, 17, 3041–3057. <https://doi.org/10.1002/hyp.1275>
- Le Morvan, A., Zribi, M., Baghdadi, N., & Chanzy, A. (2008). Soil moisture profile effect on radar signal measurement. *Sensors*, 8(1), 256–270. <https://doi.org/10.3390/s8010256>
- Le Toan, T., Laur, H., Mougin, E., & Lopes, A. (1989). Multitemporal and dual-polarization observations of agricultural vegetation covers by X-Band SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, 27(6), 709–718. <https://doi.org/10.1109/TGRS.1989.1398243>
- Lecerf, R., Ceglar, A., López-lozano, R., Velde, M. Van Der, & Baruth, B. (2019). Assessing the information in crop model and meteorological indicators to forecast crop yield over Europe. *Agricultural Systems*, 168, 191–202. <https://doi.org/10.1016/j.agsy.2018.03.002>
- Leduc, C., Ben Ammar, S., Favreau, G., Beji, R., Virrion, R., Lacombe, G., ... Zouari, K. (2007). Impacts of hydrological changes in the Mediterranean zone: environmental modifications and rural development in the Merguellil catchment, central Tunisia. *Hydrological Sciences Journal*, 52(6), 1162–1178.
- Lee, J. (1983). Digital image smoothing and the Sigma filter. *COMPUTER VISION, GRAPHICS, AND IMAGE PROCESSING*, 24, 255–269.
- Lee, J. S. (1981). Speckle analysis and smoothing of Synthetic Aperture Radar images. *Computer Graphs and Image Processing*, 17, 24–32.
- Li, J., & Wang, S. (2018). Using SAR-derived vegetation descriptors in a Water Cloud Model to improve soil moisture retrieval. *Remote Sensing*, 10, 1370. <https://doi.org/10.3390/rs10091370>
- Lievens, H., Tomer, S. K., Bitar, A. Al, Lannoy, G. J. M. De, Drusch, M., Dumedah, G., ... Pauwels, V. R. N. (2015). SMOS soil moisture assimilation for improved

- hydrologic simulation in the Murray Darling Basin , Australia. *Remote Sensing of Environment*, 168, 146–162. <https://doi.org/10.1016/j.rse.2015.06.025>
- 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 and Remote Sensing*, 9(12), 5621–5633. <https://doi.org/10.1109/JSTARS.2016.2596541>
- Liu, L., Zhang, R., & Zuo, Z. (2016). The Relationship between soil moisture and LAI in different types of soil in Central Eastern China. *Journal of Hydrometeorology*, 17, 2733–2742. <https://doi.org/10.1175/JHM-D-15-0240.1>
- Lopes, A., Touzi, R., & Nezry, E. (1990). Adaptive Speckle Filters and Scene Heterogeneity. *IEEE Geoscience and Remote Sensing*, 28(6), 992–1000.
- Lorenz, R., Argüeso, D., Donat, M. G., Pitman, A. J., Hurk, B. Van Den, Berg, A., ... Seneviratne, S. I. (2015). Influence of land-atmosphere feedbacks on temperature and precipitation extremes in the GLACE-CMIP5 ensemble. *Journal of Geophysical Research Atmospheres*, 121, 607–623. <https://doi.org/10.1002/2015JD024053>.Wales
- Martens, B., Miralles, D., Lievens, H., Fernández-prieto, D., & Verhoest, N. E. C. (2015). Improving terrestrial evaporation estimates over continental Australia through assimilation of SMOS soil moisture. *International Journal of Applied Earth Observations and Geoinformation*, 1–17. <https://doi.org/10.1016/j.jag.2015.09.012>
- Massari, C., Brocca, L., Moramarco, T., Tramblay, Y., & Lescot, J. D. (2014). Potential of soil moisture observations in flood modelling: Estimating initial conditions and correcting rainfall. *Advances in Water Resources*, 74, 44–53.
- Mattia, F., Toan, T., Souyris, J. C., Carolis, G., Floury, N., Posa, F., & Pasqariello, G. (1997). The effect of surface roughness on multifrequency polarimetric SAR data. *IEEE Transactions on Geoscience and Remote Sensing*, 35(4), 954–967.
- Merzouki, A., McNairn, H., & Pacheco, A. (2010). Evaluation of the Dubois, Oh, and IEM radar backscatter models over agricultural fields using C-band RADARSAT-2 SAR image data. *Canadian Journal of Remote Sensing*, 36(2), 274–286.
- Miralles, D. G., Berg, M. J. Van Den, Teuling, A. J., & Jeu, R. A. M. De. (2012). Soil moisture-temperature coupling: A multiscale observational analysis. *Geophysical Research Letters*, 39(L21707), 1–6. <https://doi.org/10.1029/2012GL053703>
- Miralles, D. G., Holmes, T. R. H., Jeu, R. A. M. De, Gash, J. H., Meesters, A. G. C. A., & Dolman, A. J. (2011). *Global land-surface evaporation estimated from satellite-based observations*. (2), 453–469. <https://doi.org/10.5194/hess-15-453-2011>
- Mougou, R., Mansour, M., Iglesias, A., Zitouna Chebbi, R., & Battaglini, A. (2010). Climate change and agricultural vulnerability: a case study of rain-fed wheat in Kairouan, Central Tunisia. *Regional Environmental Change - Springer*, 11, 137–142. <https://doi.org/10.1007/s10113-010-0179-4>
- Narasimhan, B., & Srinivasan, R. (2005). Development and evaluation of Soil Moisture Deficit Index ( SMDI ) and Evapotranspiration Deficit Index ( ETDI ) for agricultural drought monitoring. *Agricultural and Forest Meteorology*, 133, 69–88. <https://doi.org/10.1016/j.agrformet.2005.07.012>
- Nieto-Vesperinas, M., & Sanchez-Gil, J. A. (1992). Light scattering from a random rough interface with total internal reflection. *Journal of Optical Society of America*, 9(3), 424–

- Oevelen, P. J. Van, Member, A., & Hoekman, D. H. (1999). Radar backscatter inversion techniques for estimation of surface soil moisture : *IEEE Transactions on Geoscience and Remote Sensing*, 37(1), 113–123.
- 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., Science, C., & Arbor, A. (1994). An Inversion Algorithm For Retrieving Soil Moisture And Surface Roughness From Polarimetric Radar Observation. *IEEE Geoscience and Remote Sensing Letters*, 3, 1582–1584.
- Oh, Y., Sarabandi, K., & Ulabz, F. T. (1992). An empirical model and an inversion technique for radar scattering from bare soil surfaces. *IEEE Transactions on Geoscience and Remote Sensing*, 30(2), 370–381.
- Paloscia, S., Pampaloni, P., Pettinato, S., & Santi, E. (2010). Generation of soil moisture maps from ENVISAT/ASAR images in mountainous areas: A case study. *International Journal of Remote Sensing*, 31(10), 2265–2276. <https://doi.org/10.1080/01431160902953891>
- Paloscia, S., Pettinato, S., Santi, E., Notarnicola, C., Pasolli, L., & Reppucci, A. (2013). Soil moisture mapping using Sentinel-1 images: Algorithm and preliminary validation. *Remote Sensing of Environment*, 134, 234–248. <https://doi.org/10.1016/j.rse.2013.02.027>
- 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>
- Papa, R. J., & Lennon, J. F. (1988). Conditions for the validity of Physical Optics in rough surface scattering. *IEEE Transactions on Antennas and Propagation*, 36(5), 647–650.
- Paredes-trejo, F., & Barbosa, H. (2017). Evaluation of the SMOS-derived Soil Water Deficit Index as agricultural drought index in Northeast of Brazil. *Water*, 9, 377. <https://doi.org/10.3390/w9060377>
- Paris, F. (1986). The effect of leaf size on the microwave backscattering by corn. *Remote Sensing of Environment*, 19, 81–95.
- Pauwels, V., Verhoest, N., & Troch, P. A. (2002). Improvement of TOPLATS-based discharge predictions through assimilation of ERS-based remotely sensed soil. *Hydrol*, 16, 995–1013. <https://doi.org/10.1002/hyp.315>
- Pellarin, T., Louvet, S., Gruhier, C., Quantin, G., & Legout, C. (2013). A simple and effective method for correcting soil moisture and precipitation estimates using AMSR-E measurements. *Remote Sensing of Environment*, 136, 28–36. <https://doi.org/10.1016/j.rse.2013.04.011>
- Petropoulos, G. P., Ireland, G., & Barrett, B. (2015). Surface soil moisture retrievals from remote sensing : Current status , products & future trends. *Physics and Chemistry of the Earth*, 44. <https://doi.org/10.1016/j.pce.2015.02.009>
- Ponziani, F., Pandolfo, C., Stelluti, M., Berni, N., Brocca, L., & Maramarco, T. (2012). Assessment of rainfall thresholds and soil moisture modeling for operational hydrogeological risk prevention in the Umbria region ( central Italy ). *Landslides*, 9, 229–237. <https://doi.org/10.1007/s10346-011-0287-3>
- Potić, I., Bugarski, M., & Matić-Varenica, J. (2017). Soil moisture determination using remote sensing data for the property protection and increase of agriculture

- production. *Annual World Bank Conference On Land And Poverty*. Washington, DC, USA.
- 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*, 331–339. [https://doi.org/10.1016/0034-4257\(93\)90053-Z](https://doi.org/10.1016/0034-4257(93)90053-Z)
- Qiu, J., Crow, W. T., Nearing, G. S., Mo, X., & Liu, S. (2014). The impact of vertical measurement depth on the information content of soil moisture times series data. *Geophysical Research Letters*, *41*, 4997–5004. <https://doi.org/10.1002/2014GL060017>. Received
- Rawat, K. S., Sehgal, V. K., Pradhan, S., & Ray, S. S. (2018). Semi-empirical model for retrieval of soil moisture using RISAT-1 C-Band SAR data over a sub-tropical semi-arid area of Rewari district, Haryana (India). *Journal of Earth System Science*, *127*(18), 1–11. <https://doi.org/10.1007/s12040-018-0919-2>
- Rice, S. O. (1950). Reflection of electromagnetic waves from slightly rough surfaces. *Symposium on the Theory of Electromagnetic Waves*, *4*, 351–378.
- Ripoll, J., Ntziachristos, V., Carminati, R., & Nieto-vesperinas, M. (2001). Kirchhoff approximation for diffusive waves. *Physical Review*, *64*, 1–8. <https://doi.org/10.1103/PhysRevE.64.051917>
- Saadi, S., Boulet, G., Bahir, M., Brut, A., Mougénot, B., Simonneaux, V., & Chabaane, Z. L. (2017). Assessment of actual evapotranspiration over a semi-arid heterogeneous land surface by means of coupled low resolution remote sensing data with energy balance model: comparison to extra Large Aperture Scintillometer measurements. *Hydrology and Earth System Sciences Discussions*, (August), 1–31.
- Saadi, S., Simonneaux, V., Boulet, G., Raimbault, B., Mougénot, B., Fanise, P., ... 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*, 13005–13028. <https://doi.org/10.3390/rs71013005>
- Saadi, S., Todorovic, M., Tanasijevic, L., Pereira, L. S., Pizzigalli, C., & Lionello, P. (2014). Climate change and Mediterranean agriculture : Impacts on winter wheat and tomato crop evapotranspiration, irrigation requirements and yield. *Agricultural Water Management*, *147*, 103–115. <https://doi.org/10.1016/j.agwat.2014.05.008>
- Saha, A., Patil, M., Goyal, V., & Rathore, D. S. (2019). Assessment and impact of soil moisture index in agricultural drought estimation using remote sensing and GIS techniques †. *Proceeding*, *7*(2), 1–8. <https://doi.org/10.3390/ECWS-3-05802>
- Said, S., Kothyari, U. C., & Arora, M. K. (2012). Vegetation effects on soil moisture estimation from ERS-2 SAR images. *Hydrological Sciences Journal*, *57*(3), 517–534. <https://doi.org/10.1080/02626667.2012.665608>
- Samouëlian, A., Cornu, S., Bruand, A., & Richard, G. (2007). Modélisation de l'évolution des sols liée à des processus hydrologiques et géochimiques. *Eude et Gestion Des Sols, Association Française Pour l'étude Des Sols*, *14*(3), 195–204.
- Sandholt, I., Rasmussen, K., & Andersen, J. (2002). A simple interpretation of the surface temperature / vegetation index space for assessment of surface moisture status. *Remote Sensing of Environment*, *79*, 213–224.
- Schmugge, T. J., Kustas, W. P., Ritchie, J. C., & Jackson, T. J. (2002). Remote sensing in hydrology. *Advances in Water Resources*, *25*, 1367–1385.
- Seneviratne, S. I., Corti, T., Davin, E. L., Hirschi, M., Jaeger, E. B., Lehner, I., ... Teuling, A. J. (2010). Investigating soil moisture-climate interactions in a changing climate: A

- review. *Earth-Science Reviews*, 99, 125–161.  
<https://doi.org/10.1016/j.earscirev.2010.02.004>
- Seneviratne, S. I., Luthi, D., Litschi, M., & Schar, C. (2006). Land–atmosphere coupling and climate change in Europe. *Nature*, 443(14), 205–209.  
<https://doi.org/10.1038/nature05095>
- Shabou, M., Mougenot, B., Lili-Chabaane, Z., Walter, C., Boulet, G., Aissa, N., & 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. 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.
- Sikdar, M., & Cumming, I. (2004). *A modified empirical model for soil moisture estimation in vegetated areas using SAR data*. 803–806. <https://doi.org/10.1109/igarss.2004.1368526>
- Srivastava, H. S., Patel, P., Manchanda, M. L., & Adiga, S. (2003). Use of multiincidence angle RADARSAT-1 SAR data to incorporate the effect of surface roughness in soil moisture zstimation. *IEEE Transactions on Geoscience and Remote Sensing*, 41(7), 1638–1640.
- Srivastava, H. S., Patel, P., Sharma, Y., & Navalgund, R. R. (2009). Large-area soil moisture estimation using multi-incidence-angle RADARSAT-1 SAR data. *IEEE Transactions on Geoscience and Remote Sensing*, 47(8), 2528–2535.
- Sun, J., Salvucci, G. D., Entekhabi, D., & Farhadi, L. (2011). Parameter estimation of coupled water and energy balance models based on stationary constraints of surface states. *Water Resources Research*, 47(2), 1–16. <https://doi.org/10.1029/2010WR009293>
- Temimi, M., Lacava, T., Lakhankar, T., Tramutoli, V., Ghedira, H., Ata, R., & Khanbilvardi, R. (2011). A multi-temporal analysis of AMSR-E data for flood and discharge monitoring during the 2008 flood in Iowa. *Hydrological Processes*, 25, 2623–2634. <https://doi.org/10.1002/hyp.8020>
- Todisco, F., Brocca, L., Termitte, L. F., & Wagner, W. (2015). Use of satellite and modeled soil moisture data for predicting event soil loss at plot scale. *Hydrology and Earth System Sciences*, 19, 3845–3856. <https://doi.org/10.5194/hess-19-3845-2015>
- Touré, 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. *IEEE Transactions on Geoscience and Remote Sensing*, 32(1), 47–61.
- Tramblay, Y., Bouvier, C., Martin, C., Didon-lescot, J., Todorovik, D., & Domergue, J. (2010). Assessment of initial soil moisture conditions for event-based rainfall – runoff modelling. *Journal of Hydrology*, 387(3–4), 176–187.  
<https://doi.org/10.1016/j.jhydrol.2010.04.006>
- Tuttle, S. E., & Salvucci, G. D. (2014). A new approach for validating satellite estimates of soil moisture using large-scale precipitation : Comparing AMSR-E products. *Remote Sensing of Environment*, 142, 207–222. <https://doi.org/10.1016/j.rse.2013.12.002>
- Ulaby, F. T., Allen, C. T., & Eger III, G. (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 Dobson, M. (1990). Michigan microwave canopy scattering model. *International Journal of Remote Sensing*, 11(7), 1223–1253. <https://doi.org/10.1080/01431169008955090>

- Von Eynatten, H., Barcelo-Vidal, C., & Pawlowsky-Glahn, V. (2003). Modelling compositional change: The example of chemical weathering of granitoid rocks. *Mathematical Geology*, *35*(3), 231–251.
- Wagner, W., Lemoine, G., & Rott, H. (1999). A method for estimating soil moisture from ERS Scatterometer and soil data. *Remote Sensing of Environment*, *70*(2), 191–207. [https://doi.org/10.1016/S0034-4257\(99\)00036-X](https://doi.org/10.1016/S0034-4257(99)00036-X)
- Wagner, W., Sabel, D., Doubkova, M., Bartsch, A., & Pathe, C. (2013). *the potential of Sentinel-1 for monitoring soil moisture with a high spatial resolution At global scale.*
- Wanders, N., Karssenbergh, D., Roo, A. De, Jong, S. M. De, & Bierkens, M. F. P. (2014). The suitability of remotely sensed soil moisture for improving operational flood forecasting. *Hydrology and Earth System Sciences*, *18*, 2343–2357. <https://doi.org/10.5194/hess-18-2343-2014>
- Weng, Q., Lu, D., & Schubring, J. (2003). Estimation of land surface temperature – vegetation abundance relationship for urban heat island studies. *Remote Sensing of Environment*, *89*, 467–483. <https://doi.org/10.1016/j.rse.2003.11.005>
- Whan, K., Zscheischler, J., Orth, R., Shongwe, M., Rahimi, M., Asare, E. O., & Seneviratne, S. I. (2015). Impact of soil moisture on extreme maximum temperatures in Europe. *Weather and Climate Extremes*, *9*, 57–67. <https://doi.org/10.1016/j.wace.2015.05.001>
- Wigneron, J., Laguerre, L., & Kerr, Y. H. (2001). A simple parameterization of the L-Band microwave emission from rough agricultural soils. *IEEE Transactions on Geoscience and Remote Sensing*, *39*(8), 1697–1707.
- Yang, Y., Guan, H., Long, D., Liu, B., Qin, G., Qin, J., & Batelaan, O. (2015). Estimation of surface soil moisture from thermal infrared remote sensing using an improved Trapezoid method. *Remote Sensing*, *7*, 8250–8270. <https://doi.org/10.3390/rs70708250>
- Yang, Z., Li, K., Shao, Y., Brisco, B., & Liu, L. (2016). Estimation of paddy rice variables with a modified Water Cloud Model and improved polarimetric decomposition using multi-temporal RADARSAT-2 images. *Remote Sensing*, *8*(878). <https://doi.org/10.3390/rs8100878>
- Yu, F., & Zhao, Y. (2011). A new semi-empirical model for soil moisture content retrieval by ASAR and TM data in vegetation-covered areas. *Science China Earth Sciences*, *54*(12), 1955–1964. <https://doi.org/10.1007/s11430-011-4204-3>
- Zhang, D., & Zhou, G. (2016). Estimation of soil moisture from optical and thermal remote sensing: A review. *Sensors*, *16*(1308), 1–29. <https://doi.org/10.3390/s16081308>
- Zhang, F., Zhang, L., Shi, J., & Huang, J. (2014). Soil moisture monitoring based on Land Surface Temperature- Vegetation Index space derived from MODIS data \* 1. *Pedosphere*, *24*(4), 450–460. [https://doi.org/10.1016/S1002-0160\(14\)60031-X](https://doi.org/10.1016/S1002-0160(14)60031-X)
- Zhou, G., Liu, X., & Liu, M. (2019). Assimilating remote sensing phenological information into the WOFOST model for rice growth simulation. *Remote Sensing*, *11*(268). <https://doi.org/10.3390/rs11030268>
- Zribi, M., Anguela, T. P., Duchemin, B., Lili, Z., Wagner, W., Chehbouni, A., ... Wagner, W. (2010). Relationship between soil moisture and vegetation in the Kairouan plain region of Tunisia using low spatial resolution satellite data To cite this version : HAL Id: ird-00611933. *Water Resources Research*, *46*, 1–13. <https://doi.org/10.1029/2009WR008196.1>
- Zribi, M., Chahbi, A., Shabou, M., Lili-Chabaane, Z., Duchemin, B., Baghdadi, N., ...

- 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., & Dechambre, M. (2002). A new empirical model to retrieve soil moisture and roughness from C-band radar data. *Remote Sensing of Environment*, 84, 42–52.
- 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/10.1109/IGARSS.2014.6947205>
- 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)