

École doctorale SIBAGHE

(Systèmes Intégrés en Biologie, Agronomie, Géosciences, Hydrosciences, Environnement)

Doctorat ParisTech

THÈSE

pour obtenir le grade de docteur délivré par

L'Institut des Sciences et Industries du Vivant et de l'Environnement (AgroParisTech)

Spécialité : Science de la Terre et de l'Eau (STE)

présentée et soutenue publiquement par

Mohammad EL HAJJ

le 08 Décembre 2015

Utilisation de la télédétection optique et radar pour le suivi et la gestion de prairies irriguées

Directeur de thèse : **Nicolas BAGHDADI**, Directeur de Recherche, Irstea, Montpellier

Co-encadrement de la thèse : **Gilles Belaud**, Professeurs, SupAgro-UMR G-eau

Jury

M. Jean-Pierre Wigneron , Directeur de recherche, INRA	Rapporteur
M. Gilles Boulet , Directeur de recherche, IRD	Rapporteur
M. Marc Voltz , Directeur de Recherche, INRA	Examinateur
M. Olivier Cerdan , Ingénieur de recherche, BRGM	Examinateur
M. Nicolas Baghdadi , Directeur de recherche, Irstea	Examinateur
M. Gilles Belaud , Professeur, SupAgro	Examinateur

AgroParisTech

UMR TETIS Territoires, environnement, télédétection et information spatiale
Maison de la télédétection, 500 rue Jean-François Breton, 34093 Montpellier Cedex 5, France

REMERCIEMENTS

Mes remerciements profonds vont avant tout à *M. Nicolas Baghdadi* mon directeur de thèse. Merci *Nicolas* de m'avoir confié ce travail de recherche et de t'être toujours montré à l'écoute, et disponible tout au long de la réalisation de cette thèse. Votre implication et votre disponibilité en toute circonstance, vos conseils avisés, votre exigence, ont été des appuis inestimables. Au même titre, j'adresse mes sincères remerciements à *M. Gilles Belaud, et M. Bruno Chevron* pour leur co-direction de qualité, leurs bons conseils, et leur sympathie. *Nicolas, Gilles, et Bruno*, avec vous j'ai énormément appris et aimé apprendre, au cours de ces trois années.

Je remercie vivement la Banque Islamique de Développement d'avoir financé ce projet de thèse. En particulier, le directeur et les agents de la branche bourse scolaire. Des mercis tout particulier à *M. Malek Shah, M. Abulmayeen Shaharuqul Huq, M. Lakhdar Kadkadi, M. Haitham Alsalahi*. Au même titre, un grand merci à *M. Monzer Mohammad el Khatib*.

Je tiens également à remercier le directeur de l'UMR TETIS *M. Jean-Philippe Tonneau* de m'avoir accueilli au sein de cette unité que j'ai eu plaisir à intégrer

Merci à *M. Gilles Boulet et M. Jean-Pierre Wigneron*, de m'avoir fait l'honneur d'être les rapporteurs de ce mémoire. Je remercie également *M. Marc Voltz, M.Olivier Cerdan* d'avoir accepté d'examiner la thèse.

Je souhaiterais aussi particulièrement remercier *Mme. Dominique Courault, M. Mehrez Zribi, et M. François Charron* pour l'intérêt qu'ils ont porté à mes travaux, et surtout pour avoir apporté leur aide et leurs conseils à chacune de mes sollicitations.

Merci aussi à toutes celles et tous ceux qui ont contribué à ce travail en m'aidant lors des campagnes de terrain : *François Charron, Karim Madashi, Camille le Priol, et Lucie Pauline*.

Mes remerciements s'adressent également à toute l'équipe de la Maison de la Télédétection de Montpellier pour son accueil et son aide. Plus particulièrement, mes collègues *Hani Abdallah, Ibrahim Fayad, Mohammad Merheb, Marc Bouvier, Thomas Milon, Henri Débise, Julie Chaurand, et Christophe Agnès*.

Enfin, j'adresse mes remerciements à *Mar*, ainsi qu'à *ma famille* qui ont toujours été présents à mes cotés et de m'ont soutenu dans ce travail de long haleine.

Table des matières

<i>Liste des abréviations</i>	1
<i>RESUME</i>	2
<i>ABSTRACT</i>	3
<i>Liste des publications</i>	4
1. Articles publiés et sous presses	4
2. Articles en révision	4
3. Congrès nationaux et internationaux	4
3.1 Communications dans des congrès avec texte intégral	4
3.2 Communications orales avec publication d'un résumé	5
<i>CHAPITRE 1: Introduction</i>	6
1. Contexte général	7
2. Etat de l'art	9
2.1 Potentiel des données radar pour le suivi des états hydriques du sol	9
2.2 Potentiel des données optiques à estimer les paramètres de la végétation	11
2.3 Supervision des systèmes irrigués en temps réel	12
3. Problématique	15
4. Démarche	15
4.1 Zone d'étude	15
4.2 Approche générale	16
4.2.1 Description du site d'étude et de la base de données	17
4.2.2 Sensibilité des données radar bande X aux paramètres du sol et de la végétation	17
4.2.3 Potentiel des données radar à estimer l'humidité du sol	17
4.2.4 Intégration des paramètres dérivées de la télédétection dans un modèle de culture	18
4.2.5 Conclusions et perspectives	19
<i>CHAPITRE 2: Description du site d'étude et de la base de données</i>	20
1. Zone d'étude	21
2. Données in situ	22
2.1 Paramètres du sol	22
2.1.1 Humidité du sol	22
2.1.2 Rugosité du sol	24
2.2 Paramètres de la végétation	26
2.2.1 Indice foliaire (LAI)	27

2.2.2 Biomasse, poids sec, et contenu en eau du foin	28
2.2.3 Hauteur du foin	29
2.3 Calendrier d'irrigation, et données météorologique	29
3. Données Satellitaires	29
3.1 Images radar	29
3.2 Images optiques	33
CHAPITRE 3 : Sensibilité des données radar bande X aux paramètres du sol et de la végétation	38
1. Objectifs	39
2. Base de données	39
3. Méthode	39
4. Résultats et discussion	41
4.1 Données mesurées <i>in situ</i>	41
4.2 Sensibilité de NDVI aux paramètres de la végétation	43
4.3 Sensibilité du signal radar aux paramètres du sol et de la végétation	43
4.3.1 Sensibilité du signal radar à l'humidité du sol	43
4.3.2 Détection des activités d'irrigation	43
4.3.3 Sensibilité du signal radar aux paramètres de la végétation	44
5. Conclusions et perspectives	45
Article 1	46

CHAPITRE 4 : Estimation de l'humidité du sol à partir d'images radar en bande X	76
1. Objectifs	77
2. Base de données	77
3. Méthode	77
3.1 Modélisation du signal radar	78
3.2 Génération des données synthétiques	78
3.3 Estimation de l'humidité du sol	80
4. Résultats et discussion	80
4.1 Modélisation du signal radar	80
4.2 Inversion de données synthétiques	81
4.3 Inversion de l'humidité du sol	82

5. Conclusions et perspectives	83
Article 2	84
CHAPITRE 5 : Intégration de paramètres dérivés de la télédétection dans les modèles de culture	125
1. Objectifs	126
2. Base des données	126
3. Méthode	126
3.1 Le modèle PILOTE	126
3.2 Intégration des valeurs LAI optique	128
3.3 Effet de l'incertitude sur les dates des coupes	129
3.4 Effet de l'incertitude sur les dates d'irrigation	130
4. Résultats et discussion	131
4.1 Intégration des valeurs de LAI optique	131
4.2 Effet de l'incertitude sur les dates des coupes	131
4.3 Effet de l'incertitude sur les dates d'irrigation	132
5. Conclusion	132
Article 3	134
CHAPITRE 6 : Conclusions et perspectives	164
1. Synthèse de recherche	165
2. Perspectives de recherche	167
2.1 Couplage radar-radar ou radar-optique pour une meilleure estimation de l'humidité du sol et des paramètres des prairies	167
2.2 Supervision du rendement, et gestion de l'irrigation des systèmes irrigués	168
Annexe 1	171
Liste des figures et des tableaux	177
Bibliographie	184

Liste des abréviations

- **SAR** : Radar à Synthèse d’Ouverture
- **BIO** : Biomasse
- **TDM** : Matière sèche totale
- **VWC** : Contenu en eau de la végétation
- **HVE** : Hauteur de la végétation
- **NDVI** : Indice de végétation par différence normalisé
- **LAI** : Indice foliaire
- **FAPAR** : Fraction de rayonnement solaire absorbée
- **FCOVER** : Fraction du couvert végétal
- **Mv** : Humidité volumique du sol
- **Hrms** : Ecart type des hauteurs
- **L** : Longueur d’autocorrélation
- **RMSE** : Erreur moyenne quadratique
- **MAPE**: Erreur absolue moyenne en pourcentage
- **R²**: Coefficient de corrélation

RESUME

Dans un contexte d'accroissement des tensions sur les ressources en eau, la recherche d'une meilleure productivité agricole de l'eau d'irrigation amène à optimiser les calendriers d'arrosage en fonction des états hydriques des sols et des stades de développement de la culture. La télédétection spatiale permet aujourd'hui de fournir des informations spatialisées en temps quasi-réel sur les caractéristiques du sol et de la végétation. En particulier, les données radar ont montré un fort potentiel pour l'estimation de l'humidité du sol. De même, les données optiques sont utilisées depuis longtemps pour estimer les paramètres relatifs à la végétation (indice foliaire, biomasse, rendement). Ces informations peuvent être intégrées dans des modèles de culture pour simuler en temps réel l'évolution du rendement. L'objectif général de la thèse est de montrer comment les informations issues de la télédétection spatiale à haute résolution spatio-temporelle permettent de retrouver les dynamiques hydriques et végétatives d'un périmètre irrigué. La démarche repose sur des expérimentations menées sur un système de prairies irriguées, avec des observations spatiales et au sol à haute répétitivité temporelle, et l'utilisation d'un modèle de culture.

Le premier volet de la thèse évalue le potentiel des données radar à suivre l'état hydrique d'un sol cultivé. La bande X (3 cm de longueur d'onde) a été choisie puisque les capteurs radar en bande X permettent un suivi des parcelles avec une forte répétitivité temporelle, et des acquisitions à une très haute résolution spatiale (environ 1 m), adaptée à des parcelles de petite taille. Les résultats ont montré que le signal radar en bande X permet de suivre l'évolution de l'humidité du sol même en présence d'un couvert végétal dense. De plus, les résultats ont montré que les données radar sont capables d'identifier les apports d'eau même si l'image radar est acquise trois jours après l'achèvement de l'irrigation.

Le deuxième volet évalue le potentiel du couplage radar-optique pour estimer l'humidité du sol en présence de la végétation. Les résultats ont montré que la polarisation HH combinée avec un paramètre de la végétation, dérivée à partir des données optiques, permet d'estimer l'humidité du sol avec une précision de l'ordre de 5 vol.%. La méthodologie développée dans cette partie de la thèse permet de proposer une approche multi-capteur (optique et radar) pour une cartographie opérationnelle de l'humidité du sol en présence de végétation.

La troisième partie de la thèse étudie le potentiel des données spatiales (radar et optique) pour alimenter un modèle de culture représentant l'évolution de la biomasse en temps réel. Cette partie s'appuie sur le modèle PILOTE, permettant de prédire la sensibilité de la culture au stress hydrique, et d'intégrer des critères de déclenchement des arrosages et de fauche des prairies. Les résultats ont montré que l'intégration dans PILOTE d'informations estimées à partir des données spatiales (LAI, dates des coupes et irrigations) permet de prédire le rendement avec une bonne précision. La pertinence des informations spatiales peut ainsi être analysée en termes de fréquence d'acquisition et de précision des estimations produites, ouvrant des perspectives pour l'application de la télédétection à haute résolution temporelle à la supervision et la gestion des apports d'eau dans les périmètres irrigués.

ABSTRACT

In the context of increasing the pressure on water resources, the search for improved agricultural productivity of irrigation water leads to irrigation schedule optimization according to soil water conditions and crop development stages. Spatial remote sensing currently provides spatialized near real-time information of soil and vegetation characteristics. In particular, radar data, which showed a high potential for estimating soil moisture. Similarly, the optical data have long been used to estimate the vegetation parameters (biomass, yield). Such information can be integrated into crop models to predict yield evolution in real-time. The general aim of the thesis is to show how the information derived from remote sensing data with high spatial and temporal resolution can restore the water and vegetative dynamics of an irrigated perimeter. The approach is based on experiments conducted on a system of irrigated grasslands, with spatial and ground observations at high time repetitiveness, and the use of a crop model.

The first part of the thesis evaluates the potential of radar data for cultivated soil water status monitoring. The X-band (3 cm wavelength) was chosen since X-band radar sensors allow plots monitoring with a high revisit time, and image acquisition at fine spatial resolution (about 1m), adapted to plots with small size. Results showed that the X-band radar signal allows soil moisture evolution monitoring even in the presence of a dense vegetation cover. In addition, results showed that the radar data are able to identify the water supplies even if the radar image is acquired three days after the irrigation event.

The second part evaluates the potential of radar-optical coupling to estimate soil moisture in the presence of vegetation. The results showed that HH polarization combined with one vegetation parameter, derived from the optical data, allow soil moisture estimation with an accuracy around 5 vol.%. The methodology developed in this section of the thesis provides a multi-sensor approach (optical and radar) for operational soil moisture mapping in the presence of vegetation.

The third part of the thesis study the potential of spatial data (radar and optical) to feed a crop model representing real-time biomass evolution. This part is based on the PILOTE model, which allows the prediction of crop sensitivity to water stress, and integrate criteria for irrigation launching and grassland harvest. Results showed that the integration of spatial data information estimates (LAI, harvest and irrigation dates) into PILOTE provides a good accuracy in yield prediction. The relevance of spatial information can then be analyzed in terms of acquisition frequency and accuracy of estimations produced, opening perspectives for the application of high temporal resolution remote sensing for the supervision and management of water supply in irrigated areas.

Liste des publications

Plusieurs aspects développés lors de cette thèse ont fait l'objet de publications dans des revues scientifiques internationales à comité de lecture, et de contributions à des conférences. Une liste des valorisations est donnée par la suite:

1. Articles publiés et sous presses

- **El Hajj M.**, Baghdadi N., Zribi M., Belaud G., Cheviron B., Courault D., and Charron F., 2015. Soil moisture retrieval over irrigated grassland using X-band SAR data. *Remote Sensing of Environment*, vol. 176, pp. 202-218, doi:10.1016/j.rse.2016.01.027.
- Baghdadi N., **El Hajj M.**, Zribi M., and Fayad I., 2015. Coupling SAR C-band and optical data for soil moisture and leaf area index retrieval over irrigated grasslands. *IEEE JSTARS*, vol. xx, no. xx, pp. xx-xx. doi: 10.1109/JSTARS.2015.2464698.
- Baghdadi N., **El Hajj M.**, Dubois-Fernandez P., Zribi M., Belaud G., and Cheviron B., 2015. Signal level comparison between TerraSAR-X and COSMO-SkyMed SAR sensors. *IEEE Geoscience and Remote Sensing Letters*, vol. 12, no.3, pp. 448-452, doi: 10.1109/LGRS.2014.2342733.
- **El Hajj M.**, Baghdadi N., Belaud G., Zribi M., Cheviron B., Courault D., and Charron F., 2014. Irrigated grassland monitoring using a time series of TerraSAR-X and COSMO-SkyMed X-band SAR data, *Remote Sensing*, vol. 6, pp. 10002-10032, doi: 10.3390/rs61010002.

2. Articles en révision

- **El Hajj M.**, Baghdadi N., Cheviron B., Belaud G., Zribi M., 2015. Integration of remote sensing derived parameters in crop models: application to the PILOTE model for hay production. *Agricultural Water Management*, vol. xx, pp. xx-xx, doi: xx.

3. Congrès nationaux et internationaux

3.1 Communications dans des congrès avec texte intégral

- Baghdadi N., **El Hajj M.**, Fayad I., and Zribi M., 2015. Couplage de données radar et optique pour l'estimation de l'humidité du sol et des paramètres de la végétation sur des prairies irriguées. *10th ASAR workshop*, October 20-22, 2015, Québec, Canada
- **El Hajj M.**, Baghdadi N., Zribi M., Belaud G., Cheviron B., Courault D., and Charron F., 2015. Soil moisture retrieval over irrigated grassland using X-band SAR data combined with optical data acquired at high resolution. *International Geoscience and Remote Sensing Symposium 2015 (IGARSS 2015)*, 26 - 31 July 2015, Milan, Italie.

- **El Hajj M.**, Baghdadi N., Belaud G., Zribi M., Cheviron B., Courault D., and Charron F., 2014. Soil moisture retrieval over Grassland using X-band SAR data. *International Geoscience and Remote Sensing Symposium 2014 (IGARSS 2014)*, 13 - 18 July 2014, Quebec, Canada.

3.2 Communications orales avec publication d'un résumé

- **El Hajj M.**, Baghdadi N., Zribi M., Belaud G., Cheviron B., Courault D., Hagolle O., and Charron F., Estimation of soil moisture using radar and optical images over Grassland areas. *EGU General Assembly 2015*, Geophysical Research Abstracts, vol. 17, 12 -17 April 2015, Vienna-Austria.
- Baghdadi N., **El Hajj M.**, Zribi M., Belaud G., Cheviron B., Courault D., and Charron F., 2015. Couplage de données radar et optique pour l'estimation de l'humidité des sols sur des prairies irriguées. *XIIIème Journées Scientifiques du Réseau Télédétection*, 17 - 19 Février 2015, Dakar, Sénégal.
- **El Hajj M.**, Baghdadi N., Belaud G., Zribi M., Cheviron B., Courault D., and Charron F., 2014. Estimation of soil moisture using radar and optical images over Grassland areas. *SPOT4/Take5 User Workshop*, 18 - 19 November 2014, Toulouse, France.

CHAPITRE 1

Introduction

1. Contexte général

En 2050, la population mondiale aura atteint 9 milliards (Manning, 2015). Cette évolution nécessite une augmentation de la production agricole, qui s'accompagne d'une augmentation de la consommation d'eau. Aujourd'hui près de la moitié des besoins alimentaires mondiaux sont couverts par l'agriculture irriguée (Chaumet et al., 2009; Parry, 2007) qui va devoir contribuer à cette augmentation. Dans un contexte d'accroissement du stress hydrique, dû à une raréfaction de la ressource en eau et à une compétition plus sévère pour l'utiliser, le développement et l'optimisation des systèmes hydro-agricoles constituent une des pistes pour satisfaire les besoins agricoles tout en préservant l'environnement. Au Nord comme au Sud, on assiste au retour de grands projets d'aménagement hydro-agricoles. L'objectif principal de ces projets est d'assurer l'eau d'irrigation pour des secteurs agricoles irrigués situés dans des régions agricoles majeures. Ces secteurs agricoles doivent aussi engager d'importantes mutations pour faire face à la fois aux enjeux de partage de l'eau entre les usagers et aux objectifs d'optimisation du rendement agricole.

Le problème de l'allocation des ressources en eau pour les systèmes irrigués se pose à différentes échelles de temps.

- A l'échelle annuelle et pluri-annuelle, il s'agit d'allouer des volumes d'eau en fonction d'objectifs de production globaux (on parle de planification)
- Echelle saisonnière, il s'agit d'ajuster les dotations en eau en fonction de la disponibilité de la ressource (prévisible en fonction de l'état de remplissage des réservoirs dans le sol, par exemple) et des surfaces effectivement en culture
- Court terme, il s'agit d'ajuster des apports d'eau en fonction des conditions locales, des stocks d'eau dans le sol, des cultures et de leur stade de développement réel

C'est principalement à cette dernière dimension que s'intéressera la thèse. Dans des grands périmètres irrigués gravitaires, les efficiencies d'utilisation de l'eau, très faibles, se heurtent à un problème majeur d'adéquation offre/demande au niveau des points de livraison de l'eau. Ce problème est principalement dû à l'absence de stockage d'eau dans les réseaux, les risques étant une insatisfaction des besoins et, à terme, le recours à d'autres ressources (cf., par exemple, dynamiques de surexploitation des aquifères). Pour surmonter ce problème, il est toutefois possible de redéfinir des calendriers d'irrigation assurant une meilleure adéquation offre-demande. L'optimisation du calendrier d'irrigation améliore considérablement l'efficience hydraulique de l'eau prélevée, en particulier lorsque la demande en eau est prévue sur un horizon de quelques heures à quelques jours (Hong et al., 2013). Cette anticipation peut être assurée par la prise en compte des déterminants de l'irrigation, comme l'occupation du

sol, les facteurs climatiques ou les pratiques d'irrigation (Hong et al., 2013; Leenhardt et al., 2004). L'idée de la présente thèse est d'avancer sur la prévision des demandes en eau agricoles, à l'échelle de périmètres irrigués, et à des échelles de temps qui permettent d'assurer une meilleure adéquation offre/demande. Cette prévision repose sur une connaissance affinée des stocks d'eau dans le sol, des stades végétatifs et des pratiques de culture.

L'utilisation des capteurs *in situ* permet de suivre l'état hydrique du sol et l'état de la végétation, et par conséquence d'aider à optimiser la gestion des ressources en eau pour obtenir un rendement optimal. Cette technique est très couteuse et ne peut être réalisée que sur un petit secteur irrigué. On a ici des problèmes de passage d'une information locale (par exemple, une humidité en un point) à une grandeur intégrée à l'échelle d'un réseau (comme un volume utilisé). D'où l'importance de la télédétection spatiale (active et passive) qui permet aujourd'hui d'aller vers une gestion optimisée de l'eau pour un meilleur rendement agricole. En effet, l'imagerie spatiale est capable de fournir des informations spatialisées sur l'état hydrique du sol et les paramètres de la végétation en temps quasi-réel, avec un coût devenu accessible.

Cependant, l'information spatiale n'est pas toujours accessible et pertinente, car le signal transmis par les capteurs (radar et optique) devient saturé, donc inexploitable, quand la végétation devient importante. D'où l'intérêt d'avoir un outil pour suivre en temps réel et à l'échelle inter-parcellaire (information spatialisée), les conditions du sol et de la végétation. En effet, suivre en temps réel le développement de la végétation à l'aide des variables diagnostic correspondantes (i.e., rendement, indice foliaire) est d'une importance primordiale pour les agriculteurs.

Dans une perspective d'anticipation, ou de mise en cohérence d'informations de diverses natures, il est essentiel de s'appuyer sur des modèles capables de prédire l'évolution de la culture en fonction des forçages futurs et des états mesurés. De nombreux modèles de culture ont été développés pour simuler en temps réel principalement le rendement tout le long des cycles végétatifs (Brisson et al., 1992; Mailhol and Merot, 2008; Ritchie and Otter, 1985; Weir et al., 1984). Des mesures terrain des différents paramètres du sol et de la végétation sont toutefois nécessaires pour caler ces modèles dans la perspective d'une meilleure précision sur la prédiction du rendement. Ces mesures présentent souvent des hétérogénéités spatiales en raison de l'histoire du site et de ses utilisations, des caractéristiques environnementales (topographie, climat) et de celles des pratiques d'irrigation. Les données spatiales se révèlent importantes pour enrichir les modèles de culture avec des informations spatialisées pour une meilleure prédiction et un suivi en temps réel du rendement. La validité

de ces informations est une première question à laquelle on doit répondre. Une seconde problématique est de montrer l'effet de l'intégration dans les modèles de culture de ces informations spatiales sur la prédiction du rendement dans les modèles de culture.

Dans ce contexte, la thèse s'appuiera sur deux volets : télédétection et modélisation agricole. Le volet télédétection a pour objectif principal de fournir des informations utiles pour suivre l'état hydrique du sol et les paramètres de la végétation. Quant au volet modélisation, il a pour objectif de montrer l'importance de l'intégration des données spatiales dans les modèles de culture pour suivre en temps réel l'évolution des variables qui conditionnent la prévision du rendement.

2. Etat de l'art

2.1 Potentiel des données radar pour le suivi des états hydriques du sol

Les données SAR (Synthetic Aperture radar) ont été utilisées depuis longtemps pour estimer et cartographier les paramètres physiques du sol (en particulier humidité et rugosité). En cas de sol nu (ou sol avec peu de végétation), l'estimation de l'humidité du sol a été réalisée en utilisant des modèles physiques (par exemple, Integral Equation Model "IEM": Fung *et al.* (1992) ou empiriques (par exemple, modèles de Dubois et Oh : Dubois *et al.*, 1995; Oh, 2004). Contrairement aux modèles physiques, les modèles empiriques nécessitent souvent une calibration en utilisant des mesures *in situ* et des observations SAR acquises sur la zone d'étude. De plus, le domaine de validité des modèles empiriques est limité à la gamme des variations des données utilisées pour l'étalonnage des modèles. La plupart des études sur l'estimation de l'humidité du sol nu ont utilisé des données SAR en bandes X et C, et les résultats montrent une précision sur l'estimation de l'humidité du sol entre 3 et 6 Vol.% (Aubert *et al.*, 2011; Baghdadi *et al.*, 2012a; Srivastava *et al.*, 2003, 2009; Zribi *et al.*, 2005).

La présence de la végétation rend l'inversion du signal radar bien plus compliquée parce que la végétation n'atténue pas seulement le signal rétrodiffusé, mais aussi produit sa propre contribution (He *et al.*, 2014; Srivastava *et al.*, 2011). Donc, en présence de la végétation, le signal total radar rétrodiffusé est le résultat des contributions du sol et de la végétation. La possibilité d'estimer l'humidité du sol en présence de la végétation à partir des images SAR a été largement étudiée en utilisant des données radar en bande C (El-Hajj *et al.*, 2014; Gherboudj *et al.*, 2011; He *et al.*, 2014; Notarnicola *et al.*, 2006; Prévot *et al.*, 1993; De Roo *et al.*, 2001; Sikdar and Cumming, 2004; Wang *et al.*, 2011; Yang *et al.*, 2012; Yu and Zhao, 2011; Zribi *et al.*, 2011). A contrario, très peu d'études ont été réalisées en utilisant des données radar en bande X (Kseneman *et al.*, 2012; Soon-Koo Kweon *et al.*, 2012) ou en bande L (Paloscia *et al.*, 2012; Wigneron *et al.*, 1995).

Les principaux modèles utilisés pour estimer l'humidité du sol en présence de la végétation sont le modèle MIMICS (Michigan Microwave Canopy Scattering) (Ulaby et al., 1990) et le modèle de gouttelettes d'eau (Water Cloud «WC») (Attema and Ulaby, 1978). MIMICS est basé sur le principe théorique du modèle de transfert radiatif de premier ordre, pour simuler la rétrodiffusion radar à partir des paramètres du sol et de la végétation. Dans MIMICS la végétation est décrite en détail (diamètre des tiges et inclinaison des feuilles, entre autres), ce qui permet de mieux quantifier la contribution de la végétation sur le signal radar total rétrodiffusé, et donc une meilleure estimation de l'humidité du sol. Cependant, MIMICS est compliqué à utiliser, et nécessite un grand nombre des paramètres d'entrée. Pour cela, la plupart des études ont utilisé le modèle WC car il est relativement simple et ne nécessite que peu de variables d'entrée (Gherboudj et al., 2011; Prévot et al., 1993; De Roo et al., 2001; Sikdar and Cumming, 2004; Soon-Koo Kweon et al., 2012; Wang et al., 2011; Yang et al., 2012; Yu and Zhao, 2011; Zribi et al., 2011).

Dans le modèle WC, le signal radar total rétrodiffusé est modélisé comme la somme des contributions de la végétation et du sol, cette dernière atténuee par la végétation. La contribution de la végétation (rétrodiffusion directe et atténuation) est calculée en utilisant principalement un seul paramètre biophysique (soit la biomasse, soit la hauteur, soit le contenu en eau, soit l'indice foliaire) représentant l'effet de la végétation. La contribution du sol est calculée en fonction de l'humidité et de la rugosité du sol. Pour des images radar mono-bande (une incidence et une polarisation), les données optiques sont toutefois nécessaires pour inverser le signal radar en utilisant le modèle WC. En effet, les données optiques sont complémentaires des données radar, et leur intérêt réside dans leur sensibilité aux paramètres physiques de la végétation. Dans le modèle WC, ces paramètres permettent d'évaluer la contribution de la végétation sur le signal radar, et pour pouvoir ensuite inverser la contribution du sol et estimer l'humidité du sol. D'où l'importance du couplage entre les données optique et radar pour une meilleure estimation de l'humidité du sol (Fieuza et al., 2011; He et al., 2014; Hosseini and Saradjian, 2011; Notarnicola et al., 2006; Prakash et al., 2012). Enfin, pour des images radar multi-bandes (deux incidences, deux polarisation, deux bandes), des études ont montré, en utilisant le modèle WC, le potentiel des données radar seules (souvent multi-longueurs d'onde) à estimer l'humidité du sol avec végétation (Paloscia et al., 2012; Prévot et al., 1993).

Plusieurs études ont utilisé le modèle WC pour estimer l'humidité du sol en présence de la végétation. Les résultats montrent une précision sur l'humidité variant entre 2 et 8 Vol.%. Prévot *et al.* (1993) ont combiné des données radar en bandes C et X pour estimer l'humidité du sol de parcelles de blé (LAI du blé entre 0.1 et 8 m²/m²). La précision sur l'estimation de l'humidité du sol était 6.5 Vol.%. Une précision similaire a été obtenue par Zribi *et al.* (2011)

en utilisant des images ASAR (bande C) acquises sur des parcelles de blé (LAI entre 0.01 et $3.7 \text{ m}^2/\text{m}^2$). Kweon *et al.* (2012) ont estimé l'humidité du sol de parcelles de soja en utilisant des données SAR en bande X avec une précision de 3 Vol.% (VWC "contenu en" eau et LAI "indice foliaire" atteint 1.8 kg/m^2 et $4.5 \text{ m}^2/\text{m}^2$, respectivement). He *et al.* (2014) ont combinés des données radar (C-HH et V-VV) et optiques pour estimer l'humidité du sol. Les résultats ont montré une précision d'environ 3 Vol.%. Gherboudj *et al.* (2011) ont combiné les modèles "WC" et "Oh" pour estimer l'humidité du sol avec végétation (blé, pois, lentilles, jachères, pâturages et canola) à partir des données radar 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. Finalement, De Roo *et al.* (2001) ont utilisé le modèle MIMICS en conjonction avec le "modèle Oh" pour estimer l'humidité du sol de parcelles de soja (avec VWC entre 0.02 et 0.97 kg/m^2) à partir des données polarimétrique en bandes C et L. La précision des estimations d'humidité du sol était d'environ 2 Vol.%.

2.2 Potentiel des données optiques à estimer les paramètres de la végétation

Les données optiques dans le domaine du visible et de l'infrarouge ont montré un grand potentiel à cartographier les paramètres biophysiques de la végétation dans le cas des grandes cultures : blé, prairies, maïs, riz, soja et luzerne (Baret and Guerif, 2006a; Baret *et al.*, 2007; Bsaibes *et al.*, 2009; Chen *et al.*, 2005; Courault *et al.*, 2008, 2010; Edirisinghe *et al.*, 2011; Ferreira *et al.*, 2013; Gao, 1996; Gu *et al.*, 2007; Jackson *et al.*, 2004; Payero *et al.*, 2004; Schino *et al.*, 2003; Serrano *et al.*, 2000; Todd *et al.*, 1998). Les paramètres biophysiques de la végétation peuvent être obtenus à partir des données optiques en utilisant des modèles physiques ou empiriques. Les modèles physiques (par exemple, PROSAIL, SAFY, BV-NET) inversent les réflectances optiques pour estimer les paramètres biophysiques de la végétation, comme la teneur en chlorophylle des feuilles (Botha *et al.*, 2007, 2010), la teneur en eau des feuilles (Ceccato *et al.*, 2001; Yang and Ling, 2004), la biomasse (Fieuzal *et al.*, 2011), l'indice foliaire (LAI), la fraction de rayonnement solaire absorbée (FAPAR) et la Fraction du Couvert (FCOVER) (Baret *et al.*, 2007; Darvishzadeh *et al.*, 2008a; Goel and Strelbow, 1983; North, 2002; Pickett-Heaps *et al.*, 2014). La plupart des modèles empirique sont basés sur l'inversion des relations directes établies entre l'indice de végétation normalisé (NDVI) et les paramètres biophysiques de la végétation mesurés, comme le LAI (Baret and Guerif, 2006a; Baret *et al.*, 2007; Bsaibes *et al.*, 2009; Courault *et al.*, 2008, 2010), la biomasse (Edirisinghe *et al.*, 2011; Ferreira *et al.*, 2013; Schino *et al.*, 2003; Todd *et al.*, 1998), le contenu en eau (Chen *et al.*, 2005) ou la hauteur de la végétation (Payero *et al.*, 2004).

Schino *et al.* (2003) and Payero *et al.* (2004) ont comparé différents indices de végétation et constaté que le NDVI fournit une meilleure précision sur l'estimation de la biomasse et la hauteur de pâturage. D'autres études ont utilisé la teneur en eau par différence normalisée (NDWI), qui est calculé en utilisant le proche infrarouge et l'infrarouge court (SWIR) pour estimer le contenu en eau de la végétation (VWC) (Chen *et al.*, 2005; Gao, 1996; Gu *et al.*, 2007; Jackson *et al.*, 2004; Serrano *et al.*, 2000). Chen *et al.* (2005) ont montré que le NDVI et le NDWI permettent d'estimer le VWC de soja et de maïs avec la même précision. Gu *et al.* 2007 ont constaté que le NDWI est plus sensible aux conditions de sécheresse du pâturage que le NDVI. L'utilisation du NDVI et du NDWI pour estimer les paramètres biophysiques de la végétation est limitée en raison de la saturation des valeurs des deux indices lorsque la végétation est haute ou très dense. Par exemple, Payero *et al.* (2004) ont montré que le NDVI sature lorsque la hauteur de la luzerne a dépassé 40 cm et Anderson *et al.* (2004) ont montré que le NDVI et le NDWI saturent lorsque le LAI du maïs et du soja a dépassé 3.5 m²/m² et 4.5 m²/m², respectivement.

2.3 Supervision des systèmes irrigués en temps réel

Dans les dernières décennies, de nombreux modèles de culture ont été développés pour simuler le développement d'une culture, en tenant compte de divers forçages, comme ceux liés au climat, aux pratiques culturales, aux apports d'eau. Il existe divers degrés de complexité de ces modèles, entre les approches simplifiées de la FAO (Allen *et al.*, 1998) et des approches basées sur une description fine des processus comme le STICS, CERES, WOFOST (Brisson *et al.*, 2003; Jones *et al.*, 2003; Pogačar and Kajfez-Bogataj, 2009), le plus souvent pour des cultures de blé, maïs, ou encore prairies (Brisson *et al.*, 1992; Mailhol and Merot, 2008; Ritchie and Otter, 1985; Weir *et al.*, 1984).

Un modèle de culture est constitué d'un ensemble d'équations décrivant la croissance des composants végétaux tels que les feuilles, les racines, les tiges et les fruits, généralement à un pas de temps journalier (Oteng-Darko *et al.*, 2013). Les modèles de culture ont besoin de plusieurs paramètres d'entrée, liées au sol (par exemple, la capacité au champ), à la végétation (par exemple, l'indice foliaire maximal) ou aux options de gestion de l'irrigation (par exemple, date de semis, dates et doses d'irrigation, date de récolte). Ils ont aussi besoin de forçages climatiques (par exemple la précipitation, le rayonnement, la température de l'air, l'évapotranspiration potentielle). Ces entrées sont généralement enregistrées à l'aide des capteurs *in situ* situés à des endroits fixes sur les zones cultivées. L'inconvénient de certaines mesures ponctuelles issues des capteurs *in situ* est qu'elles ne sont pas extensibles ni dans le temps et ni dans l'espace.

Ces modèles, une fois calés, ont aidé à définir les options pertinentes pour l'irrigation (doses appliquées, fréquence et durée des irrigations) ainsi que les pratiques agricoles (date de semis, date de coupe) convenables pour avoir un rendement optimal en termes de quantité et de qualité. En effet, les dates des récolte, les dates d'irrigation, la fréquence de l'irrigation, et les doses appliquées sont les paramètres d'entrée connus pour avoir une grande influence sur la prédition du rendement par les modèles (Courault et al., 2010). De plus, comme les modèles de culture prédisent un certain nombre de variables d'état (évaporation et teneur en eau du sol, indice foliaire, quantité de matière sèche), l'observateur qui dispose d'informations indépendantes sur ces variables pourrait les utiliser pour contraindre et améliorer les prédictions des modèles.

La télédétection a été largement utilisée pour fournir des valeurs spatialement distribuées de certains paramètres du sol, de la végétation, et de la gestion (par exemple, dates de coupes). En particulier, les données radar et optique ont été suffisamment utilisées pour estimer l'humidité surfacique du sol, et les paramètres de la végétation, respectivement. Avec les dernières avancées technologiques en télédétection, il est devenu possible de disposer des images radar et optique à très hautes résolutions spatio-temporelles. Pour faire le meilleur usage de cette large disponibilité des images spatiales, on peut chercher à identifier la répétitivité temporelle minimale des informations spatialisées nécessaire pour contraindre utilement le modèle de culture.

L'incertitude sur la prédition des modèles de culture est liée d'abord aux incertitudes associées aux paramètres d'entrée (par exemple, LAI initial et maximal, densité de semis, dates de coupe, dates d'irrigation). Elle est aussi liée à la formulation choisie pour les équations du modèle qui décrivent les processus physiques du sol (par exemple, évaporation), de la végétation (par exemple, développement des feuilles) et de l'interaction sol-végétation (par exemple, stress hydrique). Pour minimiser l'effet de ces incertitudes, de nombreuses études ont intégré des informations provenant de données de télédétection (Bach, 1998; Bouman, 1995; Choudhury, 1997; Claverie et al., 2013; Courault et al., 2010; Di Bella et al., 2005; Duchemin et al., 2006, 2008; Fieuza et al., 2011; Hadria et al., 2009; Maas, 1988). La plupart des études intègrent dans les modèles de culture des valeurs de LAI dérivées des données optiques en utilisant la technique d'assimilation ou "steering function" (Bouman et al., 1997).

La technique d'assimilation a pour objectif d'ajuster la variable simulée en utilisant la même variable, inversée à partir de données observées. Cet ajustement s'effectue en utilisant différentes méthodes telles que le forçage, et le filtre de Kalman. Le forçage consiste à remplacer la valeur de variable simulée par celle de variable inversée. Le filtre de Kalman

produit une estimation optimale de la variable à assimiler, entre la valeur simulée et la valeur inversée. La technique "steering function" est une alternative qui consiste à ré-estimer certains paramètres du modèle de culture. Ceci peut être réalisé en couplant le modèle de culture avec un modèle de transfert radiatif à travers des variables prédictes par le modèle de culture. Les variables prédictes par le modèle de culture sont les paramètres d'entrée pour le modèle de transfert radiatif.

Thorp *et al.* (2010) ont montré que l'assimilation (par forçage, et mécanisme de mise à jour) des valeurs de LAI dérivées des données optiques dans le modèle de culture DSSAT-CSM-WHEAT n'améliore pas la précision sur le rendement de maïs prédis. La même conclusion a été obtenue dans l'étude de Courault *et al.* (2010) en assimilant (par forçage) dans le modèle STICS des valeurs de LAI optique interpolées à un pas de temps journalier. Ines *et al.* (2013) ont également assimilé (avec un filtre de Kalman) des valeurs d'humidité du sol dérivées des données radar et des valeurs de LAI issues des capteurs optiques MODIS dans le modèle de culture DSSAT-CSM-Maize pour améliorer la précision sur la prédiction du rendement du maïs (rendement moyen *in situ* de 11.12 t/ha avec un écart-type de 0.70 t/ha). Les résultats ont montré qu'assimiler séparément l'humidité du sol et le LAI diminue l'erreur moyenne quadratique (RMSE) sur l'estimation du rendement de 0.5 t/ha (RMSE passe de 4.7 à 4.2 t/ha) et 1.1 t/ha (RMSE passe de 4.7 à 3.6 t/ha), respectivement. De plus, l'assimilation de l'humidité du sol et du LAI à la fois diminue bien plus le RMSE sur le rendement prédit, de 4.7 à 2.9 t/ha. Vazifedoust *et al.* (2009) ont montré que l'assimilation (filtre de Kalman) des valeurs de LAI et de l'évapotranspiration dérivées des données optiques dans le modèle de culture SWAP-WOFOST réduit de façon significative l'erreur sur le rendement du blé prédict (erreur relative de la matière sèche totale prédict est d'environ 10%, en comparaison à la matière sèche totale mesurée).

De plus, plusieurs études ont combiné des modèles de culture et des modèles de transfert radiatif en utilisant la technique de « steering function » (Launay and Guerif, 2005; Ma *et al.*, 2013; Prévot *et al.*, 2003). Launay and Guerif (2005) ont assimilé des données optiques dans le modèle de culture SUCROS pour ré-estimer certains paramètres du modèle qui varient dans l'espace. Le modèle de culture SUCROS a été couplé avec le modèle de transfert radiatif «SAIL» à travers les valeurs de LAI prédictes par SUCROS pour simuler les réflectances optiques et ensuite calculer l'indice TSAVI (*Transformed Soil Adjusted Vegetation Index*). La différence entre le TSAVI simulé par SUCROS couplé avec SAIL et TSAVI calculé à partir des données optiques a été minimisée pour ré-estimer les paramètres du modèle. Les résultats ont montré que l'erreur moyenne quadratique (RMSE) sur l'estimation du rendement de la betterave à sucre passe de 13.0 à 9.7 kg/ha (rendement *in situ* rendement est entre 40 et 100 kg/ha). Une approche similaire pour l'assimilation des données de télédétection a été adoptée

dans l'étude de Prévot *et al.* (2003) en utilisant le modèle STICS couplé avec un modèle de transfert radiatif. Les résultats ont montré une amélioration significative des valeurs de LAI prédictes pour le blé (RMSE réduit de 0.63 à 0.16 m²/m²), tandis qu'une faible amélioration a été observée sur l'estimation du rendement (RMSE réduit de 1.9 à 1.6 t/ha, pour des rendements *in situ* entre 1 et 15 t/ha). Enfin, Ma *et al.* (2013) ont assimilé le produit MODIS-LAI dans le modèle de WOFOST pour réduire le RMSE sur le rendement du blé d'hiver d'environ de 0.98 à 0.47 t/ha (pour des rendements mesurés *in situ* entre 5 et 6 t/ha).

3. Problématique

La problématique principale de la thèse porte sur le potentiel des données spatiales à fournir des informations pertinentes (en termes de précision, et répétitivité temporelle) pour alimenter les modèles de culture, en vue d'un suivi fiable en temps réel des secteurs agricoles irrigués. Dans des périmètres irrigués, il existe une forte hétérogénéité des états hydriques du sol et de la végétation, compte tenu des pratiques d'irrigation variables d'une parcelle à l'autre.

Une première question concerne le potentiel des données spatiales à fournir des informations sur les états hydriques du sol et de la végétation, avec une précision pertinente pour la supervision et la gestion des systèmes irrigués. En particulier, est-ce que les capteurs spatiaux (radar et optiques) actuels et à venir permettent d'estimer les paramètres du sol et de la végétation même en présence d'un dense couvert végétal, et donc de surmonter des problèmes d'atténuation liés à la présence de végétation ?

Au-delà de la qualité des informations fournies par un capteur spatial, on peut s'interroger sur le lien entre la fréquence temporelle de ces informations et leur précision, dans une perspective d'évaluation des flux d'eau et de production agricole dans un système irrigué. Plus précisément, nous chercherons comment intégrer l'information spatiale à haute résolution spatio-temporelle dans les modèles de culture, quelle fréquence d'acquisition est pertinente, quelle précision on peut attendre des informations spatiales pour la prédiction des rendements et des flux d'eau d'irrigation.

4. Démarche

4.1 Zone d'étude

Pour aborder la problématique de la thèse, nous choisissons un système irrigué par gravité (type d'irrigation le plus répandu, avec plus de 80% des surfaces irriguées, <http://www.fao.org/nr/water/aquastat/dbase/indexfra.stm>), de taille moyenne permettant d'aborder la variabilité inter-parcellaire. Ce mode d'irrigation, comme la plupart des systèmes

irrigués par aspersion, se caractérise par des apports conséquents, remplissant la réserve utile, à chaque arrosage, les quantités d'eau apportées dépendant alors essentiellement des calendriers d'arrosage contraints par des tours d'eau.

La zone d'étude est située dans la région de la Crau. C'est une zone plate de 52000 ha située au Sud Est de la France (43.61 N ; 4.9891 E). Sur ce site, on trouve principalement de la prairie irriguée (12000 ha) en gravitaire et des zones non irriguées accueillant l'hiver des troupeaux de brebis, ainsi que des zones humides alimentées par des rejets des réseaux d'irrigation. Il y a également un peu d'oliviers, des vignes et des pêchers irrigués, ainsi que quelques parcelles de maraîchage. Le climat de la Crau est méditerranéen avec une précipitation irrégulière, et une longue période de sécheresse s'étalant typiquement du printemps à la fin de l'été. L'étude se focalisera sur un secteur des prairies irriguées de 150 ha, au sein du Domaine du Merle, domaine expérimental de SupAgro. Sur ce secteur les règles d'irrigation sont connues (Thèse d'Anne Mérot: Mérot, 2007) et le système d'irrigation a été déjà étudié dans plusieurs travaux (Hong, 2014).

4.2 Approche générale

La thèse est construite à l'interface entre télédétection et modélisation de culture. L'importance des données spatiales réside dans leur potentiel à fournir des informations spatialement reparties, avec une haute répétitivité temporelle, sur l'état hydrique du sol et les paramètres de la végétation. Ces informations permettent d'enrichir les modèles de culture. A leur tour, les modèles de culture permettent une meilleure gestion des pratiques agricoles pour obtenir un rendement optimal. De plus, les modèles de culture permettent de prédire en temps réel les conditions du sol et de la végétation, en particulier le rendement. Il est donc d'abord nécessaire de montrer la pertinence des données dérivées des données spatiales, pour ensuite étudier l'effet de l'intégration de ces données dans des modèles de culture.

Ce document de thèse est constitué de plusieurs parties qui montrent les démarches suivies pour répondre aux problématiques de recherche. La première partie décrit principalement la base des données. La deuxième et la troisième partie portent principalement sur la pertinence des données SAR pour le suivi et l'estimation de l'humidité du sol en présence de la végétation. La quatrième partie analyse le potentiel des données SAR et optiques pour alimenter et contraindre les modèles de culture. Enfin, la cinquième partie présente les conclusions et les perspectives.

4.2.1 Description du site d'étude et de la base de données

Ce chapitre présente une description du site d'étude et de la base de données composée des mesures *in situ*, et des données spatiales (radar et optique). Le site d'étude est présenté pour commencer, puis le protocole des mesures de terrain est décrit (humidité du sol, rugosité du sol, biomasse, matière sèche totale, contenu en eau, hauteur, indice foliaire, fraction de rayonnement solaire absorbée, et fraction du couvert végétal). Enfin, les acquisitions SAR et optiques sont également présentées.

4.2.2 Sensibilité des données radar bande X aux paramètres du sol et de la végétation

Après une revue bibliographique sur la sensibilité du signal radar aux paramètres du sol et de la végétation, nous pouvons constater que très peu d'études ont analysé la sensibilité des données radar en bande X à l'état hydrique du sol en présence de la végétation. Ce chapitre porte principalement sur le potentiel des données radar à suivre l'état hydrique du sol et les paramètres de la végétation. Ce chapitre résume les principaux résultats détaillés dans le papier publié dans Remote Sensing « **Irrigated grassland monitoring using a time series of terraSAR-X and COSMO-skyMed X-Band SAR Data** » (El Hajj et al., 2014).

Dans ce chapitre, la sensibilité du signal radar à l'évolution de l'humidité du sol est étudiée tout le long des cycles végétatifs. Les effets de la polarisation radar et des paramètres de la végétation sur la sensibilité du signal radar à l'humidité du sol sont discutés. Le potentiel de ces données SAR à suivre les pratiques d'irrigation est également analysé. Finalement, la sensibilité des données radar aux paramètres de la végétation est également discutée.

Sur zone d'étude, la hauteur moyenne de la végétation commence à dépasser 60 cm un mois environ après la coupe, la durée des cycles de culture étant comprise entre 50 et 70 jours. Comme nous nous attendons à des difficultés pour estimer l'humidité du sol quand la végétation atteint une forte hauteur, une des questions de recherche à traiter est: « est-ce que le signal radar en bande X reste sensible à l'état hydrique du sol (humidité et eau à l'état libre) lorsque la culture est mature?».

4.2.3 Potentiel des données radar à estimer l'humidité du sol

Ce chapitre est axé sur le développement d'une méthode opérationnelle pour estimer et cartographier l'humidité du sol en présence de la végétation à partir d'un couplage d'images radar en bande X et optiques dans le visible et proche infra-rouge. Ce chapitre résume les principaux résultats détaillés dans le papier publié dans à Remote Sensing of Environment « **Soil moisture retrieval over irrigated grassland using X-band SAR data.** » (El Hajj et al., 2015).

Pour estimer l'humidité du sol, une technique d'inversion basée sur les réseaux de neurones a été développée en utilisant des données réelles, mais aussi des données simulées à partir du modèle WC étalonné sur notre site d'étude. Des données radar synthétiques générées à partir du modèle WC étalonné ont été utilisées pour entraîner les réseaux de neurones. Ensuite, les réseaux de neurones entraînés sont utilisés pour inverser le signal radar de la base de données réelles et estimer ainsi l'humidité du sol. Différentes configurations d'inversion sont analysées avec en entrée aux réseaux de neurones le signal radar (HH, HV, ou HH+HV) et une variable de la végétation estimée à partir des données optiques (NDVI, LAI, FAPAR, ou FCOVER).

Dans la phase d'étalonnage de WC, nous avons utilisé des mesures *in situ* caractéristiques de la végétation et de l'humidité du sol pour estimer les paramètres du modèle WC. Dans la cadre de la thèse, plusieurs caractéristiques de la végétation ont été collectées *in situ* (BIO, VWC, HVE, LAI, FAPAR, et FCOVER) en plus de l'indice NDVI calculé à partir des images optiques. Une première investigation de cette partie de thèse est de déterminer la variable qui permet de mieux représenter l'effet de la végétation dans le modèle WC. De plus, une seconde investigation est d'évaluer le potentiel des données radar en bande X à estimer l'humidité du sol en présence de la végétation et de fournir la précision associée.

Ce travail permettra de proposer une approche multi-capteurs (optique et radar) pour une cartographie opérationnelle de l'humidité du sol en présence de la végétation.

4.2.4 Intégration des paramètres dérivées de la télédétection dans un modèle de culture

Ce chapitre aborde le potentiel des données spatiales à alimenter les modèles de culture sans affecter la précision sur le rendement prédictif. Ce chapitre résume les principaux résultats détaillés dans le papier soumis en attente d'une décision finale à Agricultural Water Management « *Integration of remote sensing derived parameters in crop models: application to the PILOTE model for hay production* » (El Hajj et al., **révisions mineurs**).

Dans ce chapitre le modèle de croissance de culture PILOTE développé et validé sur les prairies irriguées de notre site d'étude a été utilisé. L'intégration dans PILOTE des variables estimées à partir des données spatiales est analysée. Deux variables qui pourraient être estimées à partir des données optiques (LAI et dates des coupes) et une variable obtenue à partir des données radar (dates d'irrigations) ont été discutées. Cette partie de la thèse permettra de fournir des conclusions sur la pertinence ou pas de la résolution temporelle des capteurs spatiaux disponibles (radar et optique) pour contraindre et améliorer les prédictions livrées par les modèles de culture.

4.2.5 Conclusions et perspectives

Ce chapitre détaille les conclusions et les limites des différentes parties de la thèse. Des perspectives de nouvelles recherches sont ensuite proposées.

CHAPITRE 2:

Description du site d'étude et de la base de données

Ce chapitre présente le site d'étude et la base de données utilisée dans cette thèse. Cette base de données est composée de mesures in situ des paramètres du sol et de la végétation, et des images spatiales radar et optique.

1. Zone d'étude

Le site d'étude est situé dans la région de la Crau au Sud-Est de la France (centré à 43.64°N, 5.01°E) (Figure 1). Ce site est un domaine expérimental de SupAgro, le Domaine du Merle. La superficie totale est de 400 hectares environ, dont 150 hectares environ sont des prairies irriguées pour la production de foin. Le foin produit est certifié (avec le label français "AOP : Appellation d'Origine Protégée") grâce aux facteurs environnementaux spécifiques et les pratiques d'irrigation qui assurent une composition floristique de haute qualité.

Le site d'étude est caractérisé par un climat méditerranéen, avec une saison des pluies entre Septembre et Novembre. Le cumul pluviométrique enregistré sur le site d'étude atteint 457.5 mm en 2013, et a varié entre 350 mm et 800 mm au cours des 20 dernières années. La température moyenne de l'air est d'environ 8°C en hiver et 24°C en été. Le taux d'évaporation peut atteindre 10 mm/jour pendant l'été en raison des températures élevées associées à des conditions sèches et venteuses.

Le sol a une capacité de rétention moyenne avec des racines de la végétation concentrées dans les premiers 30 cm du sol. La capacité de rétention est un paramètre du sol qui représente le volume d'eau retenue dans un sol qui ne coule pas sous l'action de la gravité. De plus, la surface du sol est caractérisée par une absence ou faible présence des galets (15%-20% du caillou au plus). La texture du sol est limoneuse avec une profondeur variant entre 30 cm et 80 cm, dépend de l'âge de la parcelle (entre 10 ans et trois siècles).

Les parcelles ont été nivelées avec une pente très douce qui permet l'irrigation par gravité (irrigation par ruissellement). Le débit total disponible pour le site (entre 150 et 300 l/s) permet d'irriguer une ou deux parcelles simultanément. L'irrigation des parcelles a toujours lieu entre Mars et Septembre. Les procédures d'irrigation consistent en premier temps à remplir grâce à une vanne le canal frontal construit en amont de la parcelle. Ensuite, l'eau ruisselle par gravité vers l'aval de la parcelle. Lorsque le front de l'eau ruisselé arrive près de l'extrémité aval de la parcelle, l'irrigation est arrêtée (vanne amont fermée). Le front de l'eau continue à couler et s'infiltrer pour atteindre l'aval de la parcelle. A l'aval, l'excédent d'eau ruisselé est évacué à travers un canal de drainage. Une rotation est appliquée de telle sorte que toutes les parcelles puissent être irriguées, si besoin, environ tous les 10 jours en moyenne. Le mode d'irrigation assure un remplissage de la réserve utile à chaque irrigation. Finalement, les parcelles sont coupées trois fois par an, en mai, juin et septembre.

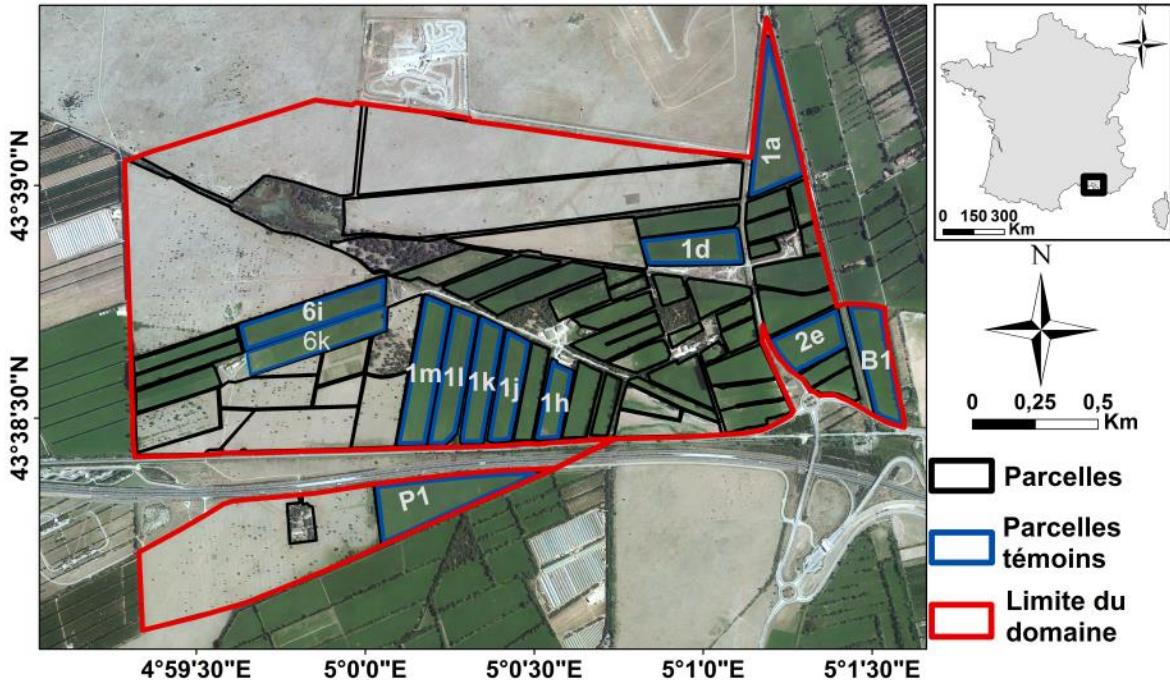


Figure 1. Site d'étude « Domaine du Merle ». En noir toutes les parcelles du domaine. En bleu les parcelles témoins. En rouge la limite du domaine.

2. Données in situ

La base de données in situ est composée des mesures terrain des paramètres du sol et de la végétation. 34 missions terrain ont été réalisées en 2013 dans 12 parcelles témoins (*Figure 1*). Les paramètres du sol sont l'humidité et la rugosité. Les paramètres de la végétation sont l'indice foliaire (LAI), biomasse (BIO), matière sèche totale (TDM), contenu en eau (VWC), et hauteur (HVE).

2.1 Paramètres du sol

2.1.1 Humidité du sol

L'humidité volumique du sol (M_v) est le volume d'eau contenu dans un échantillon du sol divisé par son volume total. Il existe plusieurs méthodes pour mesurer l'humidité du sol, comme la méthode gravimétrique, la mesure par TDR (Time Domain Reflectometry)

La méthode gravimétrique consiste à mesurer en premier temps l'humidité pondérale d'un échantillon du sol prélevé à l'aide d'un cylindre. L'humidité pondérale W_p (%) ou g^{-1}/g^{-1}) est calculé en utilisant le poids humide (Ph : poids du sol après prélèvement) et le poids sec (Ps).

Le poids sec (P_s) est obtenu en séchant l'échantillon du sol prélevé avec une température de 105 °C pendant 24 h.

$$W_p (\%) = 100 \left[\frac{Ph - Ps}{Ps} \right]$$

D'où :

Ph = poids humide

$$Ps = \text{poids sec} \quad \text{Eq.1}$$

Ensuite, l'humidité pondérale en pourcent (W_p en %) est convertie en humidité volumique (M_v en Vol.%) en multipliant W_p (%) par la densité apparente de l'échantillon du sol prélevée (D_a) :

$$M_v (\text{Vol.}\%) = D_a \ Wp (\%)$$

Où $D = Ps / \text{volume de cylindre utilisé pour prélever le sol (g/cm}^3)$

Eq.2

La méthode de mesure de l'humidité par gravimétrie est considérée comme la plus précise mais elle nécessite beaucoup d'efforts et du temps pour récolter les échantillons du sol. Pour cette raison, l'humidité volumique du sol a été mesurée à l'aide d'une sonde Tethaprobe calibrée (*Figure 2*). La figure 2 montre la droite de calibration de Tethaprobe établie en exprimant des mesures Thetaprobe en fonction des mesures gravimétriques. Les mesures d'humidité ont été effectuées dans les premiers 5 cm puisque la profondeur de pénétration de l'onde radar (bande X) dans le sol est de quelques centimètres (Ulaby et al., 1986). L'humidité volumique du sol en surface (5 premiers cm) est un paramètre dynamique dans le temps et l'espace, surtout dans les zones irriguées. Pour cela, les données d'humidité volumique sont collectées simultanément à l'acquisition radar (± 2 heures par rapport à l'heure d'acquisition radar), et chaque mesure d'humidité est positionnée à l'aide d'un GPS (Handy GPS, précision 2 m). Entre 25 à 30 mesures d'humidité sont effectuées dans chaque parcelle (*Figure 3a*).

Pour chaque parcelle, les 25-30 mesures de M_v sont moyennées pour représenter l'humidité de la parcelle (dans le cas d'une humidité homogène dans la parcelle). Cependant, si l'humidité n'est pas homogène les valeurs de M_v sont moyennées sur des sous-zones homogènes à l'intérieur de la parcelle. La valeur de M_v d'une parcelle varie entre 10 Vol.% (non-irrigué

depuis une dizaine de jours) et jusqu'à environ 50 Vol.% (quelques heures après irrigation), avec un écart-type entre ± 1 et ± 5 Vol.%.

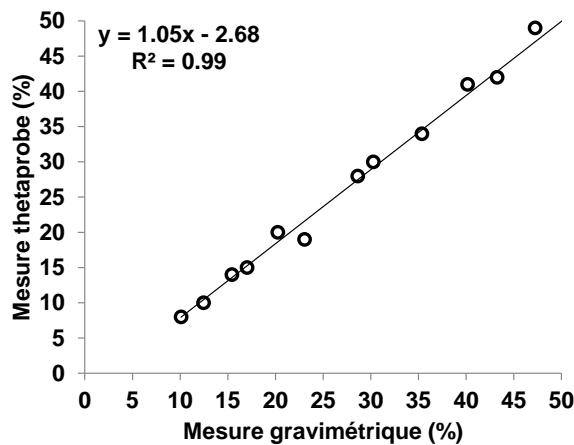


Figure 2. Courbe de calibration de Theta probe. Cercles noir représentent les mesures d'humidité

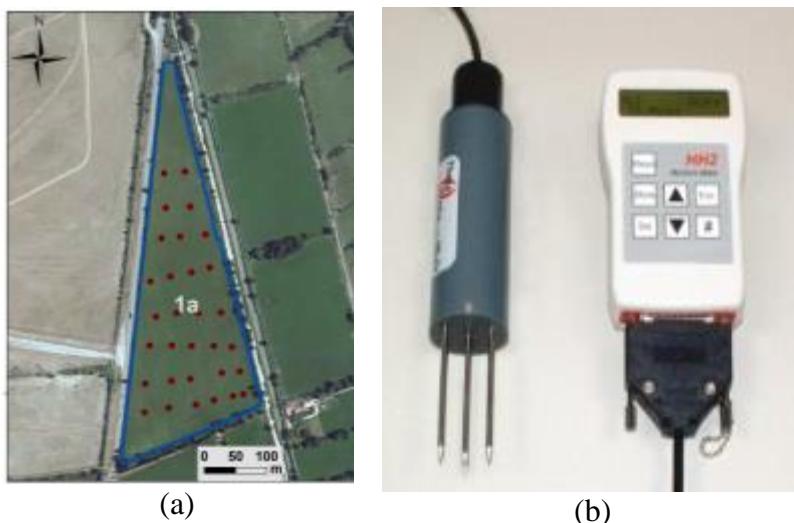


Figure 3. (a) Mesures d'humidité sur une parcelle témoin (1a), les points rouges représentent le positionnement des mesures d'humidité, ici 30 mesures. (b) l'instrument Thetaprobe.

2.1.2 Rugosité du sol

La rugosité est un paramètre qui décrit la microtopographie du sol. Quand le signal radar transmis interagit avec une surface rugueuse, l'énergie de l'onde est réfléchie dans toutes les directions et en particulier dans la direction du radar. Les mesures de rugosité ont été réalisées après une période de coupe pour minimiser la gêne due à la végétation. Pour chaque parcelle, la rugosité est mesurée à l'aide d'un profilomètre à aiguilles (*Figure 4*). Le profilomètre est de 1 m de long avec un espacement entre les aiguilles de 2 cm. Nous avons réalisé dix mesures

sur chaque parcelle témoin (5 mesures réalisées dans le sens de la longueur et 5 mesures dans le sens de la largeur). Les clichés des profils réalisés (*Figure 4*), sont ensuite digitalisés pour calculer deux paramètres : l'écart-type des hauteurs ($Hrms$), et la longueur de corrélation (L).

L'écart type des hauteurs ($Hrms$: Height root mean square) décrit la variation verticale de la rugosité du sol. Ce paramètre est calculé comme la variation moyenne des irrégularités de la surface par rapport à une surface plane :

$$Hrms^2 = \langle (z(x) - \langle z \rangle)^2 \rangle \quad \text{Eq.3}$$

où :

$z(x)$ est la hauteur au point x

$\langle z \rangle$ est la hauteur moyenne des points de profil

La longueur d'autocorrélation (L) est mesurée en complément de $Hrms$ pour décrire la rugosité du sol. La longueur d'autocorrélation décrit la variation horizontale de la rugosité du sol. L correspond à la distance à partir de laquelle les différents points de la surface ne sont plus corrélés. L est calculée grâce à une fonction ($\rho(u)$) décrivant les relations entre les altitudes de deux points de la surface écartés d'une distance « u » (fonction d'autocorrélation):

$$\rho(u) = \frac{\langle \{(z(x+u) - \langle z \rangle)\} \cdot \{z(x) - \langle z \rangle\} \rangle}{Hrms^2} \quad \text{Eq.4}$$

La fonction d'autocorrélation prend la forme d'une exponentielle en cas des sols lisses et gaussienne en cas des sols rugueux (Altese et al., 1996; Oh et al., 1992; Rakotoarivony, 1995; Ulaby et al., 1982).

Pour chaque profil de rugosité, la fonction d'autocorrélation est calculée, puis la fonction d'autocorrélation moyenne des 10 profils est utilisée pour extraire les deux paramètres de rugosité : l'écart type des hauteurs $Hrms$ et la longueur de corrélation L .

La mesure de la rugosité a été réalisée une seule fois car la rugosité reste stable pendant l'année. En effet, l'irrigation fréquente par gravité maintient la morphologie du sol toujours lisse. De plus, il n'existe pas des pratiques agricoles qui affectent significativement la rugosité du sol. Les valeurs de rugosité $Hrms$ varient entre 0.35 cm et 0.55 cm, et les valeurs de L varient entre 2.00 cm et 4.60 cm.



Figure 4. Profilomètre à aiguilles pour la mesure de la rugosité.

2.2 Paramètres de la végétation

Les paramètres de la végétation ont été récoltés dans les trois cycles de croissance végétale, et aussi dans la période qui suit le troisième cycle. Le premier cycle commence en début Mars et se termine entre le 10 et le 30 Mai (durée entre 70 et 90 jours). Ensuite, le second cycle commence pour terminer entre le 2 Juillet et le 20 Juillet (durée environ 50 jours). Finalement, le troisième cycle se termine entre le 16 Août et le 2 Septembre (durée environ 50 jours).

Les prairies de notre site d'étude ont une composition floristique spécifique, qui a permis le rattachement de ces prairies à une association végétale d'intérêt communautaire¹. Les principales espèces végétales sont : (1) Graminées (*Dactylis glomerata L.*, *Lolium perenne L.*, *Poa pratensis L.*, *Holcus lanatus L.*, *Arrhenatherum elatius L.*, *Festuca pratensis L.*, *Setaria glaucus L.*, and *Paspalum dilatatum Poir.*), (2) Légumineuses (*Medicago lupulina L.*, *Trifolium repens L.*, *Trifolium pretense L.*, *Lotus corniculatus L.*, and *Vicia cracca L.*), et (3) diverses Dicotylédones (*Plantago lanceolata L.*, *Taraxacum officinale Weber.*, *Tragopogon pratensis L.*, *Galium mollugo L.*, *Galium verum L.*, *Daucus carota L.*, *Achillea millefolium L.*, *Pastanica silvestris L.*, and *Rumex acetosa L.*) (Merot et al., 2008a). Dans le premier cycle de croissance végétale, la proportion en biomasse des Graminées est dominante (60%-65%), et diminuera ensuite dans les deuxième et troisième cycles. Cependant, les pourcentages de biomasse des Légumineuses et diverses Dicotylédones augmentent de 35%-40% dans le premier cycle à 55 % dans la troisième cycle (Mérot, 2007).

2.2.1 Indice foliaire (LAI)

L'indice foliaire (ou Leaf Area Index, LAI) représente la surface de feuilles par unité de surface au sol (m^2/m^2). Cet indice peut être calculé par deux méthodes, directe et indirecte. La méthode directe est une méthode destructive qui consiste à couper la végétation, et ensuite mesurer la surface des feuilles une par une à l'aide d'un planimètre. Cette technique est très difficile à réaliser compte-tenu du type de feuillage du foin.

La méthode indirecte consiste à acquérir des photos hémisphériques au nadir (*Figure 5*) en utilisant un objective Fish Eye. Ensuite, ces photos sont traitées avec un logiciel développé à l'INRA Avignon (Can Eye) (<http://www6.paca.inra.fr/can-eye>) qui permet d'estimer le LAI. Dans Can Eye, le traitement des photos hémisphériques pour calculer le LAI est basé sur la mesure de fraction des trous dans la végétation. Dans cette étude la méthode indirecte (20-25 photos hémisphériques) a été considérée pour mesurer le LAI car elle est plus réaliste pour un type de végétation comme le foin. Le LAI évolue rapidement dans le temps. Les valeurs de LAI varient entre 0.1 et $6 \text{ m}^2/\text{m}^2$. Pour la plupart des parcelles, le LAI atteint $4 \text{ m}^2/\text{m}^2$ environ quelques jours avant la coupe. Une dizaine de jours après la coupe, les valeurs de LAI sont de l'ordre de $2.5 \text{ m}^2/\text{m}^2$.



Figure 5. Photo hémisphérique pour l'estimation du LAI.

Le traitement des photos hémisphériques avec Can Eye permet d'estimer le LAI avec une certaine précision. Demarez *et al.* (2008) ont comparé des valeurs de LAI obtenues en traitant des photos hémisphériques avec CanEye ($\text{LAI}_{\text{CanEye}}$) par rapport aux valeurs de LAI obtenues par la méthode destructive (LAI_{dest}) sur le blé, maïs, et tournesol (*Figure 6*). Pour le blé et le tournesol (LAI_{dest} entre $0.10 \text{ m}^2/\text{m}^2$ et $3.50 \text{ m}^2/\text{m}^2$), l'exploitation des photos hémisphériques

($\text{LAI}_{\text{CanEye}}$) sous-estime légèrement les valeurs de LAI_{dest} (biais = $-0.18 \text{ m}^2/\text{m}^2$) avec un RMSE relativement faible égal à $0.29 \text{ m}^2/\text{m}^2$ (Erreur absolue moyenne en pourcentage "MAPE"~18%) (*Figure 6*). Pour le Maïs (LAI_{dest} entre $0.45 \text{ m}^2/\text{m}^2$ et $5.10 \text{ m}^2/\text{m}^2$), les valeurs de $\text{LAI}_{\text{CanEye}}$ sous-estiment considérablement les valeurs LAI_{dest} (biais = $-0.88 \text{ m}^2/\text{m}^2$) avec une RMSE importante égale à $1.02 \text{ m}^2/\text{m}^2$ (MAPE ~30%).

En conclusion, la précision sur les valeurs de LAI estimées en utilisant la technique des photos hémisphériques dépend du type de végétation et de la gamme de valeur de LAI. La structure du foin est très similaire au blé, donc on considère que les valeurs de LAI sur notre site d'étude sont fiables surtout pour des valeurs inférieures à $3.50 \text{ m}^2/\text{m}^2$.

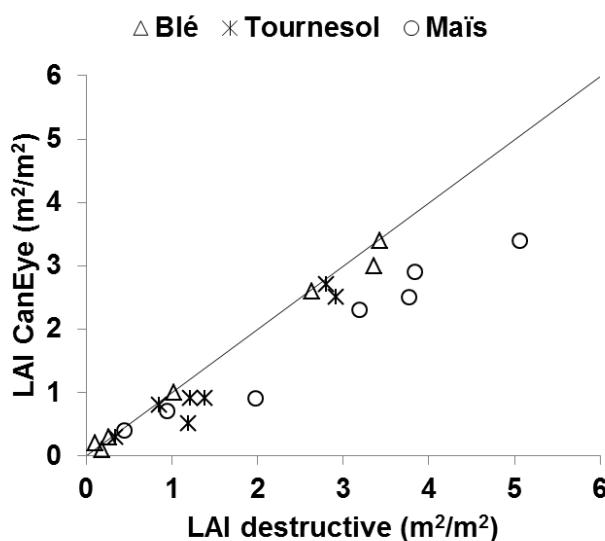


Figure 6 . LAI issues des traitements des photos hémisphériques avec CanEye en fonction de LAI destructive (Demarez et al., 2008)

2.2.2 Biomasse, poids sec, et contenu en eau du foin

Pour calculer la biomasse de la végétation (kg/m^2), on réalise en premier temps deux coupes de foin par parcelle sur une surface de $50 \text{ cm} \times 50 \text{ cm}$ en utilisant des cisailles. Ensuite, quelques heures après, le volume du foin coupé est pesé pour obtenir le poids humide qui représente la biomasse (BIO). Les échantillons coupés sont séchés dans une étuve à une température de 70°C durant 3 à 4 jours pour déterminer le poids sec qui représente la matière sèche (DM en kg/m^2). La différence entre la biomasse (poids humide) et la matière sèche (poids sec) nous permet d'estimer le contenu en eau de la végétation (VWC). Les valeurs de BIO sont entre $0.28 \text{ kg}/\text{m}^2$ et $4.20 \text{ kg}/\text{m}^2$, les valeurs de DM sont entre $0.18 \text{ kg}/\text{m}^2$ et $0.97 \text{ kg}/\text{m}^2$, et les valeurs de VWC entre $0.10 \text{ kg}/\text{m}^2$ et $3.35 \text{ kg}/\text{m}^2$.

Quelques jours avant la coupe (2 à 7 jours) la biomasse est entre 2.5 kg/m^2 et 4 kg/m^2 (VWC entre 2.08 kg/m^2 et 3.35 kg/m^2). Une dizaine de jours après la coupe, la biomasse (BIO) atteint une valeur de 0.70 kg/m^2 environ (DM~ 0.25 kg/m^2 et VWC ~ 0.5 kg/m^2).

2.2.3 Hauteur du foin

La hauteur du foin est mesurée à l'aide d'un mètre. En général, les mesures des hauteurs ont été réalisées à 20 endroits dans la parcelle. A chaque endroit, 5 mesures de hauteur sont effectuées. La hauteur du foin varie beaucoup d'une espèce de végétation à une autre. En général, on mesure la hauteur des espèces dominantes. Pour ces espèces, la hauteur atteint des valeurs entre 80 cm et 120 cm quelques jours avant la coupe. Une dizaine de jours après la coupe, la hauteur (HVE) atteint une valeur de 30 cm environ.

2.3 Calendrier d'irrigation, et données météorologique

Pendant la période d'irrigation, les dates d'arrosages avec l'heure du début et l'heure de la fin pour chaque parcelle ont été enregistrées par la responsable d'arrosage.

Les données météorologiques (température, le rayonnement, l'humidité relative de l'air, le vent, précipitations) sont acquises par une station météorologique située sur le Domaine du Merle et gérée par l'unité Agroclim de l'INRA d'Avignon. Nous en utiliserons les données à un pas du temps horaire ou journalier.

3. Données Satellitaires

Dans la cadre de cette étude, des images radar et optique ont été réalisées entre février et octobre 2013.

3.1 Images radar

Dans cette étude nous avons souhaité utiliser des images radar en bande X pour les raisons suivantes : (1) l'utilisation de cette longueur d'onde sur un site irrigué est innovant car peu d'études sont disponibles avec cette longueur d'onde, (2) les capteurs bande X permettent des acquisitions avec des résolutions métriques, adaptée à nos parcelles de petites tailles, (3) la végétation évolue rapidement dans notre site d'étude et les capteurs bande X TerraSAR-X et COSMO-SkyMed sont les seuls à permettre un suivi journalier.

Des acquisitions radar en bande X ont été programmées pour couvrir la zone d'étude le long de la période d'irrigation et de récolte, avec une répétitivité temporelle inférieure à une semaine. Les données radar ont été acquises par les satellites SAR (Synthetic Aperture

Radar), TerraSAR-X (TSX) et CosmoSkyMed (CSK). Au total, pour l'année 2013 on dispose de 25 images SAR en bande X (*Table 1*).

Les images ont été programmées en mode haute résolution spatiale (3 m – 15 m), moyenne incidence (~30°), et en double polarisations HH et HV (Table 1). En effet, le but des acquisitions SAR était dans un premier temps la caractérisation de l'humidité du sol et les paramètres de la végétation. D'après la littérature, les données radar à faible et moyenne incidences sont recommandées pour l'estimation de l'humidité du sol (Baghdadi et al., 2006, 2008a, 2012b; Srivastava et al., 2003; Zribi and Dechambre, 2003). De plus, la polarisation HH est la plus sensible à l'humidité du sol (Beaudoin et al., 1990), tandis la polarisation HV est sensible à la végétation (Balenzano et al., 2011; Brown et al., 2003; Picard et al., 2003).

La calibration radiométrique des images SAR a été réalisée en utilisant des algorithmes développés par le centre aérospatial allemand (DLR) et l'Agence spatiale Italienne (ASI). Pour les produits TSX en mode MGD (Multi Look Ground Range Detected), la calibration radiométrique a été réalisée en utilisant l'équation suivante (Eineder et al., 2008) :

$$\sigma^{\circ} = K_s \cdot DN^2 \cdot \sin(\theta) - NESZ \quad \text{Eq.5}$$

Cette équation transforme le compte numérique de chaque pixel de l'image en un coefficient de rétrodiffusion en unité linéaire (σ°) corrigé de bruit connu sous le nom NESZ (Noise Equivalent Sigma Zero). Cette calibration tient en compte l'angle d'incidence du radar (θ) et de la constante d'étalonnage (K_s), les deux sont données dans les métadonnées de chaque image. Le NESZ doit être inférieur à $K_s \cdot DN^2 \cdot \sin(\theta)$ pour assurer un important rapport signal-sur-bruit. Pour nos images du TSX, le NESZ varie de -25.2 dB à -22.6 dB pour les deux polarisations HH et HV.

La calibration des images CSK est réalisée avec l'équation suivante (Agenzia Spaziale Italiana, 2007) :

$$\sigma^{\circ} = DN^2 \cdot \frac{1}{K \cdot F^2} \cdot \sin(\theta) R_{ref}^{2 \cdot R_{exp}} \quad \text{Eq.6}$$

Où θ est l'angle d'incidence de référence, R_{ref} est la distance oblique de référence, R_{exp} est l'exposant de la distance oblique, K est la constante de calibration, et F est un facteur d'échelle. Pour les satellites CSK en mode Ping-Pong avec un angle d'incidence d'environ 30°, Torre *et al.* (2011) ont rapporté un équivalent de bruit sigma zéro entre -22 dB et -29 dB.

Pour chaque parcelle, les pixels de rétrodiffusion radar en unité linéaire ont été moyennés pour diminuer l'effet de speckle présent sur les images radar. Ensuite, la moyenne des coefficients de rétrodiffusion pour chaque parcelle est calculée en décibels selon la formule suivante:

$$\sigma^o_{dB} = 10 \cdot \log_{10} (\overline{\sigma^o}) \quad \text{Eq.7}$$

Où $\overline{\sigma^o}$ est la rétrodiffusion moyenne pour une parcelle

Date	Capteur	Bandé	Polarisations	Angle d'incidence	Résolution
06/06/2013	CSK	X	HH et HV	28,5	15 m x 15 m
10/06/2013	CSK	X	HH et HV	28,5	15 m x 15 m
11/06/2013	CSK	X	HH et HV	30.2	15 m x 15 m
14/06/2013	CSK	X	HH et HV	28.5	15 m x 15 m
26/06/2013	CSK	X	HH et HV	28.5	15 m x 15 m
08/07/2013	CSK	X	HH et HV	28.5	15 m x 15 m
12/07/2013	CSK	X	HH et HV	28.5	15 m x 15 m
16/07/2013	CSK	X	HH et HV	28.5	15 m x 15 m
01/08/2013	CSK	X	HH et HV	28.5	15 m x 15 m
09/08/2013	CSK	X	HH et HV	28.5	15 m x 15 m
26/08/2013	CSK	X	HH et HV	28.5	15 m x 15 m
29/08/2013	CSK	X	HH et HV	28.5	15 m x 15 m
02/09/2013	CSK	X	HH et HV	28.5	15 m x 15 m
10/09/2013	CSK	X	HH et HV	28.5	15 m x 15 m
04/10/2013	CSK	X	HH et HV	28.5	15 m x 15 m
19/04/2013	TX	X	HH et HV	29.3	3 m x 3 m
22/04/2013	TSX	X	HH et HV	32.6	3 m x 3 m
30/04/2013	TSX	X	HH et HV	29.3	3 m x 3 m
14/05/2013	TSX	X	HH et HV	32.6	3 m x 3 m
22/05/2013	TSX	X	HH et HV	29.3	3 m x 3 m
08/07/2013	TSX	X	HH et HV	29.3	3 m x 3 m
30/07/2013	TSX	X	HH et HV	29.3	3 m x 3 m
18/08/2013	TSX	X	HH et HV	29.3	3 m x 3 m
01/10/2013	TSX	X	HH et HV	29.3	3 m x 3 m
16/10/2013	TSX	X	HH et HV	29.3	3 m x 3 m

Table 1. Caractéristiques des images radars.

3.2 Images optiques

Les données optiques ont été acquises par les satellites SPOT-4, SPOT-5, et LANDSAT-7, LANDSAT-8 (31 images). Notre site d'étude a été sélectionné par le CNES pour l'expérience destinée à simuler avec SPOT-4 la répétitivité de la mission Sentinel-2 de l'ESA (SPOT 4/Take 5). Cette sélection nous a permis d'avoir de nombreuses images SPOT-4 (9 images sans nuages). L'acquisition des images SPOT-4 a démarré début février 2013 pour une période de 4 mois, avec une résolution temporelle de 5 jours. Pour compléter les acquisitions SPOT-4, une demande des 8 images SPOT-5 a été soumise au programme ISIS pour la période entre juin et octobre 2013. Cette demande a été acceptée et les 8 images ont été acquises. Finalement, les données Landsat 7 & 8 ont été téléchargées gratuitement sur le site de l'USGS (U.S. Geological Survey). La majorité des dates d'acquisitions des images optiques correspondent à quelques jours près aux dates des acquisitions radar (*Table 2*). Les caractéristiques des données optiques sont présentées dans le Table 3. Au total, nous disposons de 31 images optiques sans nuages. La *Figure 7* montre une image optique (SPOT-4) et une image radar acquise sur le site d'étude le jour même.

Les 31 images optiques ont été corrigées des effets atmosphériques puis ortho-rectifiées. La correction atmosphérique des images SPOT-5 et LANDSAT-8 a été réalisée en utilisant le modèle SMAC (Simplified Method of Atmospheric Correction). Les paramètres d'entrée de SMAC (épaisseur optique de l'aérosol à 550 nm et teneur en vapeur d'eau) ont été obtenus depuis le site web AERONET (Aerosol Robotic Network: <http://aeronet.gsfc.nasa.gov/>). Les images SPOT-4 et LANDSAT-7 en réflectance de surface (corrigées des effets atmosphériques) ont été obtenues directement des sites web du CNES (<http://spirit.cnes.fr/take5>) et de l'USGS (<http://earthexplorer.usgs.gov/>), respectivement. Les données SPOT-4 ont été corrigées de l'effet atmosphérique en utilisant la méthode détaillée dans l'étude de Hagolle *et al.* (2008). De plus, la correction atmosphérique des images LANDSAT-7 a été réalisée par la NASA (National Aeronautics and Space Administration) en utilisant le modèle 6S (Seconde Simulation d'un signal satellite dans le spectre solaire) (Masek *et al.*, 2013).

Dans cette étude, les données optiques dans le domaine visible et infrarouge ont été seulement utilisées car leur résolution spatiale ($\leq 30 \text{ m} \times 30 \text{ m}$) est adaptée aux tailles de nos parcelles ($\sim 105 \text{ m} \times \sim 290 \text{ m}$). Au contraire, les données optiques dans le domaine thermique ont une résolution spatiale de $100 \text{ m} \times 100 \text{ m}$ qui ne permet pas de représenter les parcelles.

	Février				Mars				Avril				Mai				Juin				Juillet																
	23	15	16	25	14	17	19	22	24	30	03	04	11	14	22	27	03	04	06	10	11	12	13	14	18	26	28	30	05	08	12	14	16	19	22	29	30
TSX							X	X		X				X	X															X					X		
CSK																						X	X	X			X	X			X	X	X				
SPOT-4 & 5	X	X		X	X				X		X	X						X			X	X			X	X											
LANDSAT-7/8			X		X					X			X		X	X		X			X			X				X			X		X	X			
Mesures in situ	X					X		X	X		X	X		X		X	X	X		X	X			X	X			X	X	X	X	X	X				

	Août												Septembre				Octobre						
	01	09	13	15	18	20	21	22	23	26	29	31	02	03	04	10	22	24	01	04	06	11	16
TSX					X														X				
CSK	X	X								X	X		X			X				X			X
SPOT-4 & 5	X					X												X				X	X
LANDSAT-7 & 8				X					X			X						X					
Mesures <i>in situ</i>	X	X	X	X		X	X		X	X		X	X	X	X	X		X	X	X		X	

Table 2. Calendrier des acquisitions spatiales (radar et optique) et des mesures *in situ*.

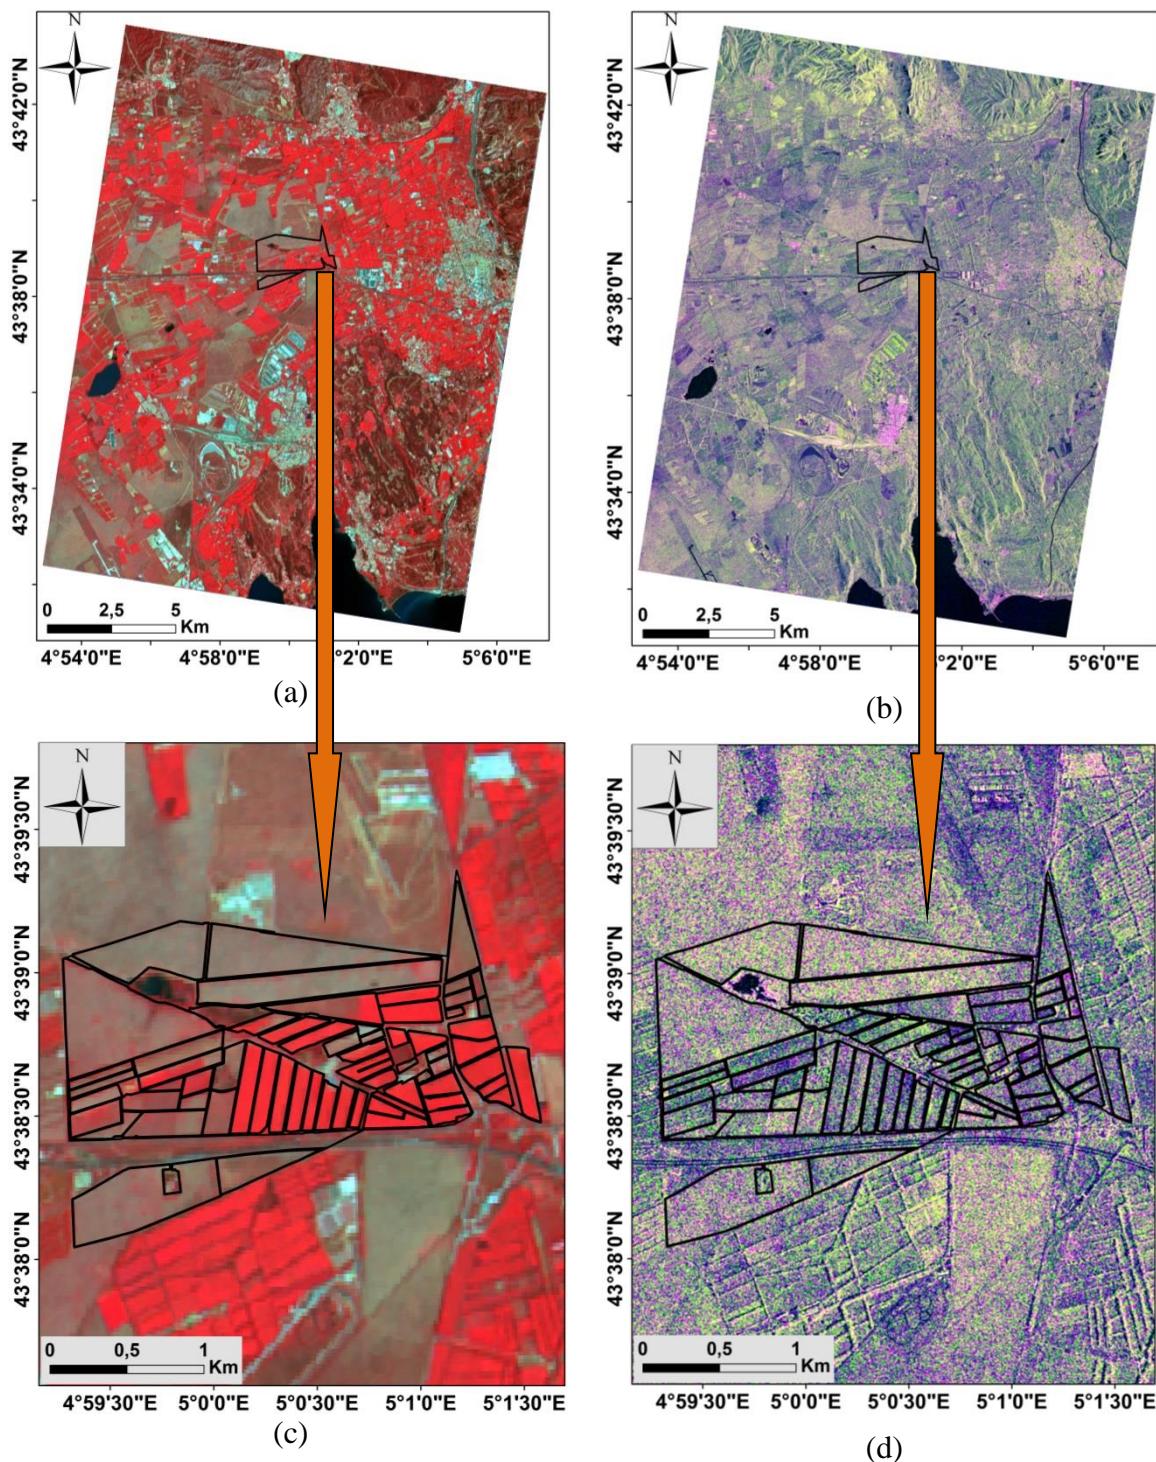


Figure 7. (a) Image optique acquise par SPOT-4 le 14 Mai 2013, composition colorée : R = PIR, V = Rouge, B = vert. (b) Image radar (TSX) acquise le même jour (14/05/2013), composition colorée : R = HH (dB), V = HV (dB), B = HH (dB)-HV (dB). L'image optique a été coupée pour ajuster l'étendue géographique de l'image radar. (c) Zoom dans l'image optique sur le site d'étude, (d) zoom dans l'image radar sur le site d'étude.

Satellite	Bandes Spectrales	Résolution
SPOT-4	Bande 1 : Green (0,50 - 0,59 µm) Bande 2 : Red (0,61 - 0,68 µm) Bande 3 : Near infrared (0,78 - 0,89 µm) Bande 4 : Mid Infrared (MIR) (1,58 - 1,75 µm)	5 m x 5 m
SPOT-5	Bande 1 : Green (0,50 - 0,59 µm) Bande 2 : Red (0,61 - 0,68 µm) Bande 3 : Near infrared (0,78 - 0,89 µm) Bande 4 : Mid Infrared (MIR) (1,58 - 1,75 µm)	5 m x 5 m
LANDSAT- 7	Band 1: Blue (0.45 – 0.51 µm) Band 2: Green (0.525 - 0.605 µm) Band 3: Red (0.63 – 0.69 µm) Band 4: Near infrared (0.75 - 0.90 µm) Band 5: SWIR 1 (1.55 – 1.75 µm) Band 6: Thermal Infrared (10.40 12.50 µm) Band 7: SWIR 2 (2.09 – 2.35 µm) Band 8: Pancromatic (0.50 – 0.90 µm)	30 m x 30 m 30 m x 30 m 60 m x 60 m 30 m x 30 m 15 m x 15 m
LANDSAT-8	Band 1: Violet (0.43 - 0.45 µm) Band 2: Blue (0.45 - 0.51 µm) Band 3: Green (0.53 - 0.59 µm) Band 4: Red (0.64 - 0.67 µm) Band 5: Near Infrared (0.85 - 0.88 µm) Band 6: SWIR1 (1.57 - 1.65 µm) Band 7: SWIR2 (2.11 - 2.29 µm) Band 8: Pancromatic (0.50 - 0.68 µm) Band 9: Near Infrared (1.36 - 1.38 µm) Band 10: Thermal Infrared 1 (10.60-11.19 µm) Band 11: Thermal Infrared 2 (11.50-12.51 µm)	30 m x 30 m 30 m x 30 m 60 m x 60 m 30 m x 30 m 15 m x 15 m 100 m x 100 m 100 m x 100 m

Table 3. Caractéristiques des images optiques.

CHAPITRE 3 :

*Sensibilité des données radar bande X aux paramètres du
sol et de la végétation*

1. Objectifs

Le potentiel des données radar en bande X pour le suivi et l'estimation de l'humidité du sol a été démontré dans plusieurs études dans le cas de sols nus (Anguela et al., 2010; Aubert et al., 2011, 2013; Baghdadi et al., 2011, 2012b; Gorrab et al., 2015; Singh, 2005). Cependant, très peu d'études ont démontré le potentiel des données radar en bande X pour l'estimation de l'humidité du sol en présence de végétation (Baghdadi et al., 2010; Kseneman et al., 2012; Soon-Koo Kweon et al., 2012).

L'objectif de cette partie de la thèse est de montrer le potentiel des données radar en bande X pour le suivi des paramètres du sol et de la végétation dans le cas de prairies irriguées. En particulier, il s'agit d'analyser le potentiel des données en bande X pour le suivi de l'irrigation et la détection des variations d'humidité du sol en présence d'un couvert végétal parfois relativement dense. Des données optiques et des mesures in situ ont été utilisées pour mener à bien cette investigation.

2. Base de données

Des images radar ont été acquises avec une forte répétitivité temporelle (mieux d'une semaine) par les capteurs TerraSAR-X (TSX) et CosmoSky-Med (CSK). De plus, des images optiques issues des satellites SPOT-4 (Expérience Take-5), SPOT-5, LANDSAT-7 et LANDSAT-8 ont été utilisées. Dans la plupart des cas, les images optiques et radar sont acquises à quatre jours d'intervalle au plus.

De plus, des données terrain ont été récoltées simultanément aux acquisitions radar. Ces données terrain concernent les paramètres du sol (humidité volumétrique : M_v , et rugosité : $Hrms$) et de la végétation (BIO : biomasse, VWC : contenu en eau, HVE : hauteur de la végétation, LAI : indice foliaire, FAPAR : fraction de rayonnement solaire absorbée, et FCover : fraction de couvert). Les mesures de terrain et les acquisitions satellites couvrent les différents stades de croissance des prairies, de la coupe jusqu'à la maturation.

3. Méthode

Les 25 images TSX et CSK (acquises entre avril et octobre) ont été calibrées pour calculer le coefficient de rétrodiffusion en utilisant les méthodes développées par le Centre Aérospatial Allemand (DLR) (Eineder et al., 2008) et l'Agence spatiale italienne (ASI) (Agenzia Spaziale Italiana, 2007), respectivement. Ces méthodes de calibration permettent de convertir le compte numérique de chaque pixel de l'image en une amplitude du signal rétrodiffusé en unité linéaire. Les pixels de rétrodiffusion radar en unité linéaire sont ensuite moyennés pour chaque parcelle, et ensuite convertis en unité décibel (dB). Finalement, les rétrodiffusions des

parcelles en dB ont été analysées en fonction de l'humidité du sol et des paramètres de la végétation en utilisant des modèles linéaires simples.

De plus, les 31 images optiques corrigées des effets atmosphériques ont été utilisées pour calculer l'indice NDVI. Les pixels NDVI ont été moyennés pour chaque parcelle et ensuite exprimés en fonction des paramètres physiques de la végétation, à travers des modèles de régressions simples.

Pour les parcelles témoins, une comparaison entre les moyennes de NDVI issues des différentes capteurs (LANDSAT-7/8, SPOT-4/5) avec un intervalle de temps inférieur à 4 jours a été effectuée (*Figure 8*). Les résultats ont montré que les valeurs de NDVI issues des différents capteurs sont cohérentes (biais ~ 0, RMSE \leq 0.04, MAPE \leq 4.42%, R² entre 0.70 and 0.98) (Figure 8).

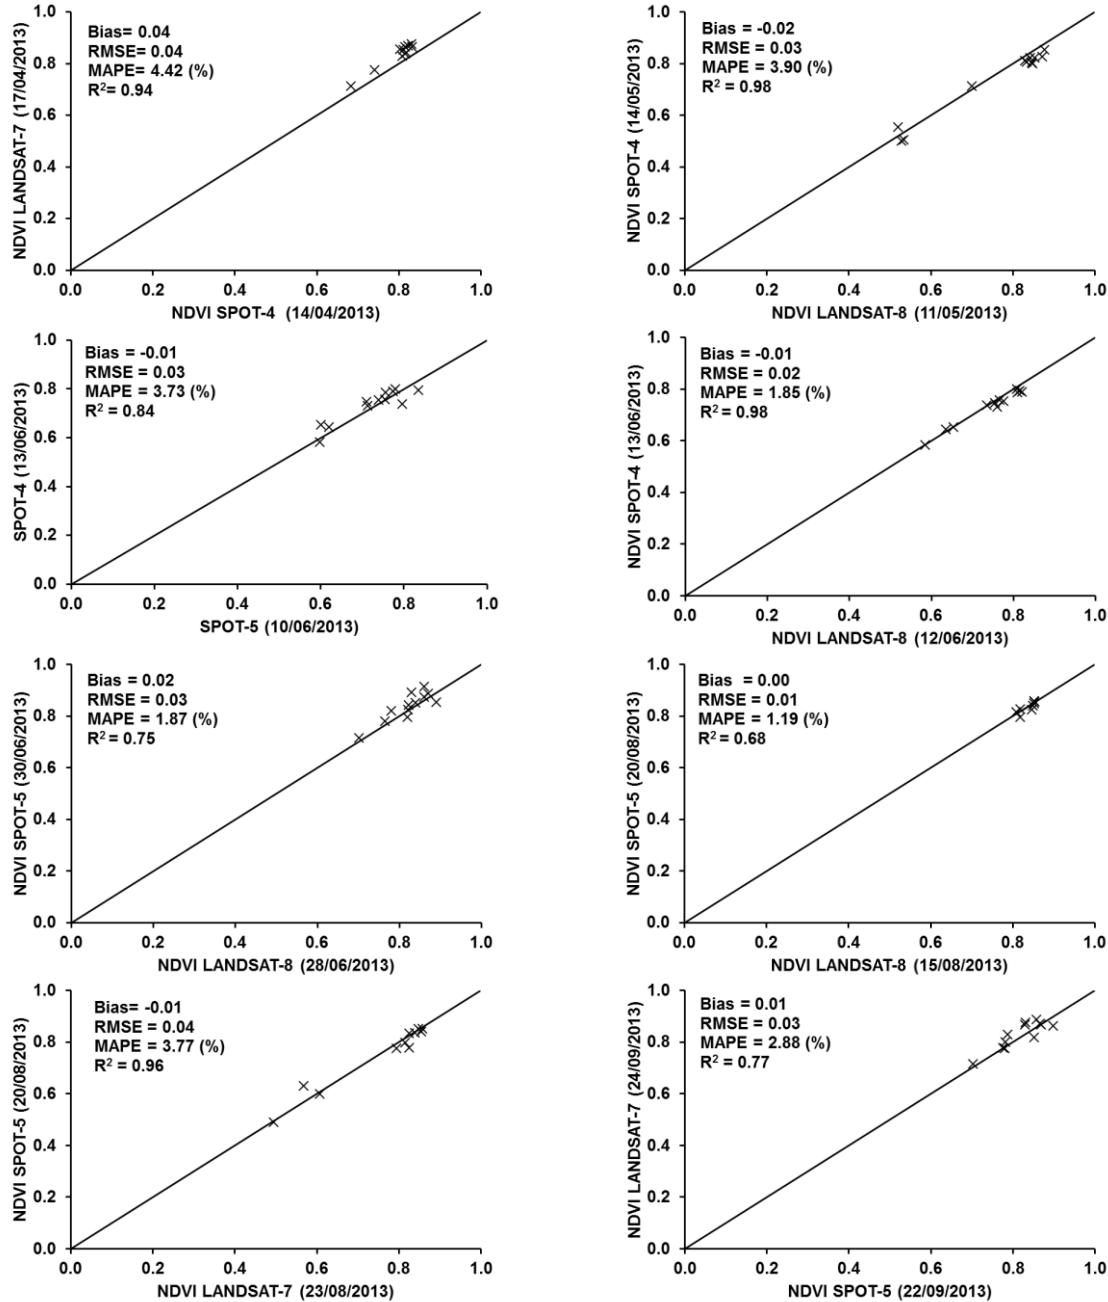


Figure 8. Comparaison entre les moyennes de NDVI des parcelles témoins issues des différents capteurs LANDSAT-7/8 et SPOT-4/5

4. Résultats et discussion

4.1 Données mesurées *in situ*

Une analyse de la dépendance entre les différents paramètres de végétation mesurés *in situ* a été réalisée. Une dépendance linéaire avec un important coefficient de détermination (R^2) a

été observée entre BIO (kg/m^2) et VWC (kg/m^2) ($R^2 \sim 0.99$) d'une part (Figure 9a), et entre BIO et HVE (m) ($R^2 \sim 0.80$) d'autre part (Figure 3b, article 1). La relation linéaire entre BIO et VWC montre que le contenu en eau du foin, récolté sur un mètre carré, représente environ 80% de la biomasse (Figure 9a). La biomasse (BIO) augmente linéairement avec la hauteur de la végétation (HVE) (Figures 3b et 4, article 1), puis, pour une hauteur de la végétation (HVE) supérieure à 50 cm, la biomasse (BIO) montre une importante variation (Figure 3b, article 1). En effet, un changement de morphologie de la végétation a été observé lorsque la hauteur de la végétation dépassait les 50 cm environ, avec par exemple la présence d'éléments inclinés (i.e. panicules) orientés de façon aléatoire au sommet de la plante.

De plus, le LAI mesuré *in situ* augmente rapidement en fonction de HVE, BIO et VWC pour de HVE inférieures à 50 cm (BIO environ 1.5 kg/m^2) (Figures 3a et 4, article1). Pour HVE entre 10 et 50 cm (BIO entre 0.3 et 1.5 kg/m^2), le LAI varie entre 0.1 et $3 \text{ m}^2/\text{m}^2$. Par contre, pour des HVE entre 50 et 120 cm (BIO entre 1.5 et 4 kg/m^2), les valeurs de LAI se saturent. Finalement, les variations de LAI et FAPAR, et celles de LAI et FCOVER, sont fortement corrélées ($R^2 \sim 0.90$). LAI augmente en fonction de FAPAR et FCOVER selon une loi exponentielle (Figure 9b,c).

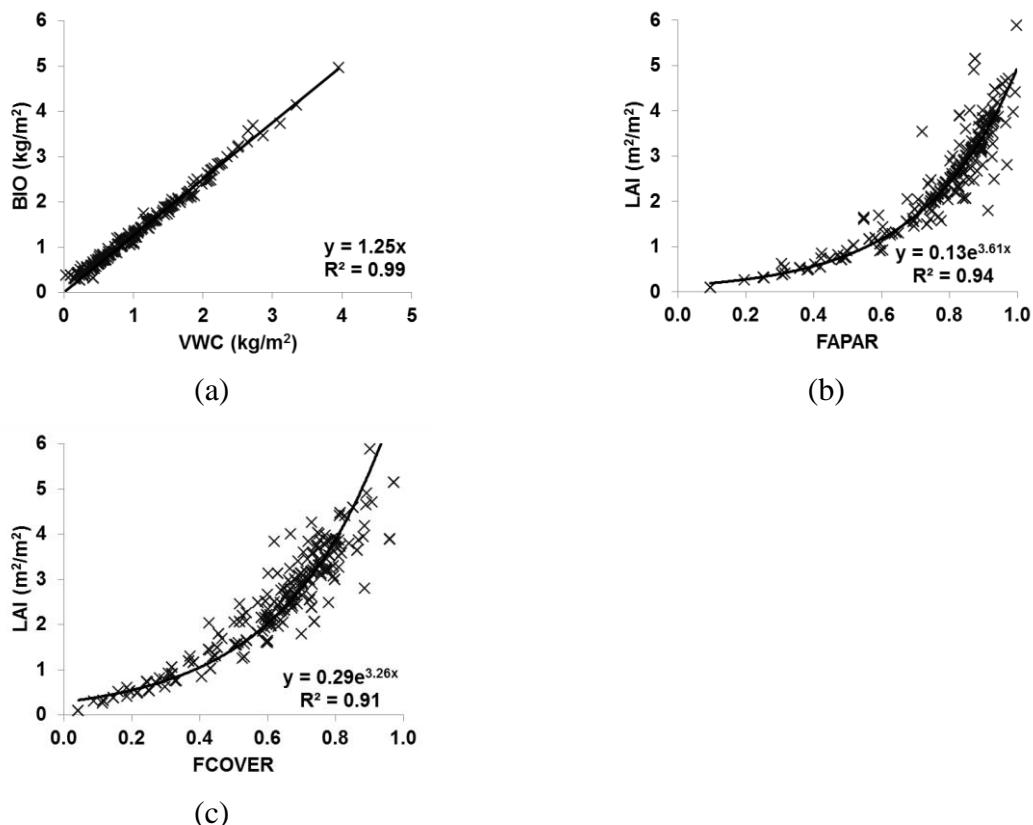


Figure 9. (a) BIO *in situ* en fonction VWC *in situ*, (b) LAI *in situ* en fonction de FAPAR *in situ*, (c) LAI *in situ* en fonction de FCOVER *in situ*.

4.2 Sensibilité de NDVI aux paramètres de la végétation

La sensibilité des données optiques aux paramètres de la végétation a été étudiée en reliant le NDVI aux BIO, VWC, HVE, et LAI (*Figure 5*, article 1). Les résultats ont montré que le NDVI augmente linéairement avec les paramètres de la végétation (BIO, VWC, HVE, LAI) pour des valeurs de NDVI inférieures à 0.8. Pour des valeurs supérieures à 0.8, le NDVI sature et devient insensible aux variations des paramètres de la prairie. Le NDVI permet de suivre l'évolution de la végétation pour des valeurs de BIO, HVE et LAI inférieures à environ 1 kg/m², 30 cm, et 2 m²/m², respectivement.

4.3 Sensibilité du signal radar aux paramètres du sol et de la végétation

4.3.1 Sensibilité du signal radar à l'humidité du sol

La rétrodiffusion radar des parcelles a été exprimée en fonction de l'humidité du sol (*Figures 6 et 7*, article 1). Pour minimiser l'effet de la végétation sur le signal rétrodiffusé, la sensibilité des données radar à l'humidité du sol a été étudiée pour deux gammes de biomasse (inférieure ou supérieure à 1 kg/m²) (*Figure 7*, article 1). Pour des biomasses inférieures à 1 kg/m² (biomasses entre 0.28 et 1 kg/m²), le signal radar dépend de l'humidité du sol, avec une sensibilité à l'humidité du sol de 0.1264 et 0.1340 dB/Vol.% en polarisations HH et HV, respectivement. Pour des biomasses supérieures à 1 kg/m² (biomasses entre 1 et 4.2 kg/m²), cette sensibilité diminue pour devenir 0.0883 et 0.0639 dB/Vol.% en polarisations HH et HV, respectivement. De plus, dans les deux gammes de biomasse, le signal radar rétrodiffusé en polarisation HV a plus de variation qu'en polarisation HH pour une valeur d'humidité donnée: le signal radar en polarisation HV est plus sensible au couvert végétal (Balenzano et al., 2011; Brown et al., 2003; Picard et al., 2003).

En résumé, le signal radar dépend de l'humidité du sol même en présence d'un dense couvert végétal (HVE ~ 1m, biomasse ~4 kg/m²). En complément, la profondeur de pénétration du signal radar en bande X (angle d'incidence ~30°) dans le couvert de pâturage dense (HVE ~ 1m, biomasse ~4 kg/m²) est importante, en particulier en polarisation HH.

4.3.2 Détection des activités d'irrigation

Le potentiel des données radar à suivre les activités d'irrigation a été démontré. Les données radar sont capables d'identifier les parcelles irriguées même si l'image radar a été acquise trois jours après l'achèvement de l'irrigation. En effet, le signal radar augmente quand l'humidité du sol augmente suite à une irrigation (*Figure 6*, article 1). Pendant et juste après l'irrigation le signal radar atteint son niveau maximal. Cette forte rétrodiffusion est due à la double réflexion qui résulte de la présence de l'eau à l'état libre et de la végétation en position

verticale (*Figure 8*, article 1). Les résultats montrent que les données radar permettent de localiser à l'échelle intra-parcellaire la présence d'eau à l'état libre, résultat de la pratique d'irrigation en cours ou récente (survenue quelques heures auparavant), même quand la végétation est importante (HVE ~1m) (*Figure 8*, article 1). Quelque temps après l'irrigation le signal commence à décroître (*Figure 6*, article 1). L'humidité du sol revient à son niveau d'avant l'irrigation en à peu près 4 jours après l'irrigation sur notre site d'étude, soit une humidité de l'ordre de 20 Vol.% (*Figure 6*, article 1).

En conséquence, sur notre site d'étude et en présence d'un couvert végétal dense, le signal radar en bande X est capable de pénétrer le couvert végétal et de fournir des informations sur l'état hydrique du sol.

4.3.3 Sensibilité du signal radar aux paramètres de la végétation

Le potentiel des données radar en bande X pour l'estimation des paramètres de la végétation (BIO, VWC, HVE, et LAI) a été également analysé. Pour minimiser l'effet de la contribution de l'humidité du sol sur le signal rétrodiffusé, la sensibilité des données radar aux paramètres de la végétation a été analysée par gammes d'humidité de 10 Vol.% (*Figures 9,10, 11 et 12*, article 1). De plus, pour chaque gamme d'humidité, la sensibilité du signal radar aux paramètres de la végétation a été établie pour deux classes de HVE : inférieures ou supérieures à 50 cm (LAI ~ 3 m²/m², BIO ~ 1.5 kg/m², VWC ~1.2 kg/m²). Ce seuil de hauteur correspond à la hauteur de la végétation à partir de laquelle l'effet de sa morphologie devient important sur le signal radar rétrodiffusé.

Les résultats ont montré que le signal radar (polarisations HH et HV) est insensible aux variations de LAI, BIO, VWC et au HVE pour des HVE supérieures à 50 cm. A contrario, une sensibilité plus importante a été observée entre le signal radar en polarisation HV et la HVE pour des HVE inférieures à 50 cm (le signal radar décroît de 1.1 dB quand la hauteur augmente de 10 cm, avec un R² d'environ 0.70) (*Figure 10*, article 1). De plus, les résultats ont montré que le signal radar diminue puis il augmente légèrement en fonction de HVE pour des HVE inférieures et supérieures à 50 cm, respectivement. La diminution et l'augmentation du signal radar est plus importante en polarisation HV qu'en HH. En effet, le signal radar en polarisation HV est plus sensible au couvert végétal. La diminution du signal radar en fonction de HVE pour des HVE inférieures à 50 cm est liée à l'augmentation de l'atténuation qui est plus importante que la contribution directe de la végétation sur le signal rétrodiffusé. Cependant, l'augmentation du signal en fonction de HVE pour des HVE supérieures à 50 cm est le résultat de l'augmentation de la contribution de la végétation combinée avec la diminution de contribution de l'humidité du sol.

5. Conclusions et perspectives

Les données optiques et radar sont utiles et pertinentes pour suivre les états hydriques des prairies irriguées de notre site d'étude. L'indice NDVI calculé à partir des données optiques permet de suivre les paramètres physiques de la végétation (BIO, VWC, HVE, et LAI) pour des NDVI inférieurs à 0.8.

De plus, le signal radar en bande X reste sensible aux variations de l'humidité du sol, même en présence d'un couvert végétal dense ($HVE \sim 1m$, $BIO \sim 4kg/m^2$). Cette sensibilité est supérieure pour des biomasses inférieures à $1 kg/m^2$. Le signal radar permet ainsi de suivre les activités d'irrigation, à condition que l'image radar soit acquise au plus trois jours après l'irrigation. Finalement, le signal radar en polarisation HV permet de suivre la hauteur de la végétation pour des hauteurs inférieures à 50 cm.

Dans le prochain chapitre, je vais montrer le potentiel des données radar en bande X à estimer l'humidité du sol.

Un article détaillant la méthode et les résultats résumés ci-dessus a été publié dans le journal international « *Remote Sensing* » :

El Hajj, M., Baghdadi, N., Belaud, G., Zribi, M., Cheviron, B., Courault, D., Hagolle, O., and Charron, F. (2014). Irrigated grassland monitoring using a time series of terraSAR-X and COSMO-skyMed X-Band SAR Data. *Remote Sens.* 6, 10002–10032.

Article 1

Irrigated Grassland Monitoring Using a Time Series of TerraSAR-X and COSMO-SkyMed X-Band SAR Data

1. Introduction	48
2. Dataset Description	52
2.1 Study Site	52
2.2 Satellite Data and In Situ Measurements	55
2.2.1 SAR Images	55
2.2.2 Optical Images	57
2.2.3 Experimental Measurements	58
2.2.3.1 <i>Soil Measurements</i>	58
2.2.3.2 <i>Vegetation Measurements</i>	59
3. Results and Discussion	61
3.1 Relationships between NDVI and Vegetation Parameters	61
3.2 The Radar Response According to Soil Moisture Variations	63
3.3 Sensitivity of Radar Signal to Soil Moisture	65
3.4 Detection of Flooded Plots	66
3.5 Relationships between Radar Signals and Vegetation Parameters	68
4. Conclusions and Perspectives	75

Irrigated Grassland Monitoring Using a Time Series of TerraSAR-X and COSMO-SkyMed X-Band SAR Data

(Version auteur de l'article publié dans Remote Sensing : vol 6, issue 10, pp 10002–10032)

Mohammad El Hajj^{1,*}, Nicolas Baghdadi¹, Gilles Belaud², Mehrez Zribi³, Bruno Cheviron⁴, Dominique Courault⁵, Olivier Hagolle³ and François Charron²

¹ IRSTEA, UMR TETIS, 500 rue François Breton, 34093 Montpellier cedex 5, France;
E-Mail: (nicolas.baghdadi@teledetection.fr)

² SupAgro, UMR G-EAU, 2 place Pierre Viala, 34060 Montpellier, France;
E-Mails: (belaud@supagro.inra.fr); (Francois.Charron@supagro.inra.fr)

³ CESBIO, 18 av. Edouard Belin, bpi 2801, 31401 Toulouse cedex 9, France;
E-Mails: (mehrez.zribi@ird.fr); (olivier.hagolle@cnes.fr)

⁴ IRSTEA, UMR G-EAU, 361 rue François Breton, 34196 Montpellier cedex 5, France;
E-Mail: (bruno.cheviron@irstea.fr)

⁵ INRA, UMR 1114 EMMAH, Domaine St. Paul, 84914, Avignon, France;
E-Mail: (dominique.courault@avignon.inra.fr)

Abstract: The objective of this study was to analyze the sensitivity of radar signals in the X-band in irrigated grassland conditions. The backscattered radar signals were analyzed according to soil moisture and vegetation parameters using linear regression models. A time series of radar (TerraSAR-X and COSMO-SkyMed) and optical (SPOT and LANDSAT) images was acquired at a high temporal frequency in 2013 over a small agricultural region in southeastern France. Ground measurements were conducted simultaneously with the satellite data acquisitions during several grassland growing cycles to monitor the evolution of the soil and vegetation characteristics. The comparison between the Normalized Difference Vegetation Index (NDVI) computed from optical images and the *in situ* Leaf Area Index (LAI) showed a logarithmic relationship with a greater scattering for the dates corresponding to vegetation well developed before the harvest. The correlation between the NDVI and the vegetation parameters (LAI, vegetation height, biomass, and vegetation water content) was high at the beginning of the growth cycle. This correlation became insensitive at a certain threshold corresponding to high vegetation ($LAI \sim 2.5 \text{ m}^2/\text{m}^2$). Results showed that the radar signal depends on variations in soil moisture, with a higher sensitivity to soil moisture for biomass lower than 1 kg/m^2 . HH and HV polarizations had approximately

similar sensitivities to soil moisture. The penetration depth of the radar wave in the X-band was high, even for dense and high vegetation; flooded areas were visible in the images with higher detection potential in HH polarization than in HV polarization, even for vegetation heights reaching 1 m. Lower sensitivity was observed at the X-band between the radar signal and the vegetation parameters with very limited potential of the X-band to monitor grassland growth. These results showed that it is possible to track gravity irrigation and soil moisture variations from SAR X-band images acquired at high spatial resolution (an incidence angle near 30°).

Keywords: grassland; irrigation; TerraSAR-X; COSMO-SkyMed; SPOT-4; LANDSAT; soil moisture; vegetation parameters

1. Introduction

In agriculture areas, information on soil and vegetation conditions is key for water and crop management. The use of in situ sensors to measure soil and vegetation parameters is not effective, especially over large areas, due to the punctual information provided by these measurements. Space-borne remote sensing is a useful tool for mapping vegetation and soil parameters due to its capacity to provide continuous coverage over large areas at various spatial and temporal resolutions. The information extracted from optical data is sometimes incomplete due to clouds. Sensors with spectral bands in the microwave range allow for the acquisition of images in all types of weather. Thus, SAR (Synthetic Aperture Radar) sensors are useful additional remote sensing data sources for applications such as crop and water management.

Over the last decade, SAR sensors have been launched to meet the increasing spatial data needs of the scientific and user communities. These SAR sensors have very high spatial resolution (1 m) and short revisit intervals (daily). Given their high spatial and temporal resolutions, TerraSAR-X (TSX) and COSMO-SkyMed (CSK) provided new opportunities for the operational monitoring of biophysical soil and vegetation parameters. The German radar satellite TerraSAR-X (TSX) was launched in June 2007 for commercial and scientific applications. It carries a high frequency X-band SAR sensor (9.65 GHz) that can be operated in different imaging modes (Eineder et al., 2008). In Spotlight imaging mode, a spatial resolution of up to 1 m can be achieved. The Stripmap mode (SM) allows for acquisitions with up to 3 m resolution. In the ScanSAR mode, a spatial resolution of up to 18 m is achieved. Imaging is possible in single polarization, dual-polarization (HH, VV, HH/VV, HH/HV, or VV/VH), or quad-polarization (HH, VV, HV, VH), and the nominal revisit period

is 11 days. The absolute and relative radiometric accuracies, determined during the commissioning phase of TerraSAR-X and confirmed by the recalibration campaigns, are 0.6 dB and 0.3 dB, respectively (Eineder et al., 2008; Schwerdt et al., 2008). The second X-band SAR system is the COSMO-SkyMed (CSK) constellation (9.6 GHz), developed in cooperation between the Italian Space Agency (ASI) and the Italian Defense Ministry. It is composed of four radar satellites (CSK1, CSK2, CSK3, CSK4). The first satellite in the constellation was launched in June 2007; the fourth satellite was launched in November 2010. The CSK SAR has the following three imaging modes (Agenzia Spaziale Italiana, 2007): Spotlight, Stripmap, and Scansar. Spotlight mode allows for images with spatial resolutions equal to 1 m (HH or VV). The Stripmap Himage (HI) and Pingpong (PP) modes provide spatial resolutions between 3 m (HH, HV, VH or VV) and 15 m (HH/VV, HH/HV, or VV/VH). Finally, the Scansar modes achieve medium (30 m) to coarse (100 m) spatial resolution (one polarization is selectable among HH, HV, VH and VV). The CSK can operate with right- and left-looking imaging capabilities and a revisit time of few hours (less than 12 h). For CSK, a radiometric accuracy better than 1 dB and a radiometric stability better than 0.5 dB are expected (Iorio et al., 2010).

Monitoring the spatio-temporal variations in vegetation biophysical parameters and soil moisture is key information for irrigation and crop management at both the farm level and the irrigation network level. Optical data in the visible and infrared spectral range have shown great potential for the mapping and characterization of vegetation biophysical parameters such as the Leaf Area Index (LAI) (Asrar et al., 1984; Baret and Guyot, 1991; Baret et al., 2007; Carlson and Ripley, 1997; Duchemin et al., 2006; Weiss and Baret, 1999; Weiss et al., 2004), biomass, height, and the Vegetation Water Content (VWC) (Baret and Guerif, 2006b). Several studies used the Normalized Difference Vegetation Index (NDVI) to estimate the LAI of different crop types (such as wheat, grassland, rice, orchard, corn, and maize) or more complex models based on radiative transfer models combined with neural networks (Bsaiibes et al., 2009; Courault et al., 2008, 2010). In addition, several studies have used the NDVI to estimate grassland biomass and height (Edirisinghe et al., 2011; Ferreira et al., 2013; Schino et al., 2003; Todd et al., 1998). Schino *et al.* (2003) and Payero *et al.* (2004) compared different vegetation indices over two different sites in central Italy and northwestern USA and found that NDVI provides the most accurate estimation of grass biomass and height. Some studies have used another index known as the Normalized Difference Water Index (NDWI), which is computed using the NIR (near infra red) and the SWIR (short wave infrared), to estimate vegetation water content (Chen et al., 2005; Gao, 1996; Gu et al., 2007; Jackson et al., 2004; Serrano et al., 2000). Chen *et al.* (2005) showed that the NDVI and the NDWI allow for similar precision in soybean and corn VWC estimates. Gu *et al.* (2007) found that the NDWI is more sensitive to grassland drought conditions than the NDVI. The use of the

NDVI and the NDWI for estimating vegetation biophysical parameters is limited due to the saturation of values when vegetation is high or very dense with high values of LAI. Payero *et al.* (2004) reported that the NDVI saturated when the height of alfalfa exceeded 40 cm. Anderson *et al.* (2004) showed that the NDVI and the NDWI saturate when the LAI of corn and soybean surpassed $3.5 \text{ m}^2/\text{m}^2$ and $4.5 \text{ m}^2/\text{m}^2$, respectively.

Synthetic aperture radars (SAR) have shown potential in the estimation of soil surface characteristics, especially surface roughness and soil moisture (Aubert *et al.*, 2011; Baghdadi *et al.*, 2002, 2012a; Srivastava *et al.*, 2009; Zribi and Dechambre, 2003; Zribi *et al.*, 2005, 2007). Moreover, many studies also assessed the sensitivity of SAR signals at different radar wavelengths (mainly the L-, C- and X-bands) to vegetation conditions (Ferrazzoli *et al.*, 1997; Gao *et al.*, 2013; Inoue *et al.*, 2002; SooBum Kim *et al.*, 2000; Wigneron *et al.*, 1999, 2002). SAR data at L, C and X bands are the configurations most widely used for estimating soil moisture (Anguela *et al.*, 2010; Aubert *et al.*, 2011, 2013; Baghdadi *et al.*, 2011, 2012b, 2012c; Hegarat-Mascle *et al.*, 2002; Ponnurangam and Rao, 2011; Shi *et al.*, 1997; Singh, 2005; Sonobe *et al.*, 2008; Srivastava *et al.*, 2003, 2009; Zribi and Dechambre, 2003; Zribi *et al.*, 2005, 2011). Over bare soil and surfaces with little vegetation, the reflected radar signal depends on soil moisture, roughness, and radar configuration (incidence angle, polarization, and wavelength). The radar signal at C-band is more sensitive to soil moisture at low incidences than at higher incidences (approximately $20 \text{ dB}/[\text{cm}^3/\text{cm}^3]$ for incidences between 20° and 35° : radar signal increases of 2 dB when the soil moisture increases of $0.1 \text{ cm}^3/\text{cm}^3$ and $10 \text{ dB}/[\text{cm}^3/\text{cm}^3]$ for incidences higher than 35°) (Baghdadi *et al.*, 2006, 2008b; Quesney *et al.*, 2000; Srivastava *et al.*, 2003). The X-band signal at low and high incidences is more sensitive to soil moisture than C-band signals at low incidence angles (approximately $41 \text{ dB}/[\text{cm}^3/\text{cm}^3]$ for HH polarization and an incidence of 25° , and approximately $32 \text{ dB}/[\text{cm}^3/\text{cm}^3]$ for HH polarization and an incidence of 50°) (Aubert *et al.*, 2011). In general, a mean accuracy between 0.03 and $0.06 \text{ cm}^3/\text{cm}^3$ on soil moisture estimates over bare soils can be achieved from the C and X band signals from SAR data (Aubert *et al.*, 2011; Baghdadi *et al.*, 2006, 2012a; Srivastava *et al.*, 2003, 2009; Zribi *et al.*, 2005).

Over vegetated surfaces, radar signals depend on the soil surface characteristics, vegetation, and radar configuration. The penetration depth of the radar wave depends on whether the biophysical parameters of the scatterers within a vegetation layer (e.g., the water content, size and geometry of the scatterers) can enhance or attenuate the interaction between the radar wave and the scatterers. Different theoretical or semi-empirical approaches have been developed to account for the effects of vegetation cover (Attema and Ulaby, 1978; Bindlish and Barros, 2001; Paris, 1986; Ulaby *et al.*, 1990). The most commonly used technique is referred to as the “water cloud model” (Attema and Ulaby, 1978). This model describes the

dependence between the radar signal and the vegetated surface parameters. In water-cloud models, the total backscattering signal (σ_{total}) from the surface is the sum of the following signals: (a) the backscattered signal from the soil (σ_{soil}) multiplied by the two-way attenuation (T^2); and (b) the direct reflected signal from the vegetation (σ_{veg}). In most studies, the contribution from vegetation has been expressed in terms of one of the physical parameters attached to it (biomass, leaf area index, vegetation water content, vegetation height). The contribution of the soil is generally modeled as a function of soil moisture and surface roughness (defined by the root mean square surface height and the correlation length).

The possibility of retrieving soil parameters in vegetated surfaces was widely investigated using C-band Synthetic Aperture Radar (De Roo *et al.*, 2001; Gherboudj *et al.*, 2011; Prévot *et al.*, 1993; Sikdar and Cumming, 2004; Wang *et al.*, 2011; Yang *et al.*, 2012; Yu and Zhao, 2011; Zribi *et al.*, 2011). Many studies showed that it is possible with SAR imagery to estimate the soil moisture with accuracy from 0.02 to 0.10 cm³/cm³ (RMSE). Prevot *et al.* (1993) showed the potential of data in the C and X bands to estimate both soil moisture and the LAI on winter wheat plots using the water cloud model. Accuracies of 0.065 cm³/cm³ and 0.64 m²/m² for soil moisture and the LAI, respectively, were obtained. De Roo *et al.* (2001) coupled a canopy scattering model (the Michigan Microwave Canopy Scattering model) with a soil scattering model (the Oh model) to estimate soil moisture and vegetation water content for a soybean canopy (VWC between 0.02 and 0.97 kg/m²) from fully polarimetric data at both L and C bands. The root mean square error of the soil moisture estimate was approximately 0.02 cm³/cm³. Zribi *et al.* (2011) estimated soil moisture using ASAR images (C-band) of wheat plots (LAI between 0.01 and 3.7 m²/m² and VWC between 0.15 and 0.93 kg/m²) using the water cloud model with an accuracy of approximately 0.06 cm³/cm³. Gherboudj *et al.* (2011) combined the Oh model and the water cloud model to estimate the soil moisture over an agriculture vegetation area (wheat, peas, lentil, fallow, pasture and canola) using Radarsat-2 images in polarimetric mode (C-band). The soil moisture was estimated with an accuracy of 0.06 cm³/cm³ for plots with a canopy height between 11 and 97 cm and a water content range between 0.54 kg/m² and 5.10 kg/m². Soon-Koo Kweon *et al.* (2012) estimated the soil moisture over soybean plots using SAR X-band data with an accuracy of 0.03 cm³/cm³ (VWC and LAI reach 1.8 kg/m² and 4.5 m²/m², respectively). Fieuzal *et al.* (2011) estimated from ASAR images the soil moisture of irrigated wheat plots with an accuracy of approximately 0.09 cm³/cm³ (VWC between 0.45 and 3.41 kg/m²).

To monitor water stress in irrigated systems and support irrigation scheduling decisions, the limited accuracy of individual soil moisture estimates may be compensated for by the amount of available SAR images. For example, Merot (Mérot, 2007) demonstrated the benefit of soil

moisture monitoring by improving irrigation schedules in gravity-irrigated plots of hay. While the benefit of having highly resolved information is obvious in water balance monitoring, the relevance of SAR products for this purpose needs to be better characterized.

The main objective of this paper is to analyze whether the X-band SAR data currently accessible by the four CSK and two TSX satellites is sensitive enough to provide useful information for the monitoring of irrigated grasslands in southeastern France. This study will focus on the following questions: (i) Is the X-band radar signal sensitive to soil moisture in dense grassland? (ii) Can the X-band detect the beginning of irrigation and monitor the duration of irrigation for each plot, even when the vegetation is well developed? (iii) Is it possible to derive useful parameters related to vegetation characteristics (vegetation height, biomass, vegetation water content, and leaf area index) from the X-band radar signal for this type of irrigated grassland?

These questions are investigated using a time series of TSX and CSK images acquired in HH and HV polarizations and a radar incidence angle near 30° over an agricultural region in southeastern France between April and October 2013. The study site and the database of satellite images and experimental measurements are described in Section 2. The results concerning the correlation between the X-band SAR signals and the soil and vegetation characteristics are presented and discussed in Section 3. In Section 3, the discussion will focus on analyzing (a) the correlation between the X-band radar signal and soil moisture; (b) the potential of the radar data to track irrigation; and (c) the correlation between the X-band radar signal and the biophysical parameters of the vegetation. Finally, conclusions and perspectives are presented in Section 4.

2. Dataset Description

2.1 Study Site

Our study site is the “Domaine du Merle”, an experimental farm of 450 hectares located in southeastern France (center: 43.64° N, 5.01° E, Figure 1). Within this farm, 150 hectares (52 parcels) are irrigated grasslands for hay production. The produced hay is certified (with the French label “AOP”) due to specific environmental factors and irrigation practices that ensure a high-quality floristic composition (Mérot, 2007).

The study site is characterized by a Mediterranean climate, with a rainy season between September and November and an average cumulative rainfall between 350 mm and 800 mm (Courault et al., 2010). The evaporation rate can reach 10 mm/day during the summer season due to high temperatures associated with dry and windy conditions. Hourly temperature and

precipitation data acquired by a meteorological station installed at the study area were available. Figure 2 shows the mean daily air temperature recorded in 2013 during the remote sensing acquisitions ($T_{mean} = 14.4 \text{ }^{\circ}\text{C}$, and $T_{max} = 35.4 \text{ }^{\circ}\text{C}$).

The soil has a mean retention capacity with concentrated vegetation roots in the upper 30 cm (Merot et al., 2008b). Moreover, the top soil is characterized by an absence or low presence of pebble (15%–20% of pebble stone at most) (Mérot, 2007). The top soil texture of the irrigated plots is a loam with a depth varying between 30 cm to 80 cm, depending on the plot age (between 10 years and 3 centuries) (Bottraud et al., 1984; Mérot, 2007).

The plots were leveled with a very gentle slope that allows for surface irrigation by gravity (border irrigation). The total flow rate available for the farm (between 150 and 300 L/s) allows for the irrigation of one or two parcels simultaneously, the largest parcels being split into 2 or more subplots. Water is applied between March and September via canals, which bring water at the highest extremity of the subplots over a few hours. Water flows by gravity down to the lowest extremity of the plots. When the waterfront reaches 90% of the plot length, the water supply is stopped. The waterfront continues to flow and infiltrate until the tail end of the plot is reached. At the lowest side, excess water is evacuated through a drainage channel.

A rotation is applied so that all the parcels can be irrigated when necessary, approximately every 10 days on average. The plots are harvested three times a year, in May, June and September.

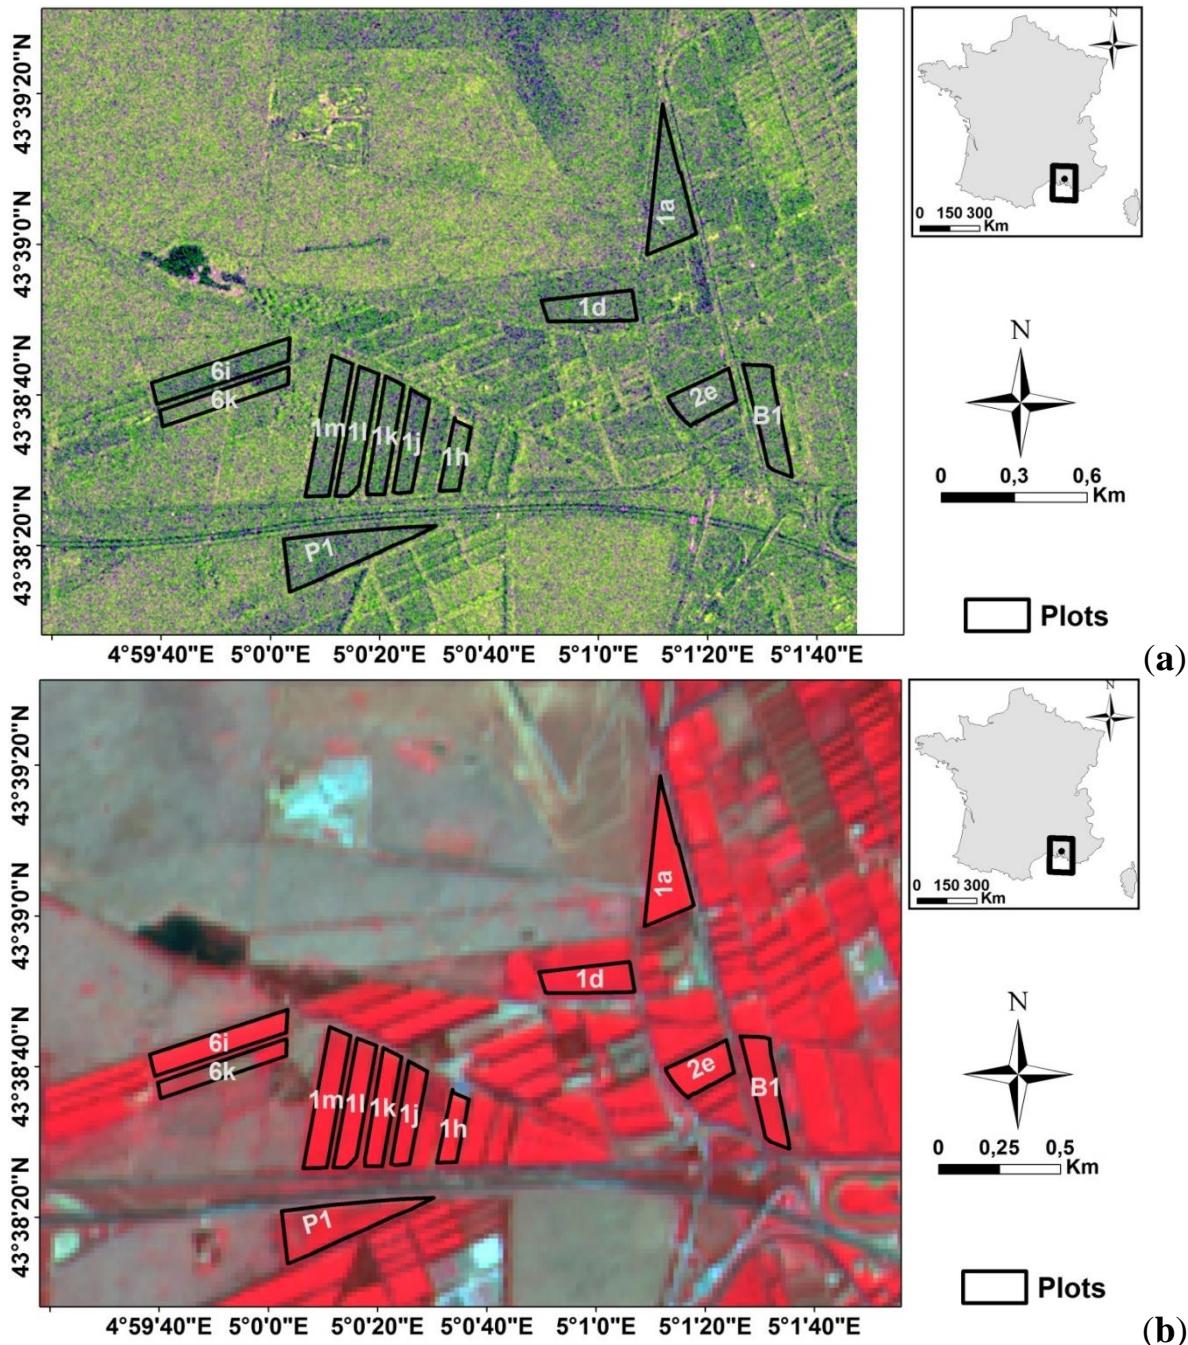


Figure 1. Location of the study site in France (Domaine du Merle). Black polygons delineate the sampled plots. (a) TerraSAR-X image was acquired on April 24, 2013 in RGB colors (R: HH, G: HV, B: HH-HV). (b) SPOT-4 image acquired on April 22, 2013 in RGB colors (R: NIR, G: R, B: G).

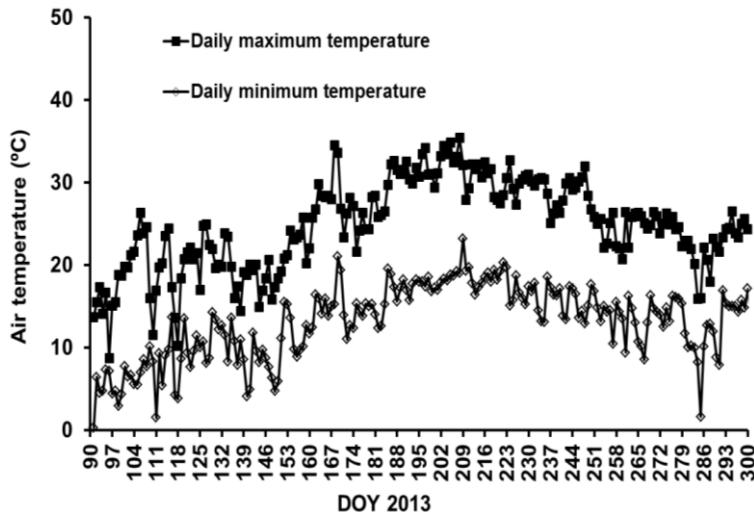


Figure 2. Daily air temperature recorded over the study area.

2.2 Satellite Data and In Situ Measurements

2.2.1 SAR Images

Twenty-five X-band SAR images were acquired by COSMO-SkyMed (CSK) and TerraSAR-X (TSX) sensors between April and October 2013, with incidence angles between 28.3° and 32.5°; both the HH and HV polarizations were analyzed (Tables 1 and 2). The nine TSX images were acquired in “Stripmap mode”, with a ground pixel spacing of 3 m. Sixteen CSK images were obtained from the four satellites in the CSK constellation (6 images from CSK1, 4 images from CSK2, 1 image from CSK3, and 5 images from CSK4) in “Stripmap Pingpong mode”, with a pixel size of 15 m.

Radiometric calibration of the SAR images was carried out using algorithms developed by the German Aerospace Center (DLR) and the Italian Space Agency (ASI). For TSX MGD (Multi Look Ground Range Detected) products, radiometric calibration was carried out using the following equation (Eineder et al., 2008):

$$\sigma^{\circ} = Ks \cdot DN^2 \cdot \sin(\theta) - NESZ \quad (1)$$

This equation transforms the digital number of each pixel DN (the amplitude of the backscattered signal) into a backscattering coefficient (σ°) corrected for background sensor noise known as *NESZ* (Noise Equivalent Sigma Zero) on a linear scale. This calibration takes into account the radar incidence angle (θ) and the calibration constant (Ks) provided in the image data. The *NESZ* must be lower than the term $Ks \cdot DN^2 \cdot \sin(\theta)$ to ensure a high signal-to-noise ratio. For our TSX images, the *NESZ* varies from -25.2 dB to -22.6 dB for both HH

and HV polarizations (Eineder et al., 2008). The calibration of the CSK images is given by the following formula:

$$\sigma^\circ = DN^2 \cdot \frac{1}{K \cdot F^2} \cdot \sin(\theta) R_{ref}^{2 \cdot R_{exp}} \quad (2)$$

where θ is the reference incidence angle, R_{ref} is the reference slant range, R_{exp} is the reference slant range exponent, K is the calibration constant and F is the rescaling factor. For CSK satellites in Pingpong mode with an incidence angle of approximately 30°, Torre *et al.* (2011) reported a noise equivalent sigma zero between -22 dB and -29 dB (depending on the antenna pattern).

The backscattering coefficients are then calculated in decibels using the following formula:

$$\sigma^0_{dB} = 10 \cdot \log_{10} (\sigma^\circ) \quad (3)$$

	Février	Mars				Avril				Mai				Juin						Juillet																
	23	15	16	25	14	17	19	22	24	30	03	04	11	14	22	27	03	04	06	10	11	12	13	14	18	26	28	30	05	08	12	14	16	19	22	29
TSX					X	X	X				X	X																X							X	
CSK																													X	X	X					
SPOT-4 & 5	X	X		X	X			X		X	X												X	X	X			X	X							
LANDSAT-7/8			X		X					X		X	X									X			X			X		X	X	X	X			
Mesures in situ	X				X		X	X		X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X			

	Août												Septembre					Octobre					
	01	09	13	15	18	20	21	22	23	26	29	31	02	03	04	10	22	24	01	04	06	11	16
TSX					X														X				
CSK	X	X								X	X	X				X			X			X	
SPOT-4 & 5	X				X														X			X	X
LANDSAT-7/8			X			X		X		X								X					
Mesures in situ	X	X	X	X		X	X		X	X	X	X	X	X	X	X	X	X	X	X	X	X	

Table 1. Acquisition dates of the SAR and optical images (all within 2013).

Date dd/mm/yyyy	Sensor	Time (UTC)	θ (°)	Range of Mv	Range of VWC	Range of BIO	Range of HVE	Range of LAI
19/04/2013	TSX	19:24	29.1	[0.13–0.23]	[1.54–2.35]	[1.9–3.00]	[0.49–1.20]	[3.98–5.88]
22/04/2013	TSX	07:53	32.5	-	-	-	-	-
30/04/2013	TSX	19:24	29.1	[0.34–0.39]	[1.67–3.35]	[1.99–4.14]	[0.69–1.03]	[3.14–3.87]
14/05/2013	TSX	07:53	32.5	[0.17–0.34]	[0.15–2.65]	[0.30–3.56]	[0.08–1.13]	[0.41–4.71]
22/05/2013	TSX	19:24	29.1	[0.18–0.33]	[0.29–3.11]	[0.46–3.74]	[0.19–1.15]	[1.96–4.90]
06/06/2013	CSK2	07:16	28.3	[0.15–0.31]	[0.33–1.12]	[0.54–1.43]	[0.16–0.41]	[0.26–3.64]
10/06/2013	CSK4	07:16	28.4	[0.23–0.44]	[0.42–1.12]	[0.60–1.43]	[0.20–0.54]	[0.31–3.74]
11/06/2013	CSK1	19:44	30.6	[0.19–0.30]	[0.40–1.12]	[0.60–1.43]	[0.20–0.59]	[0.31–3.77]
14/06/2013	CSK1	07:16	28.3	[0.16–0.34]	[0.56–0.92]	[0.73–1.43]	[0.26–0.74]	[1.30–4.00]
26/06/2013	CSK4	07:16	28.3	[0.15–0.36]	[0.83–1.65]	[1.02–2.06]	[0.37–0.82]	[2.33–4.26]
08/07/2013	TSX	07:53	32.5	[0.15–0.47]	[0.53–2.17]	[0.71–2.74]	[0.15–0.94]	[0.52–3.83]
08/07/2013	CSK2	07:16	28.3	[0.15–0.47]	[0.53–2.17]	[0.71–2.74]	[0.15–0.94]	[0.52–3.83]
12/07/2013	CSK4	07:16	28.3	[0.22–0.32]	[0.34–1.68]	[0.32–2.05]	[0.11–0.80]	[0.10–3.57]
16/07/2013	CSK1	07:16	28.3	[0.16–0.35]	[0.34–1.78]	[0.32–2.09]	[0.10–0.88]	[0.10–3.60]
30/07/2013	TSX	07:53	32.5	[0.26–0.37]	[0.37–1.34]	[0.51–1.62]	[0.20–0.69]	[1.17–3.83]
01/08/2013	CSK1	07:16	28.4	[0.18–0.38]	[0.37–1.34]	[0.51–1.62]	[0.20–0.69]	[1.17–3.83]
09/08/2013	CSK2	07:16	28.3	[0.17–0.35]	[0.51–1.58]	[0.79–1.85]	[0.28–0.70]	[2.05–3.88]
18/08/2013	TSX	19:25	29.1	-	-	-	-	-
26/08/2013	CSK3	07:16	28.4	[0.17–0.26]	[0.44–1.32]	[0.40–1.62]	[0.19–0.82]	[1.44–3.23]
29/08/2013	CSK4	07:16	28.3	[0.11–0.35]	[0.15–2.12]	[0.32–2.70]	[0.19–0.90]	[0.54–3.23]
02/09/2013	CSK1	07:16	28.3	[0.16–0.36]	[0.19–1.8]	[0.28–2.13]	[0.08–0.90]	[0.54–3.25]
10/09/2013	CSK2	07:16	28.3	[0.21–0.39]	[0.03–1.45]	[0.37–1.72]	[0.11–0.50]	[0.30–2.97]
01/10/2013	TSX	19:25	29.1	[0.30–0.39]	[0.97–2.06]	[1.03–2.46]	[0.22–0.85]	[2.10–3.80]
04/10/2013	CSK1	07:16	28.3	[0.23–0.33]	[0.85–2.06]	[1.03–2.46]	[0.22–0.85]	[2.10–3.89]
16/10/2013	CSK4	07:16	28.3	[0.17–0.31]	[1.03–2.23]	[1.22–2.81]	[0.28–0.96]	[2.60–3.90]

Table 2. Main characteristics of the SAR images (TSX and CSK, all in HH and HV polarizations), and a summary of the ground-truth measurements performed on our sampled plots used in this study. θ : radar incidence angle (°), Mv: volumetric soil moisture (cm^3/cm^3), VWC: vegetation water content (kg/m^2), BIO: vegetation biomass (kg/m^2), HVE vegetation height (m), LAI: Leaf Area Index (m^2/m^2).

2.2.2 Optical Images

Thirty one cloud-free optical images were also acquired by SPOT-4, SPOT-5, LANDSAT-7 and LANDSAT-8 sensors over the study area (Table 1). SPOT-4 images were acquired within the framework of the Take 5 experiment (<http://www.cesbio.ups-tlse.fr/>). In most cases, the optical and radar images were not separated by more than four days.

Optical data processing includes orthorectification and correction for atmospheric effects. The atmospheric correction of SPOT-4 images was performed by CESBIO (Centre d'Etudes Spatiales de la BIosphère) according to the method described by Hagolle *et al.* (2008). The atmospheric correction of SPOT-5 and LANDSAT-8 images was carried out using the

simplified method of atmospheric correction (SMAC) (Rahman and Dedieu, 1994). Aerosol optical thickness at 550 nm and the water vapor content (g/m^2), input variables in the SMAC model, were obtained from the AERONET (AErosol Robotic NETwork) website (<http://aeronet.gsfc.nasa.gov/>). Finally, LANDSAT-7 surface reflectance images were downloaded directly from the USGS website (<http://earthexplorer.usgs.gov/>). Atmospheric correction of LANDSAT-7 images was directly performed by the NASA (National Aeronautics and Space Administration) using specialized software called Landsat Ecosystem Disturbance Adaptive Processing System (LEDAPS). This software, applies the 6S (Second Simulation of a Satellite Signal in the Solar Spectrum) radiative transfer model to produce surface reflectance data as described in (Masek et al., 2013). The NDVI was computed from the optical images. Then, NDVI pixel values were averaged for each plot and compared to vegetation *in situ* measurements.

2.2.3 Experimental Measurements

In general, the in situ measurements were collected simultaneously with the SAR acquisitions to characterize the soil and vegetation variability (Table 1). Seven to twelve training plots were sampled (see the locations in Figure 1). The dimension of sampled plot ranges between 2.13 ha and 7.23 ha.

2.2.3.1 Soil Measurements

Volumetric soil moisture measurements were conducted only in the first top 5 cm using calibrated TDR (Time Domain Reflectometry) probes; this was because the radar signal penetration depth in the soil surface is only a few centimetres at X-band (Ulaby et al., 1986). Due to high evaporation rates, the soil moisture measurements were collected within a time window of 2 h around the satellite overpass time. Between 25 and 30 soil moisture measurements were performed for each training plot along regular transects. The volumetric soil moisture was then calculated for each training plot using the mean of all soil moisture measurements collected on the training plot, except for training plots where high spatial heterogeneity of the soil moisture was observed. This heterogeneity is frequent when the plot is under irrigation or when irrigation was finished a few hours before measurements were taken. In this case, several homogenous areas within the training plot were defined. The soil moisture content of each plot (or part of a plot) ranged from $0.10 \text{ cm}^3/\text{cm}^3$ to $0.47 \text{ cm}^3/\text{cm}^3$ (Table 2), with standard deviations between 0.01 and 0.05 cm^3/cm^3 .

Measurements of soil roughness were carried out only once for each training plot using a needle profilometer 1 m in length with 2 cm sampling intervals. Ten roughness profiles were established in each training plot during the period where the vegetation was the lowest (in

April). The following two surface roughness parameters were then calculated from these measurements: the average root mean square surface height ($Hrms$), which specifies the vertical scale of the roughness, and the correlation length (L), representing the horizontal scale (Ulaby et al., 1986). The $Hrms$ values varied between 0.35 and 0.55 cm. The correlation length (L) ranged from 2.00 to 4.60 cm. In general, the precision on the roughness measurements is influenced mainly by the length of the roughness profiles, the number of profiles, and the sampling interval of the profiles. It was demonstrated that significant errors are observed when short profiles with a low sampling interval are used (Lievens et al., 2009; Oh and Kay, 1998). For our smooth soils and X-band SAR data, roughness measurements with a sampling interval better than 1 cm would have been more precise. Given the homogeneous surface roughness in our study site, roughness parameters will not be considered in the sensitivity analysis of the X-band radar signal to soil moisture and vegetation parameters. However, these will be used in an upcoming work dedicated to model the radar signal according to soil and vegetation parameters.

2.2.3.2 Vegetation Measurements

Additional *in situ* measurements of vegetation were performed to estimate the following: the Leaf Area Index (LAI), the vegetation water content (VWC), biomass (BIO) and vegetation height (HVE). For each plot, 20 to 25 hemispherical digital photos were acquired at nadir using a fisheye lens. These photos were then processed using CAN-EYE imaging software to obtain the LAI (<http://www6.paca.inra.fr/can-eye>). Moreover, two grass samples over a 50 cm × 50 cm square were collected to determine the fresh grassland biomass (wet weight per unit area). The fresh biomass was then dried to determine the vegetation water content (wet weight – dry weight). Finally, 20 vegetation height measurements were carried out for each training plot. All vegetation measurements within each plot were averaged to provide a mean value for each plot.

LAI measurements show a high variability due to very quick growth in the irrigated grasslands. For example, the LAI rises rapidly from 0.1 to 3 m²/m² while the vegetation height increases from 10 to 50 cm (the biomass ranges between 0.3 and 1.5 kg/m²) (Figure 3a). A poor correlation ($R^2 = 0.49$) is observed between the LAI and the grassland height when it is less than 50 cm. When the grassland height is greater than 50 cm, the LAI derived from optical photography tends to give saturated values (Figure 3a). The grassland biomass increases linearly with the vegetation height (Figure 3b).

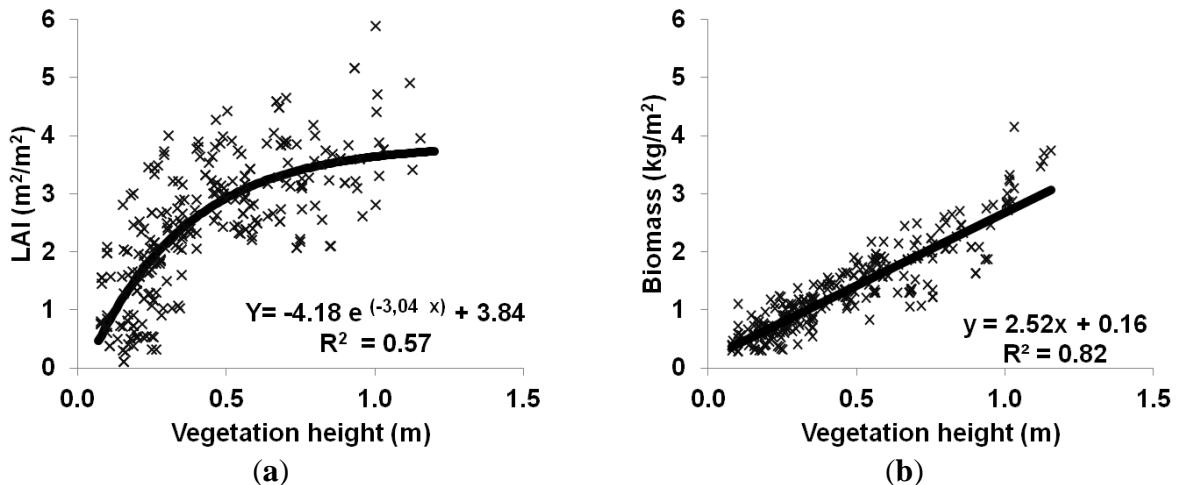


Figure 3. LAI measurements according to vegetation height (a), Biomass measurements according to vegetation height (b).

Figure 4 shows the temporal variations in the main vegetation parameters measured at the plot level. The three cuts of grassland are clearly identified on the graph in May (on approximately DOY 120) in June-July (on DOY 185) and in July-August (on DOY 230). Before the first cut, the vegetation parameters VWC, BIO and HVE are greater values in comparison to values measured during the other growth periods (Mérot, 2007). In general, the first yield always has greater hay production and is devoted to horses; the second and the third harvests are lower. The LAI usually reaches similar maximum values (approximately 3-4 m²/m²) during the first three growth periods (Figure 4). In the fourth period, the LAI values are lower (approximately 2-3 m²/m²). A strong correlation between the different vegetation parameters was observed (Figures 3 and 4). All vegetation parameters increase with time after harvesting, and this increase is very high during the first growth cycle.

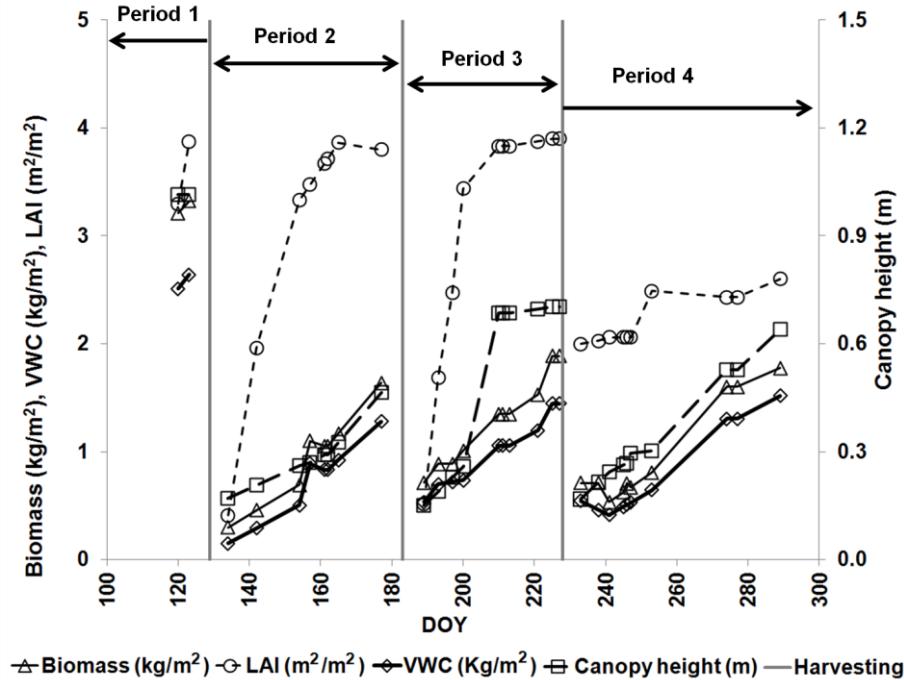


Figure 4. Temporal evolution of vegetation parameters for the sampled plot 1a. Vertical lines indicate cut dates.

3. Results and Discussion

3.1 Relationships between NDVI and Vegetation Parameters

Figure 5a shows the relationship between the LAI estimated from ground measurements and the NDVI computed from different optical images. A classical logarithmic relationship is clearly observed, in accordance with similar results observed by Asrar *et al.* (1984) and Bsaibes *et al.* (2009), and is described by the following equation:

$$LAI = -\frac{1}{k_{LAI}} \ln \left[\frac{NDVI - NDVI_{\max}}{NDVI_{\min} - NDVI_{\max}} \right] \quad (4)$$

where $NDVI_{\max}$ is the NDVI value for a maximum value of LAI ($=0.89$), $NDVI_{\min}$ is the bare soil NDVI value ($=0.22$), and k_{LAI} is the extinction coefficient ($=0.69$). The coefficient of determination R^2 that was obtained is 0.63, with a RMSE (relative mean square error) of 0.72 m^2/m^2 .

Courault *et al.* (2010) found a k_{LAI} of 0.71 from Formosat-2 images acquired on a larger area in the same region, including wheat, rice and irrigated grassland. For wheat plots on the Kairouan plain (Tunisia), Zribi *et al.* (2011) found a k_{LAI} of 1.24.

The correlations between the NDVI and the vegetation parameters HVE, BIO and VWC are displayed in Figure 5b–d. For these graphs, a linear relationship is observed between NDVI and the vegetation variables when the NDVI is less than 0.8. Above this, the NDVI saturates and does not vary with increases in the different vegetation parameters (the threshold value for the estimation of HVE from the NDVI is 30 cm, and the threshold is approximately 1 kg/m² for BIO and VWC).

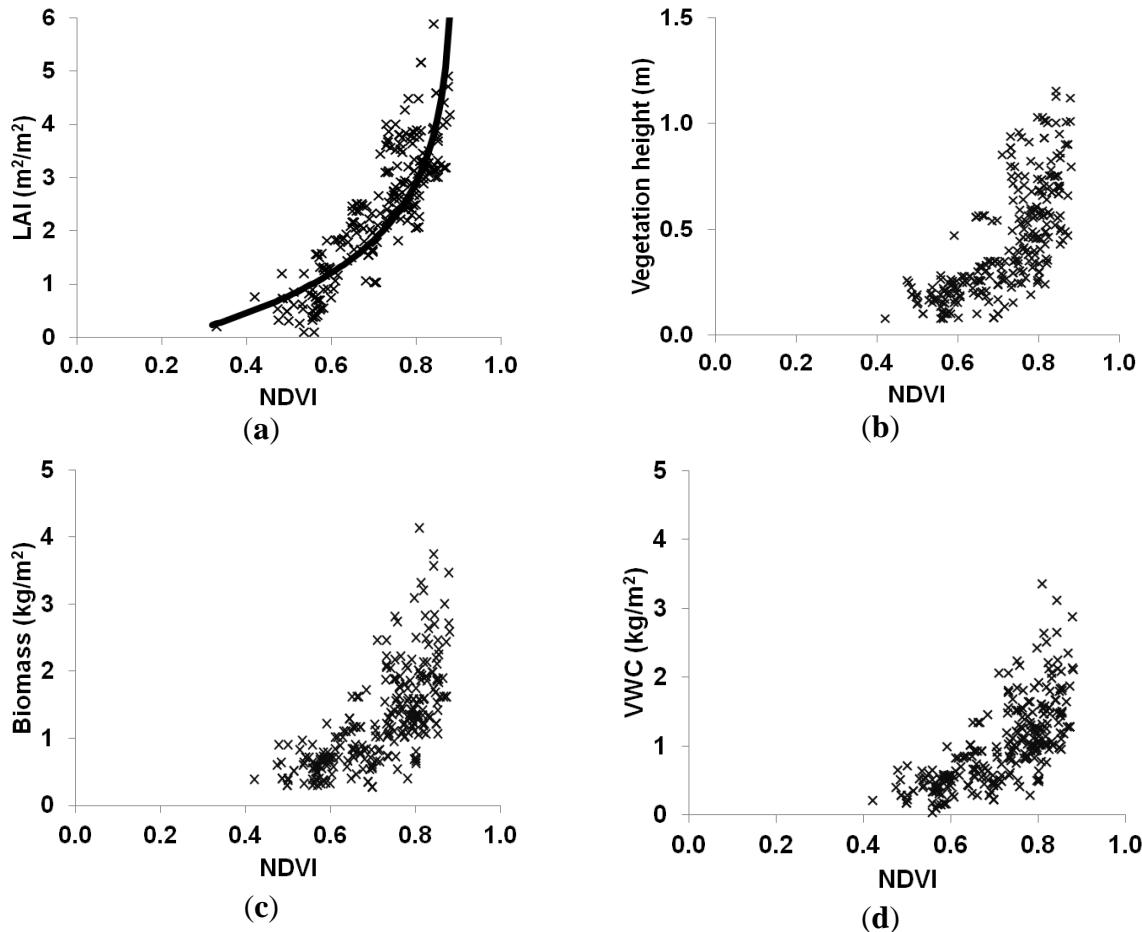


Figure 5. The relationship between the NDVI derived from the optical images and the vegetation measurements ((a) LAI, (b) HVE, (c) BIO and (d) VWC).

3.2 The Radar Response According to Soil Moisture Variations

Figure 6 shows the temporal variations in the radar signal for HH and HV polarizations according to the soil moisture measurements (plot 2e). It shows that the behavior of the radar signal follows the evolution of soil moisture throughout the entire vegetation stage. Similar results were observed for all sampled plots. In Figure 6, the joining lines between symbols represent measurement values (radar signal, M_v , BIO, HVE) and should not be used to retrieve information. These lines are used to make Figure 6 more visible.

The first cut occurred in early June (on DOY 150), and the first irrigation that followed was on DOY 158. Before the first irrigation, the soil moisture was approximately $0.18 \text{ cm}^3/\text{cm}^3$ (on DOY 157). After the first irrigation (on DOY 158) two rainfall events occurred (on DOY 159 and DOY 160, with 3.2 and 9.2 mm precipitation, respectively). Following these events, the soil moisture considerably increased (to approximately $0.40 \text{ cm}^3/\text{cm}^3$ on DOY 161). As a result, the radar signal increased between DOY 157 and DOY 161 in both the HH and HV polarizations of approximately 2.6 dB and 1.9 dB, respectively (the M_v increased to approximately $0.22 \text{ cm}^3/\text{cm}^3$; the HVE was approximately 25 cm). On the SAR image acquired on DOY 162 (4 days after irrigation), HH and HV decreased approximately 2.1 dB due to a decrease in moisture from 0.40 to $0.26 \text{ cm}^3/\text{cm}^3$. On the SAR image acquired on DOY 165, the radar signal continued to decrease due to a decrease in soil moisture (approximately $0.22 \text{ cm}^3/\text{cm}^3$).

Following irrigation on DOY 189, the *in situ* soil moisture was approximately $0.47 \text{ cm}^3/\text{cm}^3$ on DOY 189; the radar signal was high ($\sigma^\circ\text{HH} = -8.0 \text{ dB}$ and $\sigma^\circ\text{HV} = -16.5 \text{ dB}$) and the HVE was approximately 47 cm. Following a large rainfall on DOY 210 (33 mm) and irrigation on DOY 211, the radar signal on DOY 211 showed high HH and HV values ($\sigma^\circ\text{HH} = -9.7 \text{ dB}$ and $\sigma^\circ\text{HV} = -17.7 \text{ dB}$). After two days (on DOY 213), the soil moisture decreased from 0.37 to $0.27 \text{ cm}^3/\text{cm}^3$; the associated radar signal also decreased.

On DOY 241, one day after irrigation on DOY 240, the soil contribution was high on the total backscattered signal despite a HVE high value (HVE approximately 90 cm). Indeed, the radar signal increased approximately 1.4 dB in both HH and HV between DOY 238 and DOY 241 (the M_v increased from 0.20 to $0.35 \text{ cm}^3/\text{cm}^3$). In conclusion, the results show that the radar signal could be used to identify three-day-old irrigated plots.

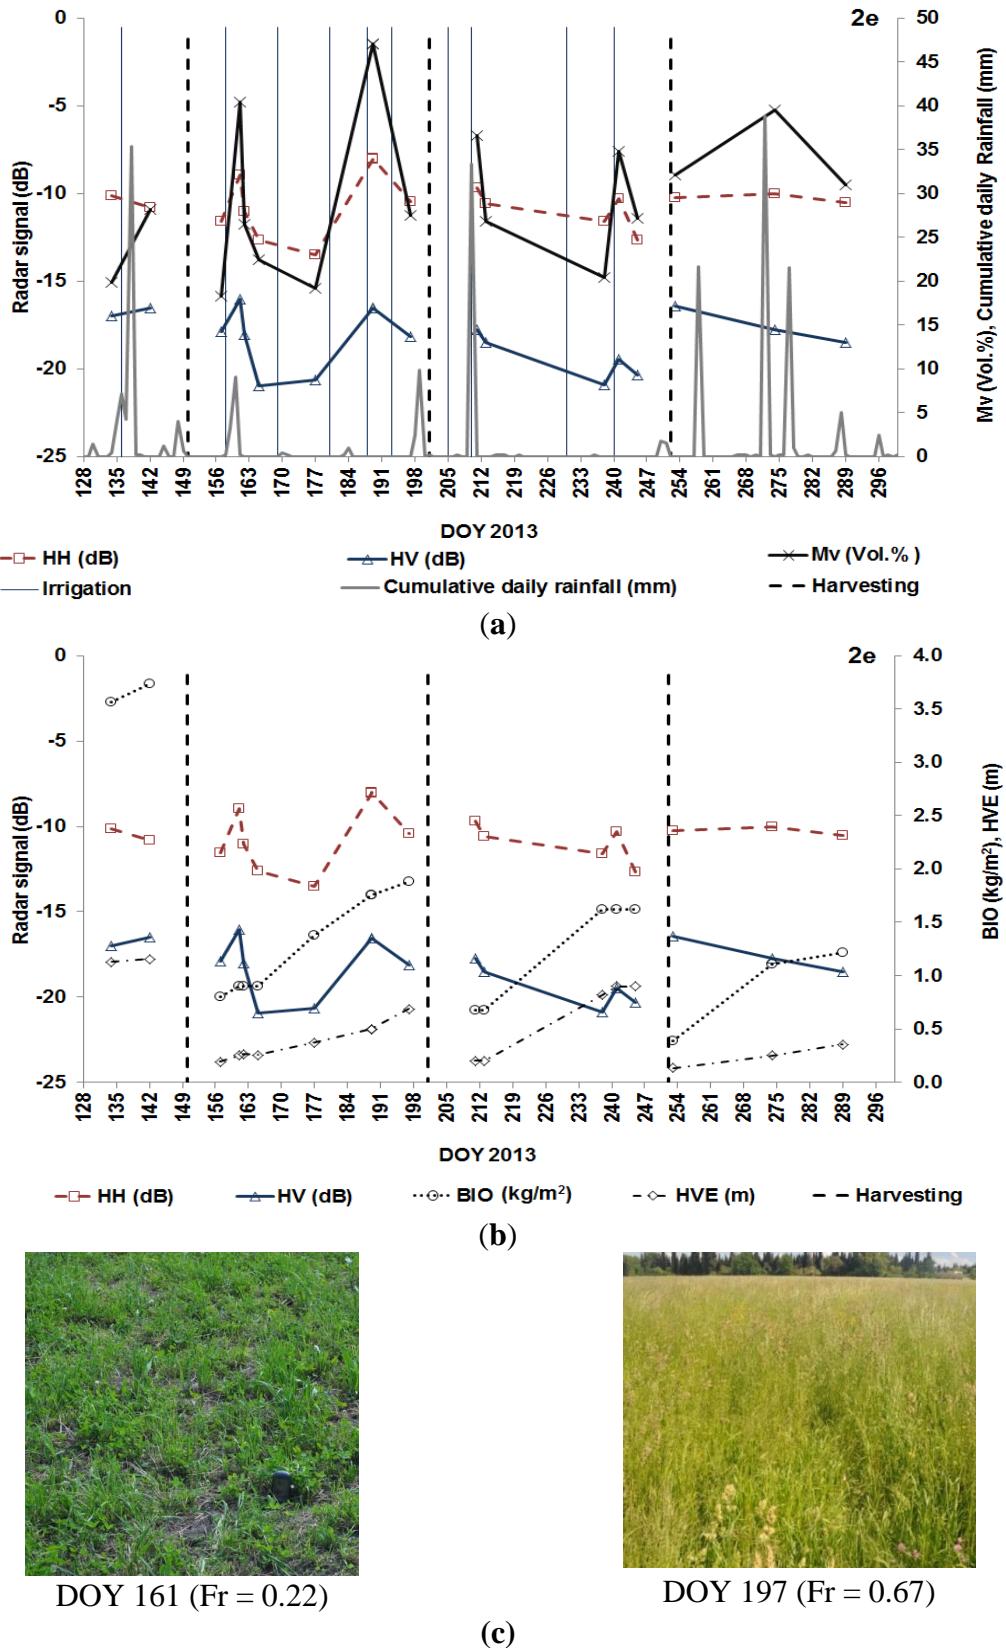


Figure 6. An example of the temporal variation in SAR X-band signals in a given training plot (plot 2e) according to soil moisture (a), and vegetation biomass and height (b). In (c) Photos with associated Fraction vegetation cover (Fr) for plot 2e.

3.3 Sensitivity of Radar Signal to Soil Moisture

The sensitivity of X-band SAR signal to soil moisture was studied for two biomass classes: $BIO < 1 \text{ kg/m}^2$ and $BIO > 1 \text{ kg/m}^2$. The $BIO = 1 \text{ kg/m}^2$ limit corresponds to a vegetation height of approximately 30 cm, a vegetation water content of 0.8 kg/m^2 , and a LAI of approximately $2 \text{ m}^2/\text{m}^2$. First, the mean backscattering coefficients were calculated from calibrated TSX and CSK images over all sampled plots by averaging the linear σ° values of all pixels within the non-flooded training plots or within the non-flooded portions of irrigated plots.

Figure 7 shows that the radar signal for HH and HV polarizations seems to depend on soil moisture variation, with sensitivity to soil moisture for BIO lower than 1 kg/m^2 of approximately 12.64 and $13.40 \text{ dB}/[\text{cm}^3/\text{cm}^3]$ at HH and HV, respectively. Baghdadi *et al.* (2010) showed that when TerraSAR-X data are used after strong rains, the soil contribution (influenced by soil moisture) to the backscattering of sugarcane plots is important when the cane height is less than 30 cm. For BIO higher than 1 kg/m^2 , the sensitivity of the radar signal to soil moisture decreases to 8.83 and $6.39 \text{ dB}/[\text{cm}^3/\text{cm}^3]$ at HH and HV, respectively. These results demonstrated that the soil contribution to the X-band SAR signal could be high for grassland biomass lower than 1 kg/m^2 in both the HH and HV polarizations; the soil contribution also decreases more quickly in HV than in HH for BIO higher than 1 kg/m^2 . These results show that the SAR X-band signal, mainly in HH polarization, can penetrate the canopy and interact with the soil even for vegetation with biomass (when $BIO > 1 \text{ kg/m}^2$). When biomass is both lower and higher than 1 kg/m^2 , the radar response showed more variability for the same soil moisture range in HV than in HH; this is due to the sensitivity of HV polarization to vegetation cover, which has already been observed by Balenzano *et al.* (2011), Brown *et al.* (2003), and Picard *et al.* (2003).

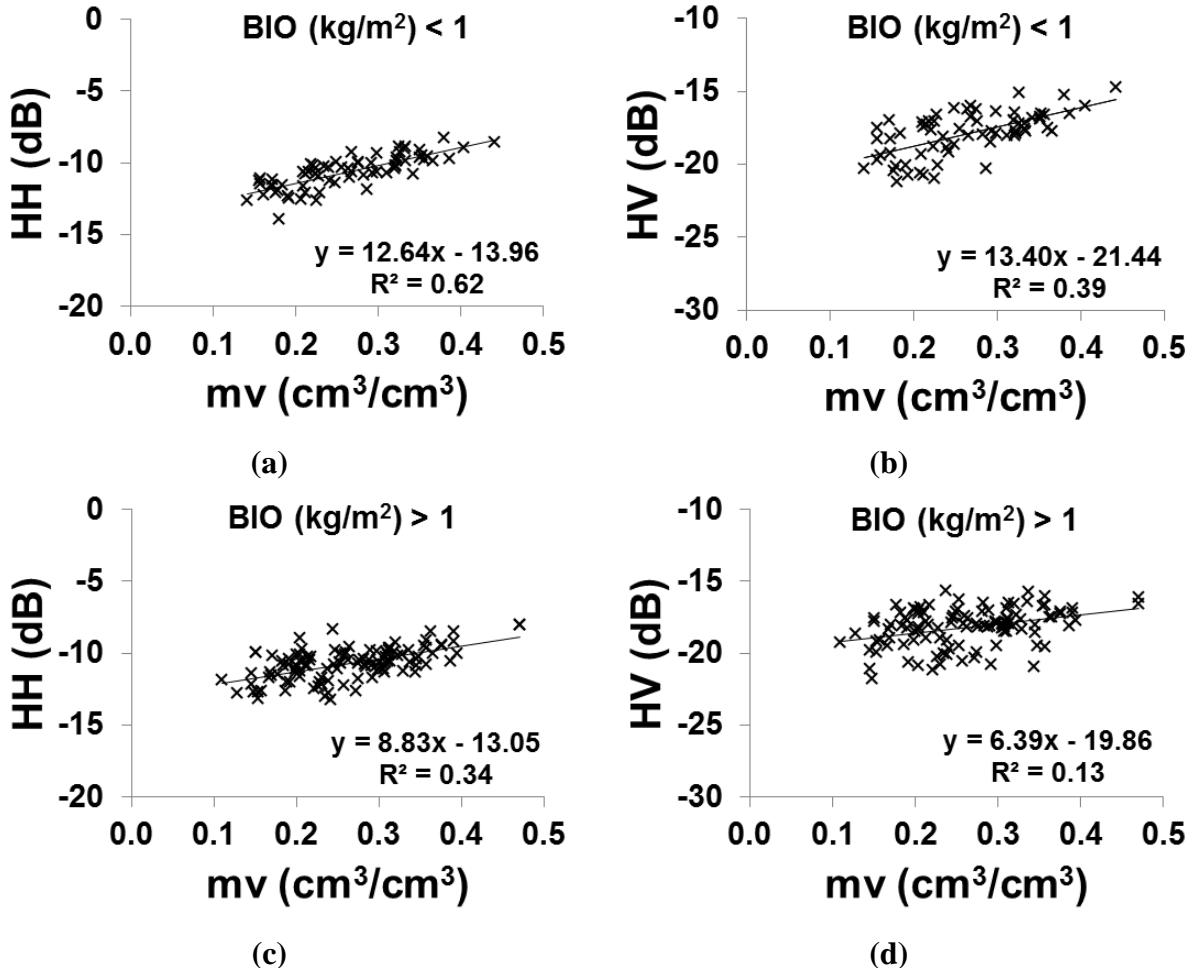


Figure 7. Sensitivity of X-band to soil moisture for biomass lower than 1 kg/m^2 ((a) HH, (b) HV) and for biomass higher than 1 kg/m^2 ((c) HH, (d) HV).

In conclusion, these results show that the X-band radar signal at a medium incidence angle (30°) depends on the soil moisture, regardless of the vegetation conditions. This dependence could be improved with SAR data at lower incidence angles. Indeed, the penetration depth of the radar signal into the vegetation cover is higher at low incidence angles.

3.4 Detection of Flooded Plots

Thanks to the high spatial resolution of the selected radar images ($3 \text{ m} \times 3 \text{ m}$ for TSX, and $15 \text{ m} \times 15 \text{ m}$ for CSK), photo interpretation makes it possible to detect which parts of the plots are flooded by gravity irrigation. The “Domaine du Merle” grassland plots are irrigated every 10 days on average, for durations between 10 and 30 h. The interpretation of SAR X-band images shows that the X-band allows for the tracking of irrigation practices. An analysis of the radar signal was conducted on plots under irrigation at the time of the SAR acquisitions

(Figure 8b-d) and on plots where irrigation was completed a few hours earlier (Figure 8a). *In situ* observations showed that water bodies present on irrigated plots in some locations varied from a few centimeters to thirty centimeters. In plot 6i, *in situ* observations showed that the plot was entirely irrigated during the SAR overpass (the SAR image was acquired 5 h after irrigation) with the presence of two water bodies (Figure 8a). The presence of water could be explained by a leveling defect in some areas and low hydraulic conductivity preventing the quick infiltration of water.

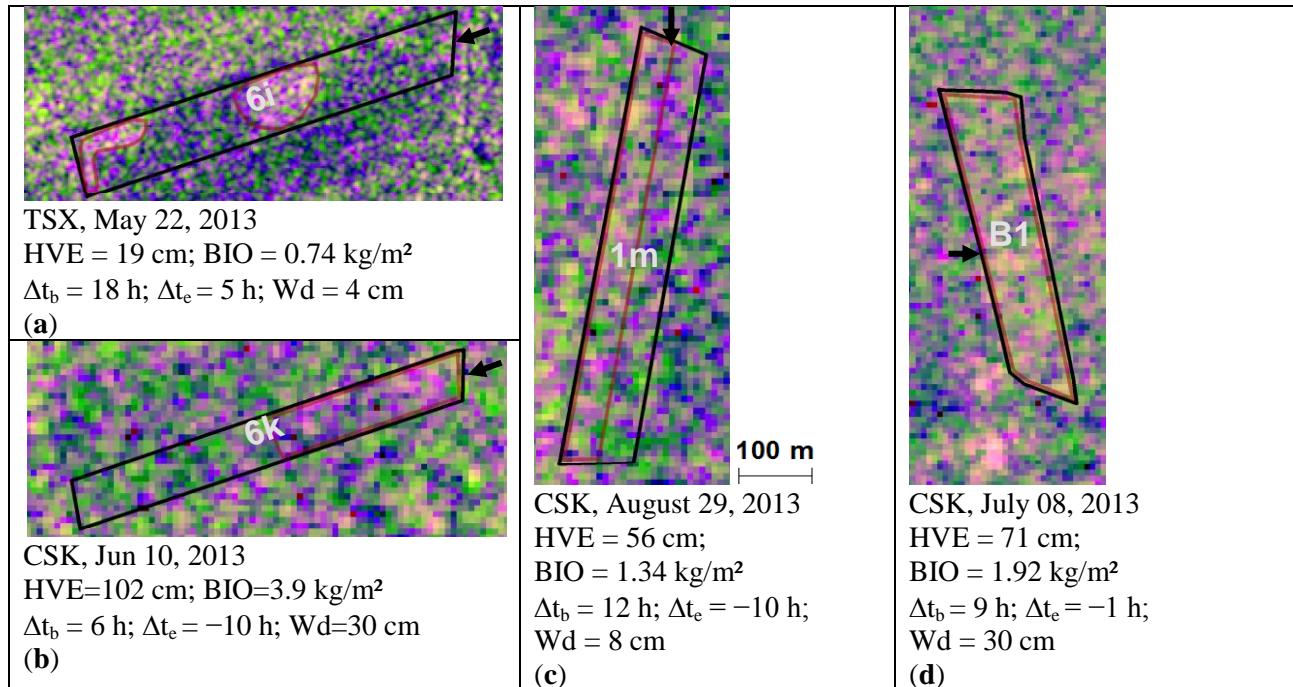


Figure 8. Detection of flooded parts of irrigated plots (in red) (a-d). Δt_b (in hours) = SAR acquisition time–start irrigation time; Δt_e (in hours) = SAR acquisition time–end irrigation time; Wd = Water body depth. Black arrows indicate open canal locations used for border irrigation. Images are in RGB colors (R: HH, G: HV, B: HH-HV).

The analysis showed a higher radar signal at locations with water bodies than at locations without water bodies. The brightest radar returns were caused by double-bounce scattering between the water surface and the vertical stems and leaves of the vegetation. The difference in the radar signal level (Δ) between the flooded areas and the unflooded areas is generally two times greater in HH compared to HV ($\Delta_{HH} \sim 5.5$ dB and $\Delta_{HV} \sim 3.5$ dB). This is due to the attenuation of the backscattered radar signal by the vegetation, which is more significant at HV polarization than at HH polarization. Baghdadi *et al.* (2001) found also that the potential of HH polarization is higher than HV and VV polarizations in a study mapping wetlands from

C-band SAR data. Our results also showed that the penetration depth of the radar wave in the X-band is high, even for dense and tall vegetation. For HVE between 20 and 55 cm and water bodies with depths between 4 and 10 cm, flooded areas are clearly visible on the images (Figure 8a,c). A strong penetration was also observed in other training grassland plots with HVE between 71 and 102 cm and water bodies with depths of approximately 30 cm (Figure 8b,d). These plots corresponded to wet biomass (BIO) values up to 3.9 kg/m².

3.5 Relationships between Radar Signals and Vegetation Parameters

In this section, the backscattered signal was analyzed as a function of vegetation parameters (LAI, HVE, BIO, and VWC). Grassland plots contain approximately 20 different species of vegetation. The main vegetation species are grasses (*Dactylis glomerata L.*, *Lolium perenne L.*, *Poa pratensis L.*, *Holcus lanatus L.*, *Arrhenatherum elatius L.*, *Festuca pratensis L.*, *Setaria glaucus L.*, and *Paspalum dilatatum Poir*), legumes (*Medicago lupulina L.*, *Trifolium repens L.*, *Trifolium pretense L.*, *Lotus corniculatus L.*, and *Vicia cracca L.*), and diverse dicotyledons (*Plantago lanceolata L.*, *Taraxacum officinale Weber.*, *Tragopogon pratensis L.*, *Galium mollugo L.*, *Galium verum L.*, *Daucus carota L.*, *Achillea millefolium L.*, *Pastanica silvestris L.*, and *Rumex acetosa L.*) (Merot et al., 2008a). At plot scale, the vegetation structure geometry is homogeneous. The biomass levels of these species vary during the growth season. In the first growth period, grass species are dominant (60%–65%). Grass biomass levels decrease in the second and third growth periods. However, legume and diverse dicotyledon biomass levels increase from 35%–40% in the first period to 55% in the third period (Mérot, 2007). An important change in morphology is observed, especially in grass species, when vegetation exceeds approximately 50 cm (LAI about 3 m²/m², BIO about 1.5 kg/m² and VWC about 1.2 kg/m²); inclined elements (panicle, small leave, etc.) randomly oriented at the top of the plant begin to appear. The VWC and plant morphology are the main vegetation variables that affect the radar response (Ulaby et al., 1975). It was therefore essential to study the relationship between the radar signal and vegetation parameters (LAI, HVE, BIO and VWC) separately according to two vegetation classes (LAI, HVE, BIO and VWC lower and higher than 2 m²/m², 50 cm, 1.5 kg/m², and 1.2 kg/m² respectively). To reduce the effect of soil moisture on the analysis of the backscattered radar signal, relationships between radar signals and vegetation parameters were traced according to three classes of soil moisture (Mv < 0.2, 0.2 < Mv < 0.3 and Mv > 0.3 cm³/cm³).

Figure 9 shows the behavior of the SAR X-band signal according to LAI. The results showed that for soil moisture between 0.10 and 0.20 cm³/cm³, the radar signal in HH and HV decreases with LAI for LAI lower than 2 m²/m², and increases as the LAI increases from 2 m²/m² to 5 m²/m². These variations in the radar signal (decrease and increase) are higher in

HV polarization than in HH polarization (Figure 9a,b). The decrease in radar signal for LAI lower than $2 \text{ m}^2/\text{m}^2$ is related to an increase in the attenuation of the soil contribution; this is more important than the enhanced contribution from the vegetation canopy (Balenzano et al., 2011; Brown et al., 2003; Mattia et al., 2003). In addition, the increase in the vegetation contribution as a function of the LAI, combined with the decrease in the soil moisture contribution (M_v between 0.10 and $0.20 \text{ cm}^3/\text{cm}^3$), results in a slight increase in the radar backscatter with LAI for values greater than $2 \text{ m}^2/\text{m}^2$. For M_v between 0.20 and $0.50 \text{ cm}^3/\text{cm}^3$, the radar signal slightly decreases in HH and HV polarization for LAI between about 0.1 and $5.0 \text{ m}^2/\text{m}^2$ (Figure 9c,d). Indeed, for M_v between 0.20 and $0.50 \text{ cm}^3/\text{cm}^3$, the decrease of the soil contribution when LAI increases between 0.1 and $5.0 \text{ m}^2/\text{m}^2$ is of the same order than the increase of the vegetation contribution. Many studies have analyzed the behavior of radar signals (Ku, X, C and L bands) as a function of LAI (Champion, 1991; Fieuza et al., 2013; Fontanelli et al., 2013; Lin et al., 2009; Liu et al., 2013; Macelloni et al., 2001; Ulaby et al., 1984). Previous results have shown that the radar signal decreases with an increase in the LAI for narrow leaf crops (wheat, alfalfa, and barley), and increases for broad leaf crops (sunflower, corn, sorghum, and sugarcane) (Fontanelli et al., 2013; Macelloni et al., 2001). For example, Champion (Champion, 1991) studied the sensitivity of radar signals in C and X bands to the LAI of wheat crops (soil moisture values between 0.05 and $0.20 \text{ cm}^3/\text{cm}^3$) in using HH and VV polarizations (20° for the C band and 40° for the X band). In this study, the signal decreased approximately 8 dB in the X-band for LAI values between 0.1 and $3 \text{ m}^2/\text{m}^2$, and the signal decreased approximately 12 dB in the C-band for LAI between 0.1 and $4 \text{ m}^2/\text{m}^2$. The signals at C and X bands increase approximately 7 dB with LAI for LAI values up to $8 \text{ m}^2/\text{m}^2$. Similar results on the behavior of X-VV radar signal according to LAI of wheat were found by Prévot et al. (1993) for soil moisture values between $0.05 \text{ cm}^3/\text{cm}^3$ and $0.20 \text{ cm}^3/\text{cm}^3$. Fieuza et al. (2013) analyzed wheat crops with LAI values between 1 and $4 \text{ m}^2/\text{m}^2$ in wet soil conditions (soil moistures between 0.20 and $0.40 \text{ cm}^3/\text{cm}^3$); the radar signals in the X and C bands decreased with the LAI by approximately -2.6 dB by $1 \text{ m}^2/\text{m}^2$ for X-HH and -2.4 dB by $1 \text{ m}^2/\text{m}^2$ for C-VV. The C-HH and C-HV signals have lower sensitivity, with about -1 dB by $1 \text{ m}^2/\text{m}^2$. Ulaby et al. (1984) demonstrated that the radar signal at Ku-VV (50°) increases with the LAI of corn and sorghum, up to LAI of approximately $2 \text{ m}^2/\text{m}^2$; beyond this, the radar signal saturates. Lin et al. (2009) observed increasing radar responses in sugarcane plots when the sugarcane LAI increased (with the C-band and incidence between 31° and 39°). This increase is greater in HV than in HH due to higher volume scattering in HV compared to HH. In a study by Liu et al. (2013), the radar signal in the C band (24° and 47°) increased with the LAI in soybean and corn crops.

Figure 10 shows the behavior of the SAR X-band signal according to HVE using different soil moisture classes. The results showed that for vegetation heights lower than 50 cm , the

radar signal decreases with HVE. This decrease in the radar signal for vegetation heights lower than 50 cm is higher in HV polarization than in HH polarization (approximately -0.5 dB and -1.1 dB by 10 cm in HH and HV, respectively). The attenuation is stronger for HV than for HH due to the vertical plant stems, and the attenuation increases with stem height (Brown et al., 2003; Cookmartin et al., 2000; Mattia et al., 2003; Picard et al., 2003). Consequently, the soil contribution to the total backscatter is lower at HV than at HH polarization. Fieuza et al. (2013) showed that for wheat height is between approximately 3 and 65 cm, the radar signal at X-HH decreases by 1.3 dB as the HVE of wheat increases by 10 cm. Beyond 50 cm, the radar signal slightly increases at both HH and HV when head element flowers begin to appear at the top layer of grassland vegetation (Figure 9). When plants are higher than 50 cm, the backscattered signal is mainly due to the leaves, stems and the head element flowers (Cookmartin et al., 2000). According to Figures 6 and 7, the soil also contributes slightly to HVE higher than 50 cm. The increase in the radar signal from HVE above 50 cm is greater in HV than in HH due to the greater contribution of vegetation in HV than in HH.

Figures 11 and 12 show the behavior of the SAR X-band signal according to BIO and VWC using different soil moisture classes. Result shows that the HH polarization appears to be insensitive to fresh biomass and vegetation water content. The results also showed that HV slightly decreases with BIO and VWC (BIO and VWC are well correlated) to a threshold about 1.5 kg/m^2 , then increases slightly.

Overall, the use of X-band radar signal with medium incidence angle ($\sim 30^\circ$) for the retrieval of LAI, HVE, BIO, and VWC of our grassland is very limited. Only the canopy height could be retrieved for heights lower than 50 cm and in using HV polarization. Results show that the opportunity to estimate the soil moisture even with dense vegetation covers (vegetation height up to 1 m). Indeed, the X-band radar signal penetrates vegetation cover and always follows the evolution of soil moisture. In the future, the opportunity to estimate soil water content using semi-empirical backscattering models (such as water cloud model) will be investigated.

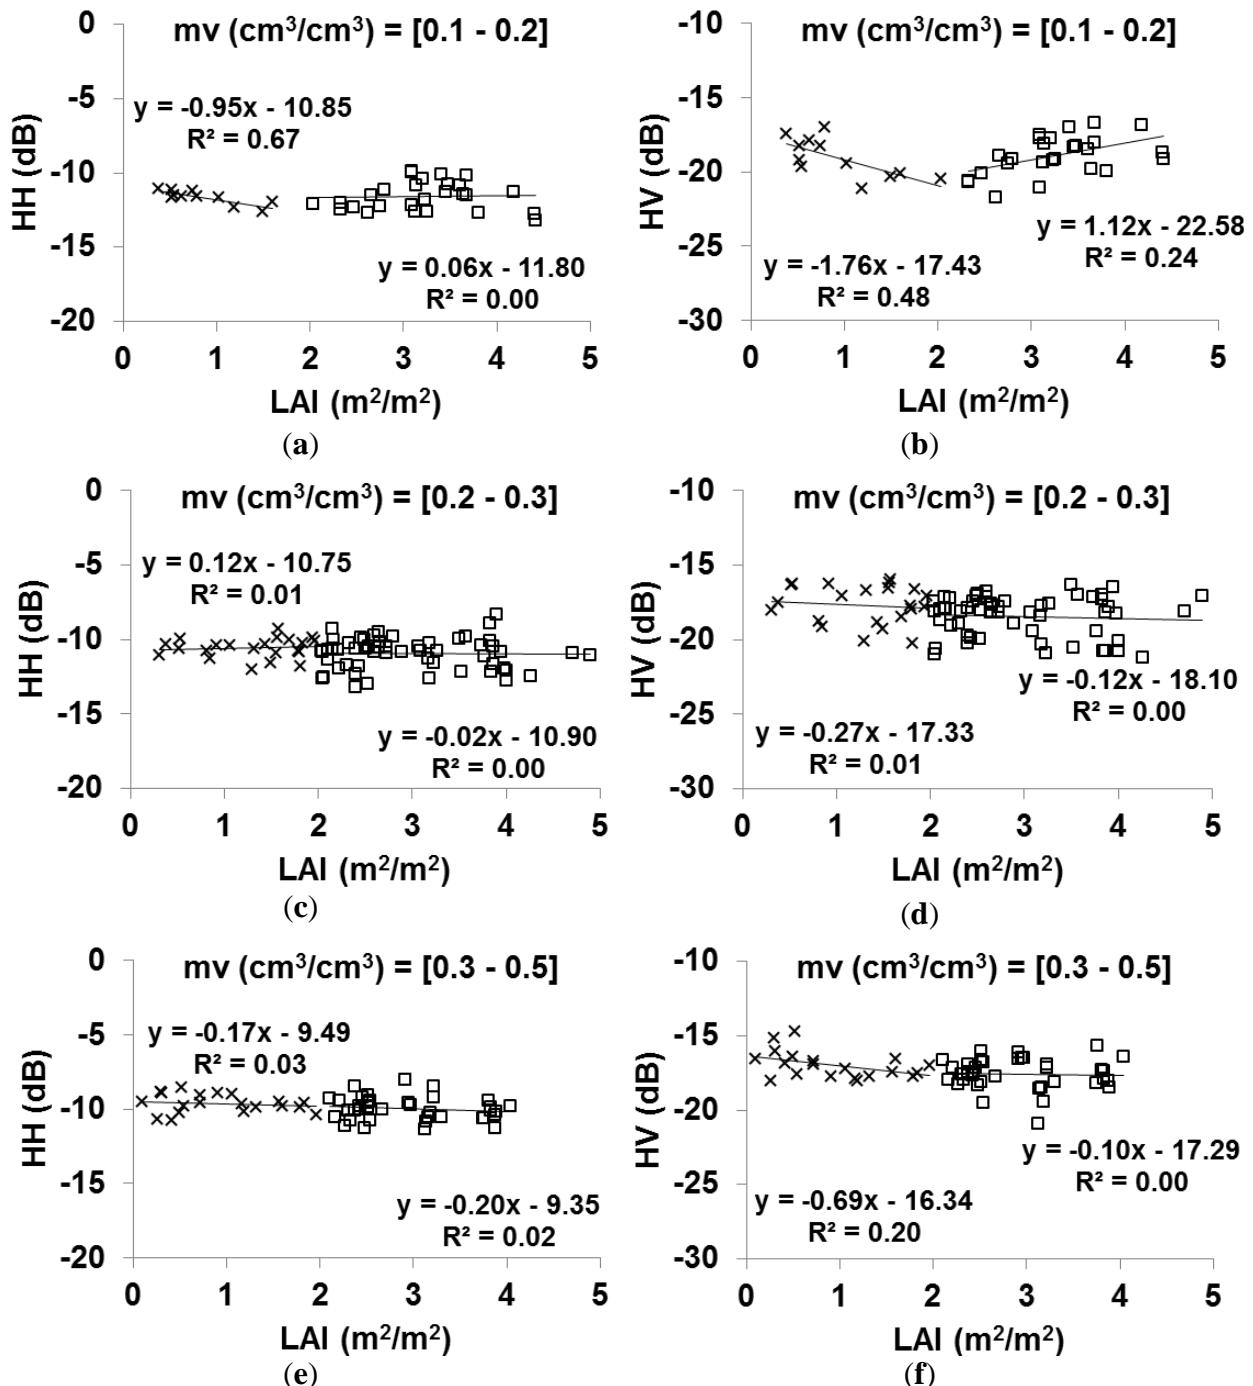


Figure 9. Sensitivity of X-band ((a,c,e) HH, and (b,d,f) HV) to LAI in three soil moisture (Mv) classes.

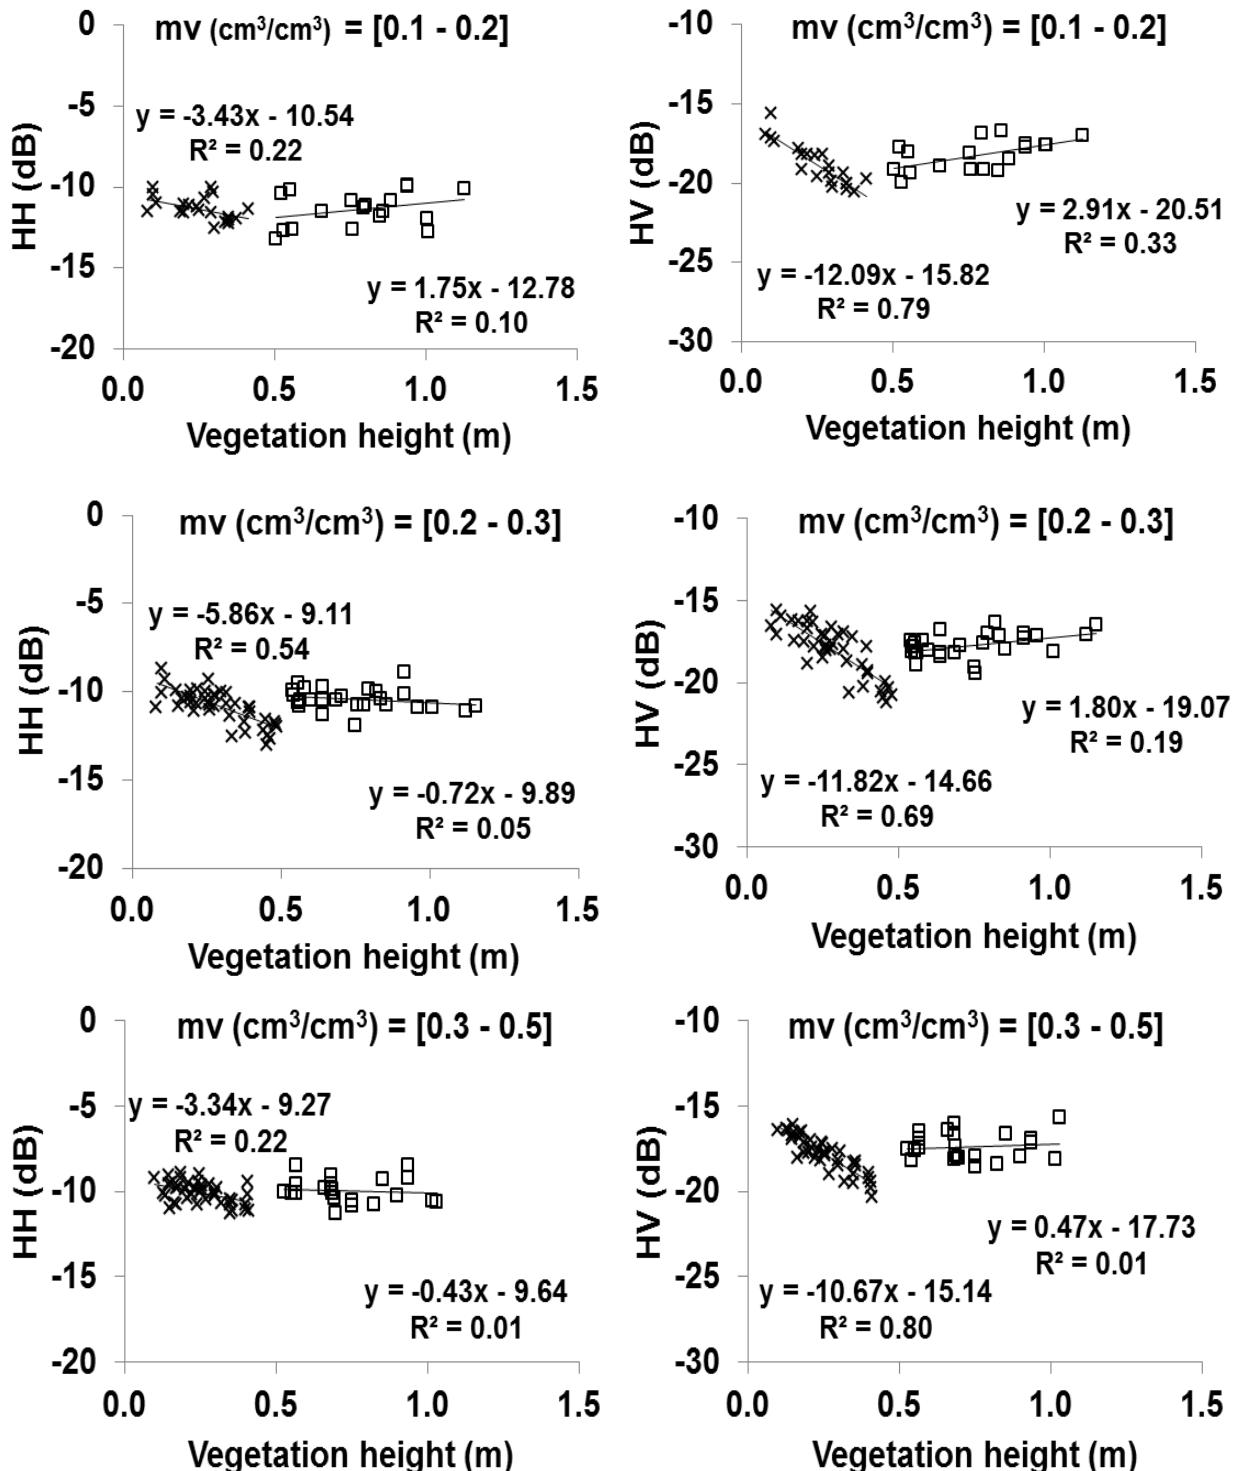


Figure 10. Sensitivity of X-band ((left) HH, and (right) HV) to vegetation height in three soil moisture (Mv) classes.

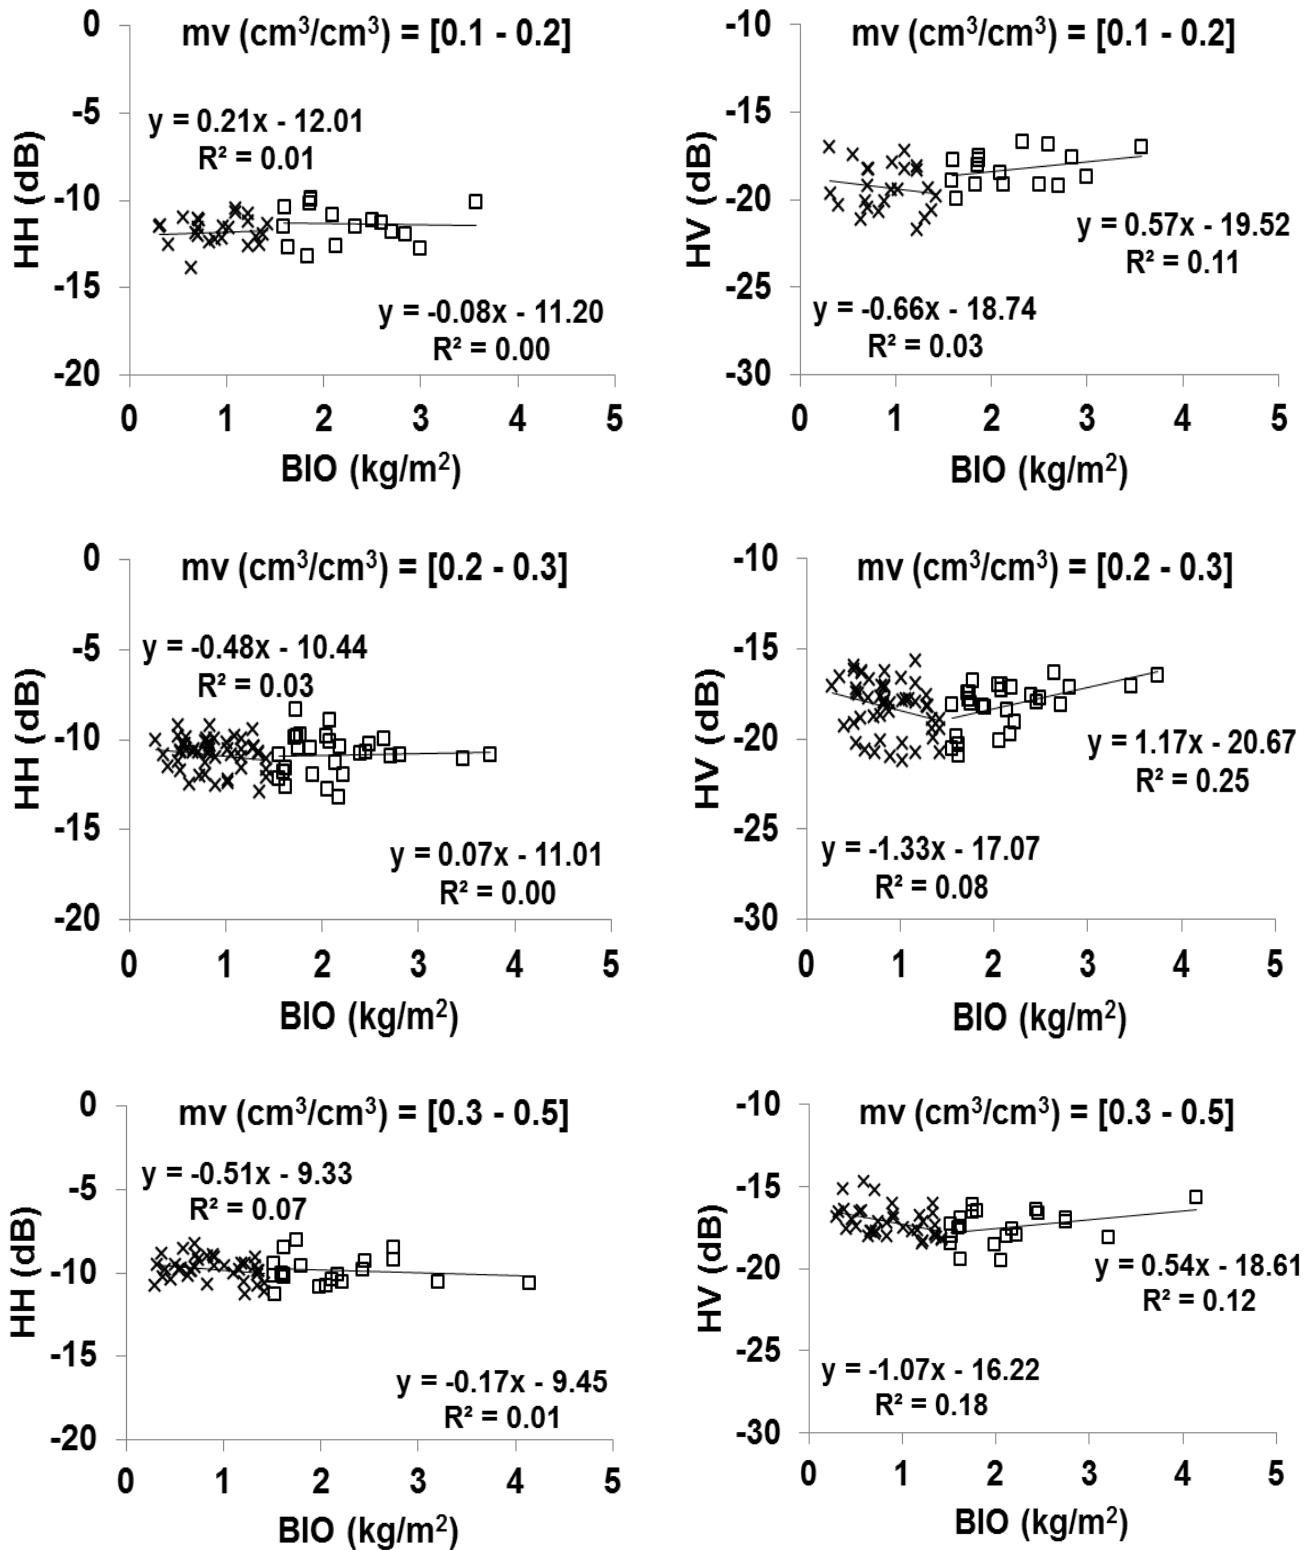


Figure 11. Sensitivity of X-band ((left) HH, and (right) HV) to BIO in three soil moisture (Mv) classes.

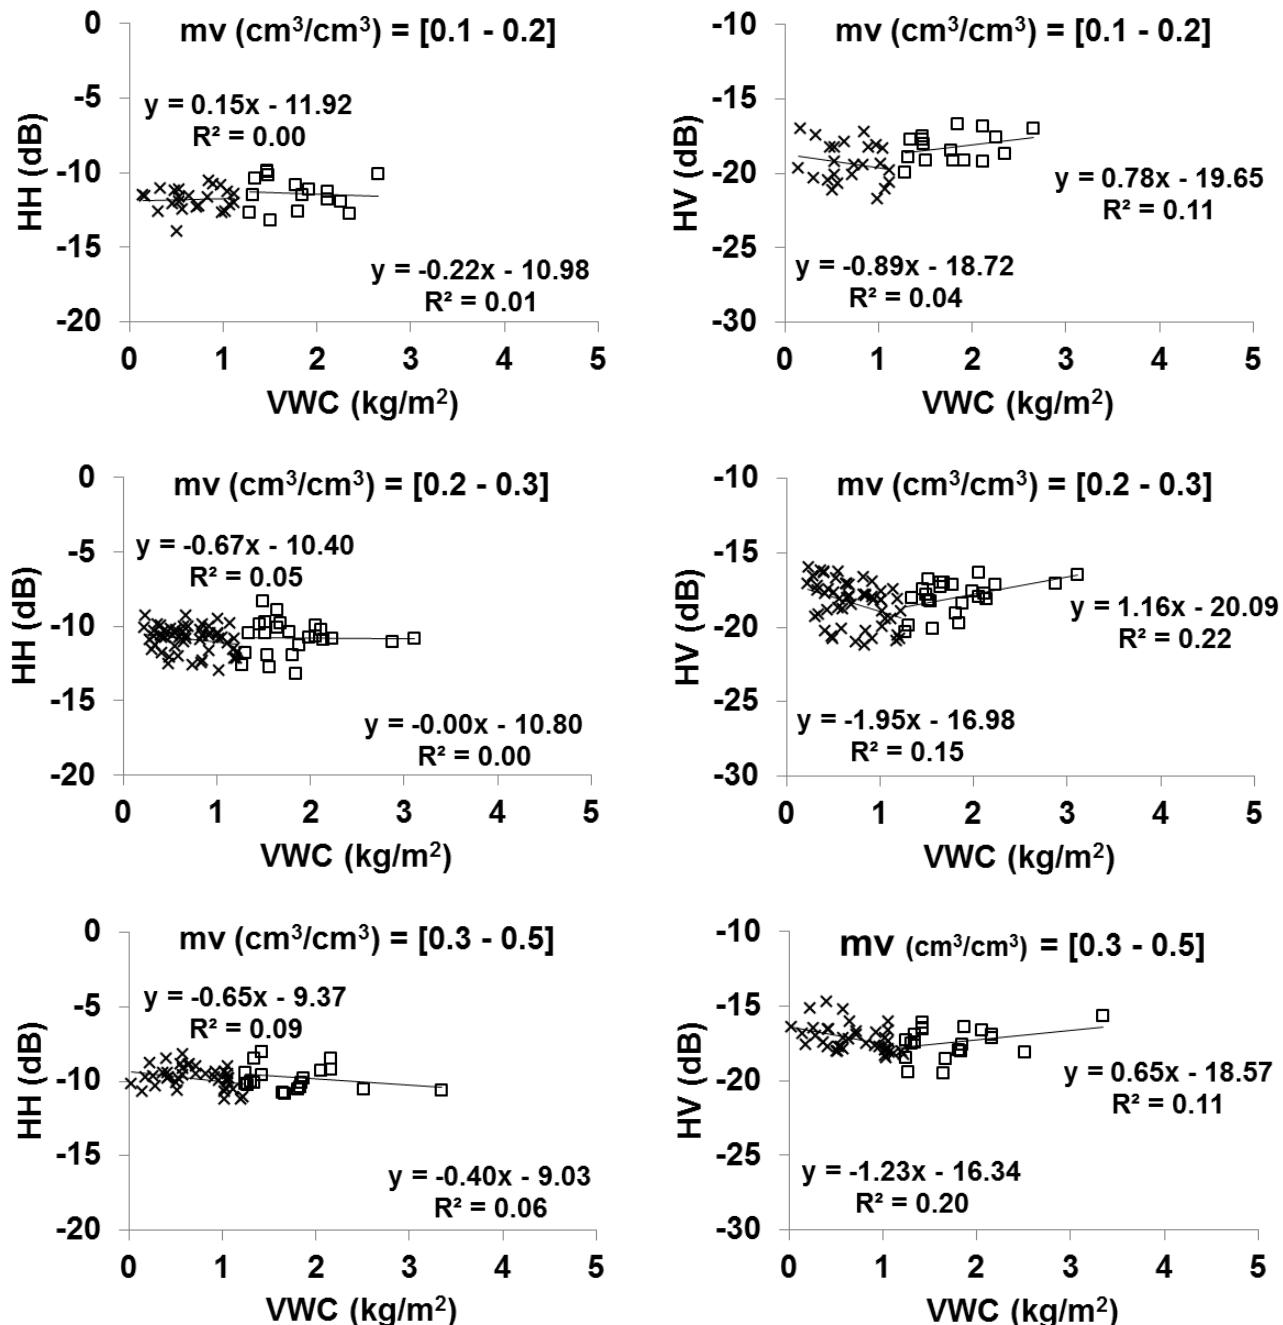


Figure 12. Sensitivity of X-band ((left) HH, and (right) HV) to VWC in three soil moisture (Mv) classes.

4. Conclusions and Perspectives

This study analyzed the temporal signature of SAR X-band signals acquired over irrigated grassland plots over several growing cycles. The objective of this work was to investigate the sensitivity of radar signals to soil moisture and vegetation parameters (LAI, vegetation height, biomass, and vegetation water content).

Our results show that the radar signal in the X-band at both HH and HV polarizations seems to be sensitive to soil moisture variations, even with dense vegetation cover (HVE up to 1 m). This sensitivity decreases as vegetation density increases (higher sensitivity for biomass lower than 1 kg/m^2). This result proves that the X-band radar signal penetrates the grassland cover (with vegetation height up to 1 m) and allows for the tracking of irrigation practices. In addition, the X-band at HV polarization is more sensitive to grassland parameters than at HH polarization; however, the potential use of the X-band for the monitoring of vegetation parameters is very limited. The X-band radar signal at HV polarization is useful for the monitoring of HVE up to 50 cm.

The X-band radar signal is sensitive enough to variations in soil moisture to monitor soil moisture over grasslands. An inversion method based on backscattering models should be developed to analyze the precision of soil moisture estimates using X-band radar images over grassland. The objective of our future work is to develop methodologies based on the coupling of X-band SAR and optical data to estimate soil moisture. The arrival of Sentinel-1 and Sentinel-2 constellations, which have the ability to provide images with high repetition, will allow scientists to combine optical and radar images to estimate soil moisture in agricultural environments.

CHAPITRE 4 :

*Estimation de l'humidité du sol à partir d'images radar en
bande X*

1. Objectifs

Pour estimer l'humidité du sol en présence de végétation (blé, pâturage, soja...) la majorité des études ont utilisé des données radar en bande C (Gherboudj et al., 2011; He et al., 2014; Notarnicola et al., 2006; Prévot et al., 1993; Sikdar and Cumming, 2004; Wang et al., 2011; Yang et al., 2012; Yu and Zhao, 2011; Zribi et al., 2011). Cependant, très peu d'études ont utilisé des données radar en bande X pour estimer l'humidité du sol en présence du couvert végétal (Kseneman et al., 2012; Soon-Koo Kweon et al., 2012).

L'objectif de cette partie de la thèse est de monter le potentiel des images radar petite longueur d'onde (bande X, 3 cm), combinées avec des images optiques, pour l'estimation de l'humidité du sol en présence d'un couvert végétal parfois relativement dense.

2. Base de données

La base de données images (radar et optique) et *in situ* est présentée dans le chapitre 2. Nous utiliserons en plus des estimations de LAI, FAPAR et FCOVER qui ont été dérivées à partir des images optiques en utilisant l'outil BV-NNET (Biophysical Variables Neural NETwork) développé par Baret *et al.* (2007).

Au final, la base de données utilisée dans ce chapitre est composée des observations radar en bande X (TerraSAR-X et CosmoSky-Med), des mesures *in situ* sur le sol et la végétation (M_v , BIO, VWC, HVE, LAI, FAPAR et FCOVER), et des paramètres dérivés des données optiques (NDVI, LAI, FAPAR et FCOVER).

3. Méthode

Le modèle semi-empirique de rétrodiffusion radar Water-Cloud (WC) développé par Attema et Ulaby (1978) a été utilisé dans cette étude pour modéliser le signal radar en fonction de l'humidité volumétrique du sol (M_v) et des paramètres de la végétation. Ce modèle a été choisi car il est simple et ne nécessite que peu de paramètres d'entrée. De plus, dans cette étude, la technique des réseaux de neurones a été utilisée pour inverser le signal radar et estimer l'humidité du sol.

La méthodologie consiste à (1) ajuster le modèle WC, (2) générer des données synthétiques de coefficient de rétrodiffusion radar en utilisant le modèle WC, (3) brouter les données synthétiques générées pour qu'elles ressemblent à des données réelles, (4) entraîner les réseaux de neurones en utilisant les données synthétiques bruitées et (5) inverser le signal radar sur les données synthétiques et réelles en utilisant les réseaux de neurones entraînés.

3.1 Modélisation du signal radar

Le modèle WC modélise le signal radar rétrodiffusé (σ_{tot}) comme la somme de la contribution de la végétation (σ_{veg}^0) et de celle du sol, atténué par la végétation ($T^2 \sigma_{\text{sol}}^0$) (Eq.4-7). La contribution de l'interaction sol-végétation sur le signal rétrodiffusé est ignorée dans le modèle WC. Le modèle a été ajusté par rapport aux données radar (polarisations HH et HV), mesures terrain (Mv, BIO, VWC, HVE, LAI, FAPAR, FCOVER), et NDVI pour estimer les différents coefficients du modèle (A, B, C, et D). Une fois le modèle ajusté, il devient possible de simuler des rétrodiffusions radar en utilisant des valeurs théoriques de M_v et d'un descripteur de la végétation (BIO, VWC, HVE, LAI, FAPAR, FCOVER ou NDVI).

$$\sigma_{\text{tot}}^0 = \sigma_{\text{veg}}^0 + T^2 \sigma_{\text{sol}}^0 \quad \text{Eq.4}$$

$$\sigma_{\text{veg}}^0 = A \cdot V_1 \cdot \cos \theta \cdot (1 - T^2) \quad \text{Eq.5}$$

$$T^2 = \exp(-2 \cdot B \cdot V_2 \cdot \sec \theta) \quad \text{Eq.6}$$

$$\sigma_{\text{sol}}^0 = C(\theta) \exp(D \cdot M_v) \quad \text{Eq.7}$$

D'où:

- V_1 et V_2 sont des descripteurs de la végétation (BIO, VWC, HVE, NDVI, LAI, FAPAR, et FCOVER)
- θ est l'angle d'incidence
- A et B sont des paramètres du WC dépendent des paramètres de la végétation, et des configurations radar
- C dépend de rugosité du sol et des paramètres instrumentaux (dans notre cas de la polarisation)
- D est la sensibilité du signal radar (unité linéaire) à l'humidité du sol nu (dépend de la configuration radar).
- M_v est l'humidité volumétrique du sol.

3.2 Génération des données synthétiques

Les données synthétiques ont été générées en utilisant le modèle WC paramétré. Ces données synthétiques sont utilisées par la suite dans les procédures conduisant à estimer l'humidité du sol à partir des réseaux de neurones. Le modèle WC paramétré permet de générer la

rétrodiffusion radar en polarisations HH et HV en utilisant comme variables d'entrées le M_v et un descripteur de la végétation. Seulement quatre bases de données synthétiques ont été générées, en utilisant NDVI, LAI, FAPAR et FCover comme descripteur de la végétation. Ceci dans le but d'offrir une perspective pour des futures études sur le couplage des données SAR et optique pour l'estimation de l'humidité du sol. En effet, des nombreuses études ont développé des méthodes pour estimer LAI, FAPAR et FCover à partir d'images optiques (Baret and Guyot, 1991; Bsaibes et al., 2009; Carlson and Ripley, 1997; Carlson et al., 1994; Claverie et al., 2013; Courault et al., 2008; Darvishzadeh et al., 2008b; Duveiller et al., 2011; Fensholt et al., 2004; Guerschman et al., 2009; Li et al., 2014; North, 2002).

Nous nous focalisons sur le résultat de l'estimation de M_v obtenue en utilisant la base de données synthétiques avec le NDVI comme descripteur de la végétation. En effet, le NDVI est plus simple à calculer à partir des données optiques que les LAI, FAPAR et FCover. La base de données synthétiques avec NDVI comme descripteur de la végétation est composée de 80 "éléments" : 8 valeurs de M_v (M_v entre 10 et 45 Vol.% avec un pas de 5 Vol.%), et 10 valeurs de NDVI (NDVI entre 0.45 et 0.90 avec un pas de 0.05). La gamme de variation utilisée de M_v et NDVI est égale à la gamme des valeurs observées sur le terrain pour M_v (*in situ*) et à partir d'images optiques pour le NDVI.

Pour que les simulations réalisées à partir du modèle WC soient réalistes, des erreurs qui correspondent à la précision des mesures radar en bande X ont été rajoutées au signal simulé. Ces erreurs absolues sont égales à ± 0.75 et ± 1 dB. En effet, la précision radiométrique des images TerraSAR-X (TSX) et CosmoSky-Med (CSK) est comprise entre 0.6 et 1 dB (Agenzia Spaziale Italiana, 2007; Coletta et al., 2007; Iorio et al., 2010; Schwerdt et al., 2008; Torre et al., 2011). De plus, pour avoir des valeurs de NDVI qui ressemblent à celles qui seront estimées à partir des données optiques, une erreur relative de 15% a été rajoutée aux valeurs synthétiques de NDVI. En effet, Hajj *et al.* (2008) ont constaté que l'incertitude relative sur l'indice NDVI calculé à partir des images SPOT-5 corrigées des effets atmosphériques est d'environ 13%.

Des distributions gaussiennes additives de moyenne nulle et d'un écart-type égal d'une part à l'erreur absolue sur le signal radar et d'autre part à l'erreur relative sur les valeurs de NDVI ont été utilisées pour brouter le signal radar et le NDVI. De plus, pour obtenir des données synthétiques statistiquement significatives, 500 tirages aléatoires de ces bruits gaussiens ont été effectués pour chaque couple (signal radar simulé, NDVI). En conséquence, la base des données synthétiques ayant NDVI comme descripteur de la végétation est composé de 2.10^7 éléments (8 éléments de M_v x 10 éléments de NDVI x 500 tirages aléatoires du bruit sur le signal radar x 500 tirages aléatoires du bruit sur le NDVI).

3.3 Estimation de l'humidité du sol

Pour estimer l'humidité du sol, des réseaux de neurones ont d'abord été entraînés et les résultats validés sur les données synthétiques en utilisant la méthode de validation croisée. Dans la méthode de validation croisée 80% des données synthétiques ont été utilisées pour l'apprentissage et les 20% restants pour la validation. L'apprentissage a été réalisé selon les configurations suivantes :

- Configuration 1: le signal radar en polarisation HH et le NDVI bruités comme entrées pour les réseaux de neurones et M_v comme paramètre à estimer.
- Configuration 2 : le signal radar en polarisation HV et le NDVI bruités comme entrées pour les réseaux de neurones et M_v comme paramètre à estimer.
- Configuration 3 : les signaux radar en polarisations HH et HV et le NDVI bruités comme entrées pour les réseaux de neurones et M_v comme paramètre à estimer.

Ensuite, les réseaux de neurones entraînés sur les données synthétiques ont été utilisés pour inverser le signal radar mesuré (base de données réelles). L'inversion a été réalisée selon les configurations ci-dessus, mais en utilisant les données réelles du signal radar et du NDVI.

4. Résultats et discussion

4.1 Modélisation du signal radar

La base des données réelles a été divisée en deux sous-bases pour permettre d'ajuster le modèle WC et valider l'estimation de M_v sur deux jeux des données séparées (*Table 4*, article 2). La première sous-base est utilisée pour ajuster le modèle WC (47% de la base totale). La deuxième sous base de données (53% de la base totale) a été utilisée pour valider l'ajustement du WC, et la méthode d'estimation de l'humidité du sol (en utilisant des réseaux de neurones entraînés sur des données synthétiques). Les résultats ont montré que la qualité de l'ajustement du modèle WC est à peu près la même quel que soit le descripteur de végétation utilisé (BIO, VWC, HVE, NDVI, LAI, FAPAR, et FCover). En effet, le RMSE (erreur moyenne quadratique) sur les coefficients de rétrodiffusion simulés varie entre 0.76 et 0.86 dB en HH, et entre 0.85 et 0.94 dB en HV, en fonction du descripteur de végétation utilisé (*Table 5*, article 2).

Le modèle WCM ajusté a été utilisé pour simuler les composantes $T^2\sigma_{sol}$, σ_{veg} et σ_{tot} du modèle WC pour une large gamme de M_v (entre 10 et 45 Vol.%) et de NDVI (entre 0.45 et 0.90). Les résultats montrent que σ_{tot} est toujours sensible à l'humidité du sol, même pour des

valeurs de NDVI d'environ 0.9 (*Figure 4*, article 2). Cette sensibilité diminue avec l'augmentation de NDVI due à la croissance de la végétation. Pour un NDVI égal à 0.5, la sensibilité du signal radar à M_v est d'environ 0.14 et 0.10 dB/Vol.% en polarisations HH et HV, respectivement. Pour des valeurs de NDVI égales à 0.9 cette sensibilité est d'environ 0.08 et 0.04 dB/Vol.% en polarisations HH et HV, respectivement.

Les résultats montrent également que le σ_{tot} est assez peu sensible aux variations de NDVI pour des NDVI entre 0.45 et 0.90 (*Figure 5*, article 2). Cette faible sensibilité de σ_{tot} aux variations de NDVI (NDVI entre 0.45 et 0.90) s'explique comme suit: avec la croissance de la végétation, l'augmentation de la contribution de la végétation (σ_{veg}) est quasiment similaire à la diminution de la contribution du sol ($T^2\sigma_{sol}$). En conséquence σ_{tot} , qui est la somme de σ_{veg} et $T^2\sigma_{sol}$ ne varie que légèrement.

4.2 Inversion de données synthétiques

L'erreur sur l'estimation de M_v a été calculée pour chaque configuration d'inversion. Des indices statistiques ont été utilisés pour quantifier cette erreur: Erreur Moyenne quadratique (RMSE), Erreur Moyenne quadratique en pourcentage (RRMSE) et biais (M_v estimée – M_v utilisée pour simulé le signal radar).

Pour toutes les valeurs de M_v et de NDVI, les résultats ont montré que l'erreur sur M_v estimée est inférieure en utilisant la polarisation HH (configuration 1) que la polarisation HV (configuration 2) (*Table 9*, article 2). De plus, l'erreur sur M_v estimée est la plus faible quand on utilise les deux polarisations HH et HV (configuration 3) (*Table 9*, article 2). Par exemple, pour une erreur absolue sur le signal radar de ± 0.75 dB, Le RMSE est de 4.5 Vol.% (RRMSE = 16.5%), 5.1 Vol.% (RRMSE=18.5%), et 3.7 Vol.% (RRMSE =13.6%) en utilisant HH (configuration 1), HV (configuration 2) et les deux polarisations HH et HV ensemble (configuration 3), respectivement. Pour les trois configurations, le RMSE augmente d'environ 1 Vol.% quand l'erreur sur le signal radar augmente de ± 0.75 dB à ± 1 dB. Enfin, le biais sur M_v estimée est nul.

Pour toutes valeurs de M_v (M_v entre 10 et 45 Vol.%), le RMSE sur M_v estimée augmente en fonction du NDVI pour les trois configurations (*Figure 6*, article 2). Par exemple, pour la configuration 3 (HH, HV et NDVI), le RMSE sur M_v estimée augmente de 3.0 à 4.8 Vol.% quand le NDVI augmente de 0.45 à 0.90. De plus, pour une valeur donnée de NDVI (NDVI entre 0.45 et 0.90), les résultats montrent que le RRMSE sur M_v estimée diminue avec l'augmentation de M_v (*Figure 7*, article 2). En effet, la contribution du M_v sur le signal rétrodiffusé augmente quand l'humidité augmente et par conséquent l'erreur sur M_v estimée à partir du signal radar diminue. Par exemple, pour une valeur de NDVI = 0.75 (LAI~3 m²/m²)

et une erreur absolue sur le signal radar de $\pm 0.75\text{dB}$, le RRMSE sur M_v estimée est de 28.3, 20.0, 16.3 et 12.0% pour des valeurs d'humidité de 15, 20, 30 et 40 Vol.%, respectivement (*Figure 7*, article 2).

Pour les trois configurations, une faible surestimation de M_v (inférieure à environ 1.2 Vol.%) a été observée pour des NDVI inférieurs à 0.6 ($\text{LAI} \sim 1\text{m}^2/\text{m}^2$) (*Figure 8*, article 2). Pour des NDVI entre 0.60 et 0.90 ($\text{LAI} \sim 6\text{m}^2/\text{m}^2$) une faible sous-estimation de M_v (inférieure à environ 1 Vol%) a été observée (*Figure 8*, article 2). De plus, les résultats montrent que le biais sur M_v estimée augmente en fonction de NDVI pour toutes les valeurs de M_v (15, 20, 30, 40 Vol.%) (*Figure 9*, article 2). Dans les trois configurations d'inversion, la surestimation de M_v a été observée principalement pour des valeurs d'humidité inférieures à 20 Vol.%. Cependant, une sous-estimation de M_v a également été observée principalement pour des M_v supérieurs à 30 Vol.%. Le biais atteint 3.5 Vol.% pour les configurations 1 et 3 comparativement à 5 Vol.% pour la configuration 2 pour une M_v de 40 Vol.% et un NDVI de 0.90.

Finalement, des résultats similaires ont été obtenus en inversant le signal radar des bases des données synthétiques, générées en utilisant les autres descripteurs de la végétation (LAI, FAPAR, et FCOVER) (*Table 10*, article 2).

4.3 Inversion de l'humidité du sol

Les réseaux de neurones entraînés sur les données synthétiques ont été validés sur la base de données réelle de validation. Les résultats montrent que la meilleure précision sur M_v estimée a été obtenue en utilisant le signal radar observé en polarisation HH (configuration 1). De plus, l'utilisation du signal radar à la fois en polarisations HH et HV (configuration 3) au lieu de la polarisation HH seule (configuration 1) ne réduit pas l'imprécision sur l'humidité estimée (*Table 11*, article 2).

Avec la configuration 1, l'humidité du sol a été estimée avec un RMSE de 3.6 Vol.% et un faible biais (M_v estimée – M_v *in situ*) de -0.2 Vol.% pour des valeurs d'NDVI entre 0.45 et 0.75 ($\text{LAI} \sim 3\text{ m}^2/\text{m}^2$). Pour des valeurs de NDVI entre 0.75 et 0.90 ($\text{LAI} \sim 6\text{ m}^2/\text{m}^2$) l'estimation de l'humidité du sol selon la configuration 1 n'est pas fiable car le R^2 entre les valeurs d'humidité estimées et mesurées est égal à 0.1. Finalement, des résultats similaires ont été obtenus en utilisant les autres paramètres de la végétation comme descripteurs de la végétation (LAI, FAPAR, et FCOVER) (*Table 13*, article 2).

5. Conclusions et perspectives

Cette étude a montré le potentiel des données radar en bande X (incidence ~30°) combinées avec des images optiques pour l'estimation de l'humidité du sol en présence de végétation. L'utilisation des images radar mono-polarisation HH en bande X est celle qui offre la meilleure précision sur l'estimation de l'humidité du sol. Cette précision est de 3.6 Vol.% pour des NDVI inférieurs à 0.75 ($LAI \sim 3 \text{ m}^2/\text{m}^2$). Pour des NDVI inférieurs à 0.75 ($LAI \sim 3 \text{ m}^2/\text{m}^2$) l'approche d'inversion pour estimer l'humidité n'est pas fiable.

Les capteurs radar actuels (RADARSAT-2, SENTINEL-1A CSK, TSX) et optique (LANDSAT-8, SENTINEL-2A) et ceux qui seront disponibles dans le futur proche (SENTINEL-1B, et SENTINEL-2B) permettront d'estimer l'humidité du sol et les paramètres de la végétation à l'échelle intra-parcellaire avec une haute répétitivité temporelle (de l'ordre de la semaine). Ces estimations pourront être utiles pour calibrer les modèles de croissance de culture pour une meilleure gestion des systèmes irrigués.

Dans le prochain chapitre, je vais analyser l'intérêt d'intégrer (i.e. de forcer) dans des modèles de culture certains paramètres obtenus à partir d'images radar (dates d'irrigation) ou optiques (LAI, dates de coupe).

Un article détaillant la méthode et les résultats résumés ci-dessus a été soumis dans le journal international « *Remote Sensing of Environment* » :

El Hajj, M., Baghdadi, N., Zribi, M., Belaud, G., Cheviron, B., Courault, D., Hagolle, O., and Charron, F. Soil moisture retrieval over irrigated grassland using X-band SAR data. *Remote Sensing of Environment*, vol. 176, pp. 202-218, doi:10.1016/j.rse.2016.01.027.

Article 2

Soil moisture retrieval over irrigated grassland using X-band SAR data

1.	Introduction	86
2.	Study area and in situ measurements	89
2.1	Study area	89
2.2	SAR Images	91
2.3	Optical Images	92
2.4	In situ measurements	93
2.4.1	Soil moisture and roughness	94
2.4.2	Vegetation parameters	94
3.	Methods	96
3.1	Radar signal modeling	96
3.2	Soil moisture retrieval	98
4.	Results and discussions	100
4.1	Water Cloud Model parameterization, and modelling results	100
4.1.1	Water Cloud Model parameterization	101
4.1.2	Modelling results	104
4.2	Soil moisture retrieval	108
4.2.1	Synthetic dataset	109
4.2.2	Real dataset	117
5.	Conclusion	123

Soil moisture retrieval over irrigated grassland using X-band SAR data

Mohammad El Hajj^{1,*}, Nicolas Baghdadi¹, Mehrez Zribi², Gilles Belaud³, Bruno Cheviron⁴, Dominique Courault⁵, François Charron³

(Version auteur de l'article soumis dans Remote Sensing of Environment)

¹ IRSTEA, UMR TETIS, 500 rue François Breton, 34093 Montpellier cedex 5, France;
E-Mail: (mohammad.el-hajj@teledetection.fr) ;(nicolas.baghdadi@teledetection.fr)

² CNRS, CESBIO, 18 av. Edouard Belin, bpi 2801, 31401 Toulouse cedex 9, France;
E-Mails: (mehrez.zribi@ird.fr); (olivier.hagolle@cnes.fr)

³ SupAgro, UMR G-EAU, 2 place Pierre Viala, 34060 Montpellier, France;
E-Mails: (belaud@supagro.inra.fr); (Francois.Charron@supagro.inra.fr)

⁴ IRSTEA, UMR G-EAU, 361 rue François Breton, 34196 Montpellier cedex 5, France;
E-Mail: (bruno.cheviron@irstea.fr)

⁵ INRA, UMR 1114 EMMAH, Domaine St. Paul, 84914, Avignon, France;
E-Mail: (dominique.courault@avignon.inra.fr)

Abstract: The aim of this study was to develop an inversion approach to estimate surface soil moisture from X band SAR data over irrigated grassland areas. This approach simulates a coupling scenario between Synthetic Aperture Radar (SAR) and optical images through the Water Cloud Model (WCM). A time series of SAR (TerraSAR-X and COSMO-SkyMed) and optical (SPOT 4/5 and LANDSAT 7/8) images were acquired over an irrigated grassland region in southeastern France.

An inversion technique based on multi-layer perceptron neural networks (NNs) was used to invert the Water Cloud Model (WCM) for soil moisture estimation. Three inversion configurations based on SAR and optical images were defined: (1) HH polarization, (2) HV polarization, and (3) both HH and HV polarizations, all with one vegetation descriptor derived from optical data. The investigated vegetation descriptors were the Normalized Difference Vegetation Index "NDVI", Leaf Area Index "LAI", Fraction of Absorbed Photosynthetically Active Radiation "FAPAR", and the Fractional vegetation COVER "FCOVER". These vegetation descriptors were derived from optical images. For the three

inversion configurations, the NNs were trained and validated using a noisy synthetic dataset generated by the WCM for a wide range of soil moisture and vegetation descriptor values. The trained NNs were then validated from a real dataset composed of X band SAR backscattering coefficients and vegetation descriptor derived from optical images. The use of X band SAR measurements in HH polarization (in addition to one vegetation descriptor derived from optical images) yields more precise results on soil moisture (M_v) estimates. In the case of NDVI derived from optical images as the vegetation descriptor, the Root Mean Square Error on M_v estimates was 3.6 Vol.% for NDVI values between 0.45 and 0.75, and 6.1 Vol.% for NDVI between 0.75 and 0.90. Similar results were obtained regardless of the other vegetation descriptor used.

Keywords: grassland; TerraSAR-X; COSMO-SkyMED; neural networks; inversion; soil moisture; vegetation indices

1. Introduction

In irrigated agricultural areas, irrigation scheduling is a decision-making process that determines when and how much water to apply to meet optimum yield (Wright, 1990). The optimization of irrigation scheduling can significantly improve the water efficiency, especially when the water demand can be anticipated on a horizon of a few hours to a few days (Hong et al., 2013). The anticipation of water demand could be realized heuristically when taking into account land use, climatic factors, known irrigation practices, and soil moisture (Leenhardt et al., 2004). Over irrigated grassland areas, soil moisture is the most influential factor controlling grassland growth and consequently, the yield (Merot et al., 2008b). Indeed, when soil is very wet or suffers for water-stress the growth rate of the grassland is low (Allen et al., 1998; Brereton and Hope-Cawdery, 1988). In this context, monitoring the spatio-temporal evolution of soil moisture over irrigated grassland areas is needed for effective irrigation and crop management. In situ sensors to measure soil moisture are costly and provide only local information. Thus, these sensors are not sufficient for monitoring the soil moisture in huge irrigated grassland areas because the soil moisture presents large heterogeneities due to environmental characteristics and irrigation practices. SAR (Synthetic Aperture Radar) data have shown great potential to provide spatially distributed surface soil moisture measurements over bare and vegetated soil (Aubert et al., 2011; Baghdadi et al., 2012a; Gherboudj et al., 2011; Paloscia et al., 2008, 2013; Prévot et al., 1993; Santi et al., 2013a). Due to their ability to operate in all weather conditions, SAR sensors offer the opportunity to monitor and quantify the surface soil moisture at a large scale with high spatial and temporal resolution.

SAR remote sensing was widely and primarily used to estimate the soil moisture and surface roughness. Over bare soil (or soil with little vegetation cover) the estimation of soil moisture was performed using either a physical (e.g the Integral Equation Model, Fung et al., 1992) or statistical (e.g Dubois and Oh models, Dubois et al., 1995; Oh, 2004) model in an inversion scheme. In contrast to physical models, statistical models need to be calibrated using in situ measurement and SAR observation acquired over the study area. Moreover, the use of statistical models is limited to the ranges of data variation used for calibration. Most of the studies used radar data in the X and C bands to estimate the soil moisture of bare soil and have shown good results, with an accuracy between 3 and 6 Vol.% (Aubert et al., 2011; Baghdadi et al., 2012a; Srivastava et al., 2003, 2009; Zribi et al., 2005). The presence of vegetation cover complicates soil moisture retrieval from SAR data because vegetation canopy not only introduces two-way attenuation in SAR backscatter from soil, but also contributes its own backscatter (He et al., 2014; Srivastava et al., 2011). Therefore, over vegetated areas, the total backscattered radar signal is the result of contributions from the underlying soil and the vegetation.

For soil moisture estimates, SAR configurations (wave length, polarization, and incidence angle) should be selected to have minimum vegetation effects on SAR backscatter. It was always preferred to acquire SAR data at low incidence angle to reduce the vegetation cover slant height (Srivastava et al., 2008). Similarly, wavelength was always selected to offer reasonable penetration capability inside the vegetation cover. Few studies investigated the potential of X-band to penetrate the vegetation cover and consequently estimate soil moisture. Baghdadi et al., (2010) showed that when TerraSAR-X data (HH polarization with high incidence angle) are used after heavy rainfall, the soil contribution (influenced by soil moisture) to the backscattering of sugarcane plots is important when the sugarcane height is less than 30 cm. Moreover, EL Hajj *et al.* (2014) showed that the radar signal penetration depth in the X-band (incidence about 30°) is high, even in dense grass cover (HVE about 1m, biomass up to 3.9 kg/m²). These results encourage the use of X-band with medium angle (about 30°) in both HH and HV polarizations for soil moisture estimates over grassland.

Most studies used the Water Cloud Model (WCM) in an inversion scheme for soil moisture estimation over areas with vegetated cover. In the WCM the total reflected radar signal is modeled as a function of the vegetation and soil contribution. The vegetation contribution, direct scattering and attenuation, is computed mainly using one biophysical parameter representing the vegetation effect. This biophysical parameter could be estimated from optical data. Therefore, it is important to combine SAR and optical data for operational mapping of soil moisture over areas covered by vegetation (Fieuzal et al., 2011; He et al., 2014; Hosseini and Saradjian, 2011; Notarnicola et al., 2006; Prakash et al., 2012).

Optical data have shown a great potential to estimate biophysical parameters of vegetation, such as Leaf Area Index (LAI), Fractional vegetation COVER (FCOVER), Fraction of Absorbed Photosynthetically Active Radiation (FAPAR) (Baret et al., 2007; Pickett-Heaps et al., 2014). Biophysical parameters of vegetation can be derived from optical data using physical and statistical models. Physical models (e.g PROSAIL, and SAFY) invert the vegetation spectral reflectance and estimate the biophysical parameters of the vegetation, such as leaf chlorophyll content (Botha et al., 2007, 2010), leaf water content (Ceccato et al., 2001; Yang and Ling, 2004), LAI (Darvishzadeh et al., 2008a; Goel and Strelbow, 1983), and biomass (Fieuza et al., 2011). Most statistical models are based on direct relationships between the Normalized Differential Vegetation Index (NDVI) and the measured biophysical parameters of vegetation, such as the LAI of wheat, grasslands, maize, corn and rice (Baret and Guerif, 2006a; Baret et al., 2007; Bsaibes et al., 2009; Courault et al., 2008, 2010); BIO of grasslands (Edirisinghe et al., 2011; Ferreira et al., 2013; Schino et al., 2003; Todd et al., 1998); VWC of corn and soybeans (Chen et al., 2005); and HVE of alfalfa and grasslands (Payero et al., 2004).

Currently, many optical and SAR sensors are orbiting earth, such as TerraSAR-X (“TSX” with two satellites), COSMO-SkyMed (“CSK” with four satellites), and LANDSAT-8. TSX and CSK sensors had the advantage of acquiring at least one image per day for the same geographical zone in the X-band with low and medium incidence angles ($< 35^\circ$). Low and medium SAR incidence angles are optimal for soil moisture estimation (Baghdadi et al., 2006, 2008a, 2012b; Srivastava et al., 2003; Zribi and Dechambre, 2003). On the other hand, LANDSAT-8 provides optical images with a temporal resolution of 16 days at a spatial resolution of 30 m. This good availability of remote sensing data sources allows the monitoring and quantification of biophysical parameters of soil and vegetation in near real time using both SAR and optical images.

The possibility of retrieving soil parameters from vegetated surfaces was widely investigated using C-band configurations, whereas few studies were carried out using the X-band (De Roo et al., 2001; El Hajj et al., 2014; Gherboudj et al., 2011; He et al., 2014; Notarnicola et al., 2006; Prévot et al., 1993; Sikdar and Cumming, 2004; Wang et al., 2011; Yang et al., 2012; Yu and Zhao, 2011; Zribi et al., 2011). For C-band SAR data, studies showed that it is possible to estimate the soil moisture with accuracy from 2 to 8 Vol.% (RMSE) using the WCM. (Prévot et al., 1993) combined radar data in the C and X bands to estimate soil moisture of winter wheat plots (for surfaces with a LAI between 0 and $1 \text{ m}^2/\text{m}^2$) located in southeastern France and obtained results on M_v estimates with an accuracy of 6.5 Vol.%. Similar accuracy was obtained by Zribi et al. (2011) using ASAR images (C-band) acquired over wheat plots (LAI between 0.01 and $3.7 \text{ m}^2/\text{m}^2$) located in the Kairouan plain region

(Tunisia). Soon-Koo Kweon *et al.* (2012) estimated the soil moisture over soybean plots using SAR X-band data with an accuracy of 3 Vol.% (VWC and LAI reached 1.8 kg/m^2 and $4.5 \text{ m}^2/\text{m}^2$, respectively). He *et al.* (2014) coupled radar (C-HH and C-VV) and optical images in the WCM model to assess soil moisture over a grassland area located in the eastern part of the Qinghai-Tibet Plateau of China using the NDVI derived from optical images to characterize the vegetation. In this study, the soil moisture was estimated with an accuracy of approximately 3 Vol.%. De Roo *et al.* (2001) have used another model: MIMICS (the Michigan Microwave Canopy Scattering model) in conjunction with the Oh model to estimate soil moisture and vegetation water content applied to a soybean canopy (with VWC between 0.02 and 0.97 kg/m^2) from fully polarimetric data at both the L and C bands. The accuracy of soil moisture estimates was approximately 2 Vol.%. Gherboudj *et al.* (2011) have combined the Oh model and the WCM to estimate the soil moisture over an agricultural vegetation area (wheat, peas, lentil, fallow, pasture, and canola) located in Saskatchewan (Canada) using Radarsat-2 images in polarimetric mode (C-band). The soil moisture was estimated with an accuracy of 6 Vol.% for plots with a canopy height between 11 and 97 cm. Finally, Hajj *et al.* (2014) showed that the radar signal in X-band (incidence angle about 30°) in both HH and an HV polarization is sensitive to soil moisture of meadow even in dense vegetation covers (vegetation height about 1m, and biomass around 3.9 kg/m^2). This sensitivity is high for biomass less than 1 kg/m^2 (about 0.13 and 0.08 dB/% for biomass lower and higher than 1 kg/m^2 , respectively).

The aim of this study is to evaluate the potential of X band SAR data combined with optical data to estimate soil moisture over irrigated grassland areas located in southeastern France. An approach based on the inversion of the WCM using multi-layer neural networks (NNs) was developed. This approach relies on four main steps: (1) parameterize the WCM, (2) simulate learning the SAR synthetic dataset, (3) train the neural networks according to three inversion configurations using a part of the synthetic dataset, and finally (4) apply the trained NNs on synthetic and real datasets to validate the inversion approach. In this paper, section 2 presents the study areas and the ground-truth measurements performed in situ. Section 3 describes the methodology. The results are shown in section 4. Finally, section 5 presents the principal conclusions.

2. Study area and in situ measurements

2.1 Study area

The study area, named "Domaine de Merle", is an experimental farm located in southeastern France (centered at 43.64° N , 5.00° E). Its extent is approximately 400 hectares, among which 150 hectares are irrigated grassland for hay production (Figure 1). The produced hay is high-

value with a Certified Origin Product label (COP) thanks to the specific environmental conditions and conventional irrigation guidelines.

The climate is Mediterranean with a rainy season between September and November. The average cumulative rainfall collected at the study site reached 457.5 mm in 2013, and in general varies between 350 mm and 800 mm over the past 20 years (Courault et al., 2010). The mean air temperature is approximately 8°C and 24°C during winter and summer, respectively (Courault et al., 2010). The in situ measured evaporation rate (potential evapotranspiration) can reach 10 mm/day during the summer due to high temperatures associated with dry and windy conditions. Meteorological instruments installed in the study area allow for recording hourly temperature and precipitation.

The topsoil texture of irrigated plots is stony loam (15% to 20% pebbles) with the depth varying from 30 cm to 80 cm, depending on the plot age (between 10 years and 3 centuries) (Botraud et al., 1984; Mérot, 2007). The soil is always very smooth thanks to regular irrigation (approximately every 10 days) by gravity. Moreover, the soil has a moderate retention capacity, with concentrated vegetation roots in the upper 30 cm (Merot et al., 2008b). The retention capacity represents the volume of water retained in a soil, which does not flow under the action of gravity.

Plots were leveled with a very gentle slope to allow irrigation by gravity (border irrigation). Irrigation is applied by means of canals which bring water to the highest extremities of the plots. Each plot is irrigated every 10 days on average from April to September. Plots are harvested three times a year, in May, July, and September.



Figure 1. Location of the study site (Domaine du Merle). Black polygons delineate training irrigated grassland plots where ground measurements were made.

2.2 SAR Images

Twenty three X-band SAR images were acquired by the COSMO-SkyMed (CSK) and TerraSAR-X (TSX) sensors between April and October 2013. All SAR images are in dual-polarization mode (HH and HV) with incidence angles between 28.3° and 32.5° (Table 1). Moreover, TSX and CSK images are in Stripmap (pixel spacing of 3 m) and Stripmap Pingpong (pixel spacing of 15 m) imaging modes, respectively.

Radiometric calibration of SAR images was performed using algorithms developed by the German Aerospace Center (DLR) and the Italian Space Agency (ASI). The radiometric calibration transforms the digital number of each pixel (DN_i) to a radar backscattering coefficient (σ_i°), in linear scale. For the seven TSX MGD (Multi Look Ground Range Detected), the radiometric calibrations were performed according to the following equation (Eineder et al., 2008):

$$\sigma_i^\circ = K_s \cdot DN_i^2 \cdot \sin(\theta) - NESZ \quad (\text{Eq. 1})$$

where K_s is the calibration constant, θ is the reference incidence angle, and NEZ is the Noise Equivalent Sigma Zero.

For the sixteen CSK images, σ_i^o was computed from the DN_i using the following equation:

$$\sigma_i^o = DN_i^2 \cdot \frac{1}{K \cdot F^2} \cdot \sin(\theta) R_{ref}^{2 \cdot R_{exp}} \quad (\text{Eq. 2})$$

where R_{ref} is the reference slant range, R_{exp} is the reference slant range exponent, K is the calibration constant, and F is the rescaling factor.

Values of parameters given in Equations 1 and 2 are given in the metadata associated with each TSX and CSK image. The σ_i^o were then averaged for each grassland plot and converted to the decibel scale according to the following equation:

$$\sigma^o_{dB} = 10 \cdot \log_{10} (\sum \sigma_i^o) \quad (\text{Eq. 3})$$

Backscattering coefficients derived from TSX and CSK sensors are comparable. For training plots, a comparison was performed between the backscattering coefficients (in both HH and HV polarizations) derived from one TSX and one CSK image, both acquired on the same day (08/07/2013) with about 40 minutes time interval. For such time interval the soil and vegetation conditions remain unchanged. For both HH and HV polarizations, results showed unbiased comparison with low Root Mean Square Error (RMSE ~ 0.4 dB), low Mean Absolute Percentage Error (MAPE $< 5\%$) and high correlation coefficient ($R^2 \sim 0.9$).

2.3 Optical Images

Thirty one optical images were acquired by SPOT-4, SPOT-5, LANDSAT-7 and LANDSAT-8 between April and October 2013 at dates very close to the SAR images (Table 1). The calibration of optical images includes correction for atmospheric effects and orthorectification. SPOT-4 images were calibrated by the CESBIO (Centre d'Etudes Spatiales de la BIOosphère) in the framework of the Take 5 experiment (<http://www.cesbio.ups-tlse.fr/>). Atmospheric correction of SPOT-4 images was performed according to the method described in the study of Hagolle *et al.* (2008). SPOT-5 and LANDSAT-8 were corrected for atmospheric effects using the Simplified Method of Atmospheric Correction (SMAC) (Rahman and Dedieu, 1994). The SMAC model transforms the TOA reflectance (Top Of Atmosphere) to an atmospherically corrected reflectance. Input data to the SMAC model, the Aerosol Optical Thickness (AOT) at 550 nm, the water vapor content (g/m^2), and Ozone, were obtained from the AERONET (AErosol RObotic NETwork) website (<http://aeronet.gsfc.nasa.gov/>). LANDSAT-7 images, already corrected for atmospheric effects, were downloaded directly from the website of the USGS

(<http://earthexplorer.usgs.gov/>). The atmospheric correction of LANDSAT-7 images were carried out by NASA (National Aeronautics and Space Administration) by applying the 6S (Second Simulation of a Satellite Signal in the Solar Spectrum) radiative transfer model data as described by Masek *et al.* (2013) . Finally, LANDSAT-7/8 images were already ortho-rectified, whereas SPOT-5 images were ortho-rectified using the terrain correction module implemented in the ERDAS imaging software.

The NDVI was computed from the optical images. Then, NDVI pixel values were averaged for each plot. For all training plots, a comparison was performed between NDVI derived from images acquired by different sensors (LANDSAT-7/8, SPOT-4/5) with time interval less than four days. Results showed unbiased comparison with low RMSE (≤ 0.04), low MAPE (< 5%), and good correlation coefficient (R^2 between 0.70 and 0.98). Thus, NDVI derived from different sensors were comparable.

	Février	Mars			Avril			Mai			Juin						Juillet																				
	23	15	16	25	14	17	19	22	24	30	03	04	11	14	22	27	03	04	06	10	11	12	13	14	18	26	28	30	05	08	12	14	16	19	22	29	30
TSX							X	X	X				X	X															X							X	
CSK																									X	X	X		X	X				X	X	X	
SPOT-4 & 5	X	X		X	X			X		X	X												X		X	X		X	X								
LANDSAT-7/8			X		X					X			X		X	X						X			X			X			X		X	X	X		
Mesures in situ	X				X			X	X		X	X		X	X	X	X	X	X	X	X	X	X	X		X	X	X	X	X	X	X	X	X	X	X	

	Août												Septembre					Octobre					
	01	09	13	15	18	20	21	22	23	26	29	31	02	03	04	10	22	24	01	04	06	11	16
TSX					X														X				
CSK	X	X								X	X		X		X		X			X			X
SPOT-4 & 5	X				X													X			X	X	
LANDSAT-7 & 8				X			X		X		X							X					
Mesures in situ	X	X	X	X		X	X		X	X		X	X	X	X	X	X		X	X	X	X	

Table 1. Acquisition dates of SAR and optical images (in 2013). Ground measurements are soil moisture and roughness, LAI, FAPAR, FCOVER, BIO, VWC, and HVE (described in section below).

2.4 In situ measurements

In situ campaigns were conducted simultaneously with SAR acquisitions to collect ground-truthed measurements of soil and vegetation parameters in twelve training plots. These plots are well levelled and have enough size to be considered as sampling unit (Patel and Srivastava, 2013). The dimension of sampled plot ranges between 2.9 ha and 8.80 ha.

2.4.1 Soil moisture and roughness

Due to the high irrigation frequency and evapotranspiration rates, soil moisture measurements were performed close in time (within a window of 2 hours) to the satellite overpass. For each training plot, twenty five to thirty measurements of volumetric soil moisture were conducted in the top 5 cm of soil by means of a calibrated TDR (Time Domain Reflectometry) probe. Soil moisture was measured in the top 5 cm of soil because the radar penetration depth is assumed to be a few centimeters in the X-band (Ulaby et al., 1986). The soil moisture of each plot was represented by the mean of all soil moisture measurements performed in that plot, except when high spatial variability of soil moisture was observed. This variability is the result to current or recent (few hours before) irrigation events. In this case, many homogenous sub-plots were defined. The soil moisture was approximately 12 Vol.% when the plot was not supplied by water (irrigation or rainfalls) for 10 days during the summer, and it reached approximately 45Vol.% approximately 10 hours after irrigation ended (Table 2).

Soil roughness measurements were conducted only once because soil roughness remains stable, using a needle profile-meter (total length of 1 m, and needle spacing of 2 cm). Ten roughness profiles (five parallels and five perpendiculars to SAR's line of sight) were recorded for each plot couple of days after the third cut, when the vegetation was very short. The root mean square height ($Hrms$) which represents the vertical scale of roughness, and the correlation length (L), representing the horizontal scale, were derived by processing the roughness profile. The individual autocorrelation functions are averaged, to produce a mean autocorrelation function representing each training plot (exponential function). Then, this mean autocorrelation function was used to derive $Hrms$ and L . The $Hrms$ values varied between 0.35 and 0.55 cm, and the correlation length (L) ranged from 2.00 to 4.60 cm.

2.4.2 Vegetation parameters

Additionally, in situ measurement of vegetation parameters were performed to estimate the fresh Biomass (BIO), Vegetation Water Content (VWC), Vegetation Height (HVE), leaf area index (LAI), Fraction of Absorbed Photosynthetically Active Radiation (FAPAR), and Fractional vegetation COVER (FCOVER). To determine the BIO, two vegetation samples over a 50 cm x 50 cm square were clipped using shears, and then weighed (wet biomass). Later, these samples were dried at 70°C to calculate the VWC (VWC = wet biomass – dry biomass). Twenty measurements of vegetation heights were performed for each plot. Finally, twenty to thirty hemispherical images were acquired for each plot by means of a fish eye lens. These photos were processed using CanEye software (<http://www6.paca.inra.fr/can-eye>) to estimate the LAI, FAPAR and FCover. Figure 2 showed photos for plots at different vegetation growth stage.

	Training plot 2e (Jun 10, 2013) BIO= 0.89 kg/m ² HVE = 0.25 m LAI = 1.01 m ² /m ²
	Training plot 11 (April 19, 2013) BIO= 1.90 kg/m ² HVE = 0.50 cm LAI = 3.98 m ² /m ²
	Training plot 1m (May 14, 2013) BIO= 3.56 kg/m ² HVE = 1.13 m LAI = 4.71 m ² /m ²

Figure 2. Photo clicked for some training plots with associated in situ measurements

Date dd/mm/yy	Sensor	θ ($^{\circ}$)	Range of M_v (Vol.%)	Range of VWC (kg/m 2)	Range of BIO (kg/m 2)	Range of HVE (m)	Range of LAI (m 2 /m 2)	Range of FAPAR	Range of FCOVER
19/04/13	TSX	29.1	[13-23]	[1.54-2.35]	[1.90-3.00]	[0.49-1.20]	[3.98-5.88]	[0.96-1.00]	[0.77-0.90]
30/04/13	TSX	29.1	[34-39]	[1.67-3.35]	[1.99-4.14]	[0.69-1.03]	[3.14-3.87]	[0.88-0.94]	[0.63-0.79]
14/05/13	TSX	32.5	[17-34]	[0.15-2.65]	[0.30-3.56]	[0.08-1.13]	[0.41-4.71]	[0.32-0.97]	[0.19-0.91]
22/05/13	TSX	29.1	[18-33]	[0.29-3.11]	[0.46-3.74]	[0.19-1.15]	[1.96-4.90]	[0.74-0.94]	[0.52-0.89]
06/06/13	CSK2	28.3	[15-31]	[0.33-1.12]	[0.54-1.43]	[0.16-0.41]	[0.26-3.64]	[0.20-0.89]	[0.11-0.87]
10/06/13	CSK4	28.4	[23-44]	[0.42-1.12]	[0.60-1.43]	[0.20-0.54]	[0.31-3.74]	[0.25-0.91]	[0.12-0.74]
11/06/13	CSK1	30.6	[19-30]	[0.40-1.12]	[0.60-1.43]	[0.20-0.59]	[0.31-3.77]	[0.25-0.91]	[0.12-0.75]
14/06/13	CSK1	28.3	[16-34]	[0.56-0.92]	[0.73-1.43]	[0.26-0.74]	[1.30-4.00]	[0.65-0.93]	[0.37-0.81]
26/06/13	CSK4	28.3	[15-36]	[0.83-1.65]	[1.02-2.06]	[0.37-0.82]	[2.33-4.26]	[0.81-0.93]	[0.60-0.84]
08/07/13	TSX	32.5	[15-47]	[0.53-2.17]	[0.71-2.74]	[0.15-0.94]	[0.52-3.83]	[0.36-0.90]	[0.16-0.76]
08/07/13	CSK2	28.3	[15-47]	[0.53-2.17]	[0.71-2.74]	[0.15-0.94]	[0.52-3.83]	[0.36-0.90]	[0.16-0.76]
12/07/13	CSK4	28.3	[22-32]	[0.34-1.68]	[0.32-2.05]	[0.11-0.80]	[0.10-3.57]	[0.31-0.90]	[0.15-0.73]
16/07/13	CSK1	28.3	[16-35]	[0.34-1.78]	[0.32-2.09]	[0.10-0.88]	[0.10-3.60]	[0.10-0.86]	[0.04-0.71]
30/07/13	TSX	32.5	[26-37]	[0.37-1.34]	[0.51-1.62]	[0.20-0.69]	[1.17-3.83]	[0.56-0.90]	[0.38-0.80]
01/08/13	CSK1	28.4	[18-38]	[0.37-1.34]	[0.51-1.62]	[0.20-0.69]	[1.17-3.83]	[0.56-0.90]	[0.38-0.80]
09/08/13	CSK2	28.3	[17-35]	[0.51-1.58]	[0.79-1.85]	[0.28-0.70]	[2.05-3.88]	[0.68-0.92]	[0.50-0.96]
26/08/13	CSK3	28.4	[17-26]	[0.44-1.32]	[0.40-1.62]	[0.19-0.82]	[1.44-3.23]	[0.60-0.88]	[0.43-0.79]
29/08/13	CSK4	28.3	[11-35]	[0.15-2.12]	[0.32-2.70]	[0.19-0.90]	[0.54-3.23]	[0.42-0.90]	[0.25-0.77]
02/09/13	CSK1	28.3	[16-36]	[0.19-1.80]	[0.28-2.13]	[0.08-0.90]	[0.54-3.25]	[0.42-0.90]	[0.25-0.77]
10/09/13	CSK2	28.3	[21-39]	[0.03-1.45]	[0.37-1.72]	[0.11-0.50]	[0.30-2.97]	[0.25-0.93]	[0.09-0.78]
01/10/13	TSX	29.1	[30-39]	[0.97-2.06]	[1.03-2.46]	[0.22-0.85]	[2.10-3.80]	[0.76-0.93]	[0.60-0.79]
04/10/13	CSK1	28.3	[23-33]	[0.85-2.06]	[1.03-2.46]	[0.22-0.85]	[2.10-3.89]	[0.76-0.93]	[0.61-0.80]
16/10/13	CSK4	28.3	[17-31]	[1.03-2.23]	[1.22-2.81]	[0.28-0.96]	[2.60-3.90]	[0.81-0.93]	[0.65-0.80]

Table 2. Main characteristics of the SAR images (TSX and CSK, all in HH and HV polarizations), and a summary of training plots measurements (made on ten to twelve plots).

3. Methods

3.1 Radar signal modeling

In this study, the Water Cloud model (WCM) was used for modeling the total backscattered radar signal according to soil moisture and vegetation parameters. This semi-empirical model is widely used over soil with vegetation cover because it can be easily performed in an inversion scheme to estimate soil moisture and vegetation parameters (Gherboudj et al., 2011; Prévot et al., 1993; De Roo et al., 2001; Sikdar and Cumming, 2004; Soon-Koo Kweon et al., 2012; Wang et al., 2011; Yang et al., 2012; Yu and Zhao, 2011; Zribi et al., 2011). The WCM, developed by Attema and Ulaby (1978), assumes the vegetation volume as lossy medium composed by dielectric cylinders (scattering elements). This assumption is appropriate to model canopies such as grass and wheat (Attema and Ulaby, 1978; Peake,

1959). Moreover, to simplify the WCM as much as possible, Attema and Ulaby (1978) assumed the dielectric cylinders were identical in size and uniformly distributed in a space bounded by the soil surface and the top of the vegetation volume. In the WCM, only direct scattering from soil and vegetation was considered, whereas multiple scattering effects from soil and vegetation interactions were ignored. The significant variables in the WCM are the medium height and dielectric cylinder density (Attema and Ulaby, 1978). The latter was assumed to be proportional to the volumetric water content of the canopy. Very few studies have compared different vegetation parameters to define the optimal one for use in the WCM. Champion (1991) and Champion and Guyot (1991) found that the LAI (m^2/m^2) better represents the wheat canopy in the WCM than the VWC per unit volume (kg/m^3). Said *et al.* (2012) compared the use of LAI (m^2/m^2), VWC (kg/m^2), and HVE and found that the use of LAI as the vegetation descriptor allows the accurate simulation of the vegetation volume contribution (sugarcane, cherry, rice, and grassland).

In this context, the WCM represents the total backscattered radar signal (σ^0_{tot}) in linear scale as a sum of the direct vegetation contribution (σ^0_{veg}) and soil contribution attenuated by the vegetation volume ($T^2 \sigma^0_{\text{sol}}$).

$$\sigma^0_{\text{tot}} = \sigma^0_{\text{veg}} + T^2 \sigma^0_{\text{sol}} \quad (\text{Eq.4})$$

$$\sigma^0_{\text{veg}} = A \cdot V_1 \cdot \cos \theta \cdot (1 - T^2) \quad (\text{Eq.5})$$

$$T^2 = \text{Exp}(-2 \cdot B \cdot V_2 \cdot \sec \theta) \quad (\text{Eq.6})$$

$$\sigma^0_{\text{sol}} = C(\theta) \exp(D \cdot M_v) \quad (\text{Eq.7})$$

Where:

- V1 and V2 are vegetation descriptors (BIO (kg/m^2), VWC (kg/m^2), HVE (m), LAI (m^2/m^2), FAPAR, FCover, and NDVI)
- θ is the radar incidence angle
- A and B are parameters that depend on the canopy descriptors and radar configurations
- T^2 is the two way attenuation
- C is dependent on the roughness and incidence angle
- D is the sensitivity of the radar signal to volumetric soil moisture in the case of bare soils, which is dependent on radar configurations
- M_v is the volumetric soil moisture (expressed in Vol.%).

3.2 Soil moisture retrieval

In this study, soil moisture was estimated by means of multi-layer perceptron *neural networks* (*NNs*). The Levenberg-Marquardt optimization algorithm (Marquardt, 1963) was used to train the *NNs*. The *NNs* architecture is composed of three layers: input, one hidden, and output. The *NNs* have a two dimensional input vector when using one polarization (HH or HV) in addition to one vegetation descriptor. Using two polarizations (HH and HV) in addition to one vegetation descriptor, the *NNs* have a three dimensional input vector. The one dimensional output vector contains soil moisture. The numbers of neurons associated with the hidden layer was determined by training the *NNs* using different numbers of neurons. 20 hidden neurons provided accurate estimates of reference parameters (Baghdadi et al., 2012a; Chai et al., 2009). Sigmoidal and linear transfer functions were associated with the hidden and output layer, respectively. These functions allow non-linear transformations from input to output (Del Frate and Solimini, 2004; Del Frate et al., 2003; Paloscia et al., 2008). To study the performance of the inversion approach, the *NNs* were trained and validated on the synthetic datasets.

Synthetic dataset of SAR data was generated from the parameterized WCM to be used in the procedures leading to the estimation of soil moisture by means of the neural networks (*NNs*) technique. The parameterized WCM is able to simulate the backscattering coefficients at both HH and HV polarizations using the volumetric soil moisture, one vegetation descriptor, and incidence angle values as input variables. Only parameters easily estimated from optical images such as NDVI, LAI, FAPAR and FCover were considered in the synthetic datasets generation. Indeed, only few studies showed that the optical data could be used for estimating the biomass, vegetation water content, and the vegetation height. Four synthetic datasets have thus been generated using NDVI, LAI, FAPAR and FCover as vegetation descriptors (V1 and V2 in equations 4 and 5) to evaluate the most adequate vegetation descriptor for vegetation layer characterization in the WCM, and to open a perspective for future works based on SAR and optical data coupling. Indeed, several studies have developed methods to correct atmospheric effects in optical images, allowing the accurate estimation of the NDVI (Agapiou et al., 2011; Masek et al., 2013; Rahman and Dedieu, 1994; Saastamoinen, 1972; Vermote et al., 2002). Regarding the other vegetation descriptors, many studies have developed methods to estimate LAI, FAPAR, and FCover from optical images (Baret and Guyot, 1991; Bsaibes et al., 2009; Carlson and Ripley, 1997; Carlson et al., 1994; Claverie et al., 2013; Courault et al., 2008; Darvishzadeh et al., 2008b; Duveiller et al., 2011; Fensholt et al., 2004; Guerschman et al., 2009; Li et al., 2014; North, 2002). In addition, in the framework of our study, LAI, FAPAR, and FCover of our studied grassland were derived from optical images (SPOT-4, SPOT-5, LANDSAT-7, LANDSAT-8) using the BV-NNET

(Biophysical Variables Neural NETwork) tool developed based on algorithms proposed by Baret *et al.* (2007) and then optimized through the SIRRIMED project (<http://www.sirrimed.org/index.php>). A comparison was performed between the LAI, FAPAR and FCOVER derived from BV-NNET (using optical images) and those derived from hemispherical photos. Results showed unbiased estimations of LAI, FAPAR, and FCOVER by the BV-NNET. Moreover, the BV-NNET estimates the LAI with an RMSE of $0.66 \text{ m}^2/\text{m}^2$ and an RRMSE (as well as MAPE) around 29%. For FAPAR and FCOVER, an RMSE around 0.13 and an RRMSE (as well as MAPE) around 19% were obtained.

The synthetic dataset based on NDVI as the vegetation descriptor comprises 80 elements (8 x 10, Table 3). Each element of the dataset contains radar signals in HH and HV polarizations for a given NDVI and volumetric soil moisture (Table 3). Moreover, synthetic dataset based on LAI and FAPAR (as well as FCOVER) comprised 248 (8 x 31, table 3) and 168 (8 x 21, table 3) elements, respectively.

Parameter	Min value	Max value	Step	Total elements
NDVI	0.45	0.90	0.05	10
LAI (m^2/m^2)	0.0001	6	0.20	31
FAPAR	0.0001	1	0.05	21
FCOVER	0.0001	1	0.05	21
M_v (Vol.%)	10	45	5	8

Table 3. The minimum, maximum, and step values of WCM inputs.

To make WCM simulations more realistic, uncertainties of SAR measurements was added to the simulated radar response. The uncertainties range is between 0.6 and 1 dB for CSK and TSX sensors (Agenzia Spaziale Italiana, 2007; Coletta *et al.*, 2007; Iorio *et al.*, 2010; Schwerdt *et al.*, 2008; Torre *et al.*, 2011). Thus, we considered two absolute uncertainties values (± 0.75 , and ± 1.00 dB) to be added to the simulated radar response. Moreover, relative uncertainties were added on our reference vegetation descriptor values (NDVI, LAI, FAPAR, and FCOVER) to handle the associated uncertainty. For NDVI, Simoniello *et al.* (2004) reported a relative uncertainty of approximately 8% on NDVI values estimated from AVHRR (Advanced Very High Resolution Radiometer) calibrated data over pasture and cultivated areas. El Hajj *et al.* (2008) found that the relative uncertainty on NDVI computed from SPOT-5 surface reflectance data over sugarcane fields is approximately 13%. For the other vegetation descriptors, studies showed for crop canopies (corn, grass, sunflower, maize,

wheat, rapeseed and sunflower) relative uncertainty between 10% and 30% for LAI, and between 5% and 20% for FAPAR and FCOVER (Bsaibes et al., 2009; Claverie et al., 2013; Courault et al., 2008; Duveiller et al., 2011; North, 2002). In addition, the uncertainty on the vegetation descriptor estimates depends on crop type (Bsaibes et al., 2009; Claverie et al., 2013). Moreover, the comparison between derived LAI, FAPAR, and FCOVER from our optical images with ground-truthed measurements yields a relative RMSE (Root Mean Square Error) of 29.12, 19.24, and 18.14%, respectively. Therefore, in our study we considered a relative additive noise of 15, 30, and 20% on the NDVI, LAI, and FAPAR (as well as FCOVER), respectively.

Zero-mean Gaussian noises with a standard deviation equal to absolute and relative uncertainties were added to the radar signal simulated by the WCM and reference vegetation descriptors, respectively. Finally, to obtain statistically significant datasets, 500 random samplings of zero-mean Gaussian noises were added to each simulated radar response and each vegetation descriptor value.

Three cases allowed to estimate only the soil moisture were studied:

- Case 1: Noisy radar signal at HH polarization and noisy vegetation descriptor as the inputs to NNs, and soil moisture as the target.
- Case 2: Noisy radar signal at HV polarization and noisy vegetation descriptor as the inputs to NNs, and soil moisture as the target.
- Case 3: Noisy radar signal at HH and HV polarizations and noisy vegetation descriptor as the inputs to NNs, and soil moisture as the target.

Finally, the calibrated NNs were used to invert real SAR measurements for estimation of the soil moisture. The inversion was performed according to the configurations above, but using SAR and a vegetation descriptor (LAI, FAPAR, and FCOVER) derived from optical images instead of the noisy radar signal and vegetation descriptors.

4. Results and discussions

4.1 Water Cloud Model parameterization, and modelling results

This section presents the results of the Water Cloud Model (WCM) parameterization, and shows the radar signal modelling results as a function of soil and vegetation parameters.

4.1.1 Water Cloud Model parameterization

The real dataset composed of SAR data and measurements of soil moisture and vegetation descriptors was divided into two sub-datasets. The first sub-dataset (training dataset) was used to fit the WCM model, whereas the second (validation dataset) was used to validate the soil moisture estimation of the WCM model. The training dataset contains the SAR and the ground-truthed data obtained during the three cycles for the half of training plots, whereas the validation dataset comprises the data collected for other half of plots. These two real sub-datasets contain a wide range of soil moisture (M_v) and vegetation descriptor values measured in situ (BIO, VWC, HVE, LAI, FAPAR, FCOVER) and derived from optical images (NDVI, LAI, FAPAR, and FCOVER) (Table 4). The two real sub-datasets have almost the same ranges of variation.

		Min	Mean	MAX	Unit
Real training dataset	M_v	10.9	25.6	39.0	Vol.%
	In situ BIO	0.28	1.41	4.14	Kg/m^2
	In situ VWC	0.15	1.12	3.35	Kg/m^2
	In situ HVE	0.08	0.48	1.20	m
	In situ LAI	0.10	2.64	5.88	m^2/m^2
	In situ FAPAR	0.20	0.79	1.00	-
	In situ FCOVER	0.12	0.63	0.96	-
	LAI (BV-NNET)	0.20	2.63	5.04	m^2/m^2
	FAPAR (BV-NNET)	0.16	0.77	0.98	-
	FCOVER (BV-NNET)	0.16	0.66	0.96	-
	NDVI	0.47	0.73	0.88	-
Real validation dataset	M_v	14.1	27.0	47.0	Vol.%
	In situ BIO	0.30	1.31	3.46	Kg/m^2
	In situ VWC	0.03	1.02	2.87	Kg/m^2
	In situ HVE	0.08	0.45	1.15	m
	In situ LAI	0.26	2.23	4.00	m^2/m^2
	In situ FAPAR	0.20	0.73	0.93	-
	In situ FCOVER	0.09	0.57	0.88	-
	LAI (BV-NNET)	0.26	2.16	5.10	m^2/m^2
	FAPAR (BV-NNET)	0.09	0.69	0.98	-
	FCOVER (BV-NNET)	0.09	0.58	0.94	-
	NDVI	0.48	0.69	0.87	-

Table 4. ranges of variation of real training and validation datasets

WCM parameterization consists of first estimating the sensitivity parameter D before fitting the model against ground-truthed measurements to estimate parameters A, B, and C (equations 4, 5, and 6).

- To estimate parameter D, SAR backscattering coefficients in HH and HV polarizations (dB scale) were linearly related to soil moisture (Vol.%) for 18 plots recently harvested (vegetation very short), to have the minimum vegetation effect on the backscattering coefficients (Figure 3). The slopes of these linear regressions represent the sensitivity of the backscattered radar signal to volumetric soil moisture on the dB scale (Figure 3). Results showed a good correlation between radar signal and volumetric soil moisture ($R^2 = 0.87$ and 0.71 for HH and HV, respectively). Moreover, results showed that the HH polarization is slightly more sensitive (0.172 dB/Vol.%) to volumetric soil moisture rather than HV (0.135 dB/Vol.%) polarization (Figure 3). In the WCM model, the sensitivity parameter D is represented on a linear scale. In linear unit, these sensitivities D_{HH} and D_{HV} are 0.03971 [m^2/m^2]/[Vol.%] and 0.03116 [m^2/m^2]/[Vol.%] for HH and HV polarizations, respectively
- A, B and C parameters were then estimated for each radar polarization and each vegetation descriptor (NDVI and ground-truthed BIO, VWC, HVE, LAI, FAPAR, and FCover) by minimizing the sum of squares of the differences between the simulated and measured radar signal. Therefore, the WCM was parameterized according to seven vegetation descriptors (Table 5). With A, B and C parameters, it becomes possible to predict WCM components (σ_{veg}^0 , T^2 , and σ_{sol}^0) and consequently the total backscattering coefficient (σ_{tot}^0) using one vegetation descriptor and the soil moisture values as inputs in the WCM.

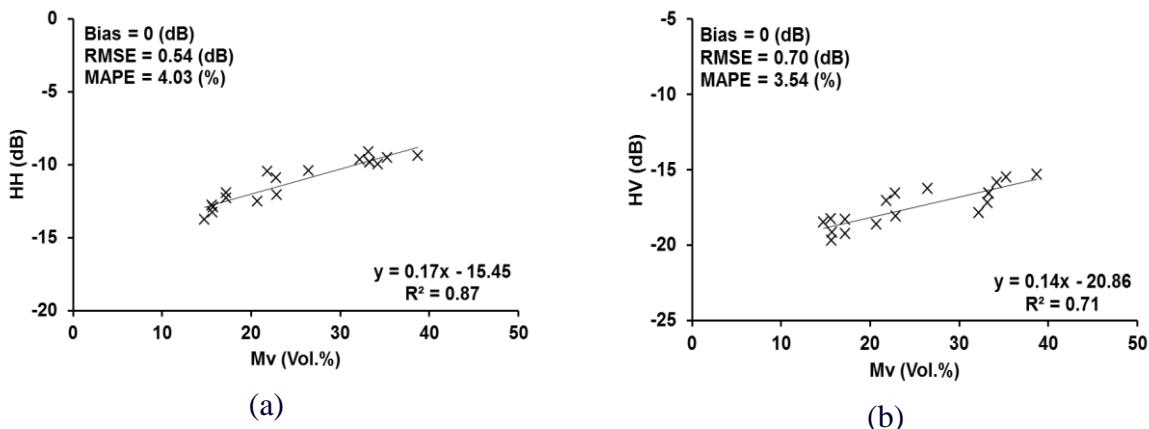


Figure 3. Sensitivity of radar signal in both HH and HV polarization to volumetric soil moisture.

To validate the fitted WCM, a comparison was performed between the radar backscattering coefficients predicted by the mean of the parameterized WCM (using the soil moisture and ground-truthed vegetation descriptors of the real validation dataset) and the observed backscattering coefficients of the real validation dataset. Results showed that the fit of the WCM was slightly better in HH polarization than in HV polarization (Table 5). The limited correlation coefficient (R^2) is not due to difficulty of model to simulate radar data but particularly to limited range of radar data dynamic for different moisture and vegetation conditions. In addition, the quality of the fit is approximately the same for all the used vegetation descriptors with the RMSE (Root Mean Square Error) on the predicted backscattering coefficients between 0.76 and 0.86 dB in HH, and between 0.85 and 0.94 dB in HV polarization, depending on the used vegetation descriptor. Water cloud model is considered adequately fitted because the RMSE on simulated radar signal in both HH and HV polarizations is less than 1 dB, which is the same magnitude as the CSK and TSX sensors precision (Agenzia Spaziale Italiana, 2007; Coletta et al., 2007; Iorio et al., 2010; Schwerdt et al., 2008; Torre et al., 2011). Several studies used the WCM model to predict radar backscattering coefficients (Attema and Ulaby, 1978; Gherboudj et al., 2011; Prevot et al., 1993; Ulaby et al., 1984). Attema and Ulaby, (1978) simulated the X-band backscattering coefficients for crops fields (alfalfa, corn, milo, and wheat) in HH and VV polarizations for a wide range of incidence angles (0° - 70°) with a RMSE of simulated backscattering coefficients ranging between 1.5 and 2 dB, depending on the crop type. Ulaby *et al.* (1984) simulated the radar backscattering coefficients in the X-band (VV polarization and 50° incidence angle) for wheat fields with a RMSE of 1.6 dB. Prevot *et al.* (1993) obtained a RMSE for wheat fields on the simulated backscattering coefficients of 1.24 and 0.72 dB in the C-band (HH, 20°) and X-band (VV, 40°), respectively. Gherboudj *et al.* (2011) predicted the backscattering coefficients in the C-band, in quad-polarization mode with a 30° incidence angle for wheat and pea fields. The RMSE on the predicted backscattering coefficients in HH and VV polarizations was approximately 1 (for wheat) and 0.7 dB (for peas), respectively. In cross polarization, the backscattering coefficient was simulated with a RMSE of 1.2 and 0.2 dB for wheat and pea fields, respectively.

V1=V2	A_{HH}	B_{HH}	C_{HH}	D_{HH}	A_{HV}	B_{HV}	C_{HV}	D_{HV}	R²_{HH} (R²_{HV})	RMSE_{HH} (RMSE_{HV}) (dB)
Ground-truthed BIO	0.0345	0.0995	0.0334	0.03971	0.0068	0.1850	0.0093	0.03116	0.49 (0.39)	0.85 (0.86)
Ground-truthed VWC	0.0438	0.1047	0.0324	0.039711	0.0084	0.1927	0.0088	0.03116	0.49 (0.39)	0.86 (0.86)
Ground-truthed HVE	0.1045	0.4314	0.0357	0.03971	0.0207	0.7882	0.0105	0.03116	0.52 (0.40)	0.79 (0.85)
Ground-truthed LAI	0.0205	0.0613	0.0338	0.03971	0.0041	0.0856	0.0088	0.03116	0.48 (0.29)	0.86 (0.95)
Ground-truthed FAPAR	0.0911	0.3275	0.0354	0.03971	0.0177	0.4662	0.0096	0.03116	0.47 (0.25)	0.80 (0.93)
Ground-truthed FCOVER	0.1021	0.3696	0.0355	0.03971	0.0203	0.5212	0.0095	0.03116	0.48 (0.27)	0.82 (0.94)
NDVI	0.0767	0.7944	0.0644	0.03971	0.016474	1.134	0.0221	0.03116	0.51 (0.33)	0.76 (0.93)

Table 5. Fit of WCM parameters for HH and HV polarizations (real validation dataset).

4.1.2 Modelling results

Modelling results obtained by using the NDVI as the vegetation descriptor in the WCM model will be presented first because (i) the best fit of water cloud model was obtained with NDVI as vegetation descriptor, and (ii) it is easier to derive NDVI from optical data than LAI, FAPAR, and FCOVER. Next, results with the LAI, FAPAR, FCOVER, BIO, VWC, and HVE as vegetation descriptors will be briefly discussed.

The WCM components ($T^2\sigma_{sol}^o$ and σ_{veg}^o) were simulated for wide ranges of soil moisture (M_v) and NDVI values using the WCM with the NDVI as the vegetation descriptor. For both HH and HV polarizations, the vegetation contribution (σ_{veg}^o), soil contribution (σ_{sol}^o), two-way attenuation (T^2), and consequently, the total backscattered signal (σ_{tot}^o) were generated in a linear scale using the parameterized equations (3) to (6). NDVI values ranging from 0.45 to 0.90 were used to simulate the vegetation contribution and the two-way attenuation ($V1=V2=NDVI$ in equations 4 and 5). In addition, the soil contribution was simulated using M_v -values ranging from 10 to 45 Vol.% (equation 6). The maximum values of NDVI and M_v

correspond to the highest values derived from optical images and measured in situ, respectively.

Figure 4 shows the modelled σ^o_{veg} , $T^2\sigma^o_{sol}$ and σ^o_{tot} in dB units as a function of M_v using different values of NDVI (0.5, 0.7, and 0.9). In addition, the modelled σ^o_{veg} , $T^2\sigma^o_{sol}$ and σ^o_{tot} were also plotted according to NDVI for M_v values of 15, 20, 30 and 40 Vol.% (Figure 5).

Figure 4 shows that σ^o_{tot} in both HH and HV polarizations are always sensitive to soil moisture even for high NDVI values. The sensitivity of σ^o_{tot} to soil moisture decreases with the NDVI for NDVI between 0.45 and 0.90. For NDVI value equal to 0.50 this sensitivity is about 0.14 dB/% and 0.10dB/% for HH and HV, respectively. Moreover, for a NDVI value equal to 0.9, this sensitivity is approximately 0.08 and 0.04 dB/Vol.% in HH and HV, respectively. For each case in figure 4 statistical index were provided in table 6. Results showed that the WCM adequately simulates SAR real validation dataset observations ($0 < \text{Bias} < 0.3$, $\text{RMSE} < 1\text{dB}$, RRMSE and $\text{MAPE} < 7\%$).

Figure 5 shows that σ^o_{tot} in both HH and HV polarization is slightly sensitive to the NDVI (for NDVI between 0.45 and 0.90). Indeed, as the vegetation grows, the decreasing soil contribution is similar to the increasing vegetation contribution. σ^o_{tot} shows slight decreases with increases in the NDVI until reaching a minimum, and starts to slightly increase. In both HH and HV polarizations, σ^o_{tot} decreases with NDVI for a NDVI lower than 0.60, 0.75, and 0.90 for M_v of 15, 20, and 30 Vol.%, respectively. However, the σ^o_{tot} in both HH and HV polarizations always decreases with NDVI (NDVI between 0.45 and 0.90) for M_v equal to 40 Vol.% due to the high soil contribution (Figures 5 d and h). This decrease of σ^o_{tot} with the NDVI is related to an increase in the attenuation of the soil contribution (T^2), which is more important than the enhanced contribution from the vegetation canopy (Balenzano et al., 2011; Brown et al., 2003; Mattia et al., 2003). Beyond these values of NDVI thresholds, σ^o_{tot} increases slightly with NDVI for M_v values between 15 and 30 Vol.%. This increase of σ^o_{tot} with NDVI results in the increase of the vegetation contribution combined with the decrease in the soil contribution. Moreover, the decrease and increase of σ^o_{tot} according to the NDVI are slightly more pronounced in HV than in HH polarization. Regarding vegetation contribution (σ^o_{veg}), results showed that the modelled σ^o_{veg} in HH polarization increases from -17.7 dB for NDVI of 0.45 to -13.2 dB for NDVI of 0.90. For HV polarization, σ^o_{veg} increases from -23.5 dB to -18.8 dB for NDVI between 0.45 and 0.90. For each case in figure 5, statistical index were provided in table 7. Results showed that the WCM adequately simulates SAR real validation dataset observations ($0 < \text{Bias} < 0.7$, $\text{RMSE} \leq 1\text{dB}$, RRMSE and $\text{MAPE} < 8\%$).

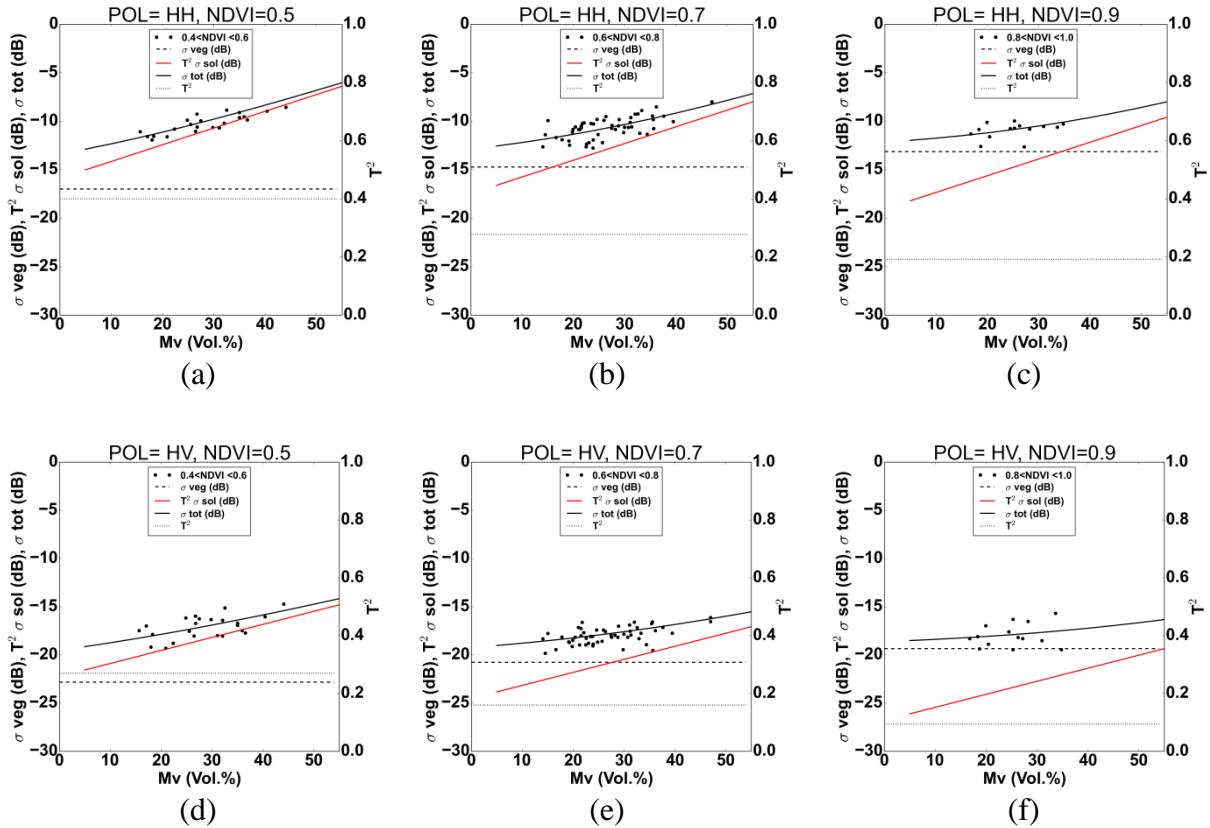


Figure 4. Behavior of WCM components (σ^0_{veg} , $T^2 \sigma^0_{sol}$, and σ^0_{tot}) in both HH and HV polarizations according to M_v . Black points represent the SAR data (σ^0_{tot} : real validation dataset) associated with NDVI measurements within ± 0.1 of the NDVI used in the modelling.

Case	Polarization	NDVI	Bias (dB)	RMSE (dB)	RRMSE (dB)	MAPE (dB)	R^2	Nb
Figure 4a	HH	0.50	0.3	0.6	6.0	5.4	0.71	23
Figure 4b	HH	0.70	0.0	0.9	8.0	6.7	0.45	52
Figure 4c	HH	0.90	0.1	0.8	7.0	4.8	0.12	14
Figure 4d	HV	0.50	0.1	1.0	5.7	5.1	0.30	23
Figure 4e	HV	0.70	0.2	0.8	4.3	3.3	0.26	52
Figure 4f	HV	0.90	0.1	1.1	6.4	5.5	0.03	14

Table 6. Statistical index for each case in figure 4

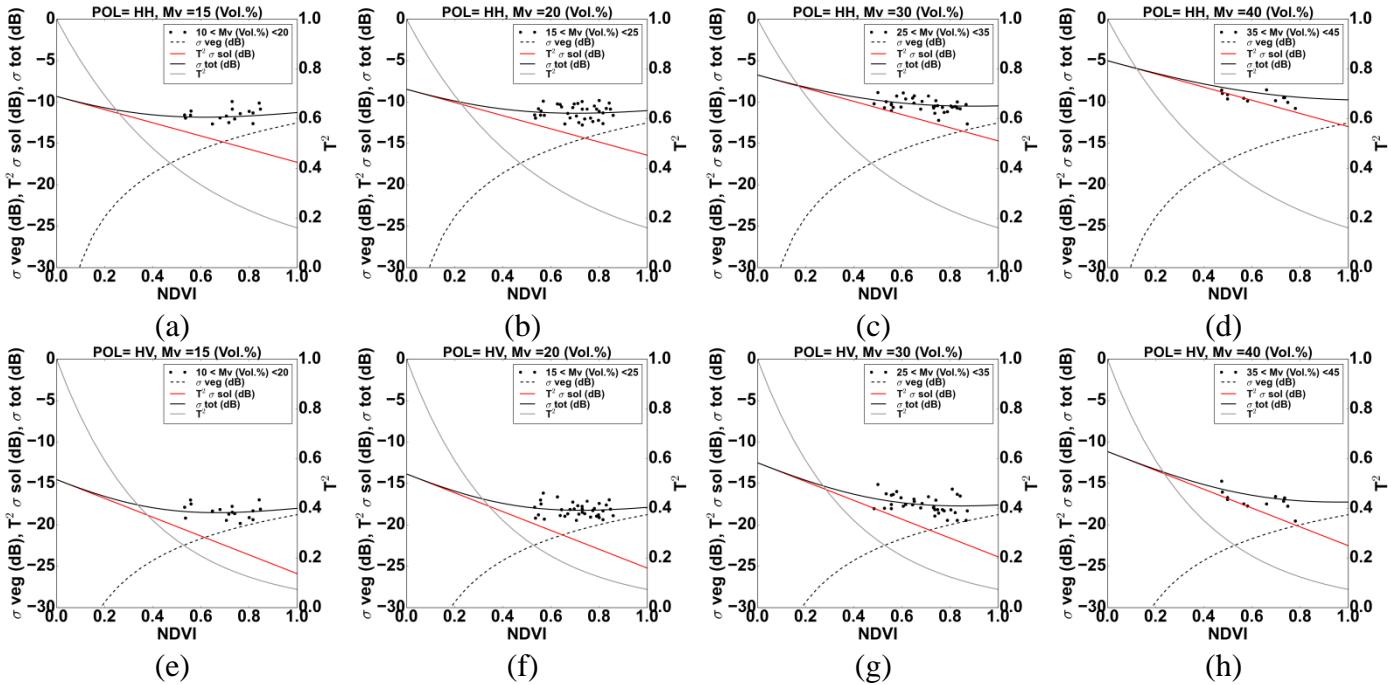


Figure 5. Behavior of WCM components ($\sigma^\circ_{\text{veg}}$, $T^2\sigma^\circ_{\text{sol}}$, and $\sigma^\circ_{\text{tot}}$) in both HH and HV polarizations according to NDVI. Black points represent the SAR data ($\sigma^\circ_{\text{tot}}$: real validation dataset) associated with Mv measurements within ± 5 vol. % of the Mv used in the modelling.

Case	Polarization	M _v (Vol.%)	Bias (dB)	RMSE (dB)	RRMSE (%)	MAPE (%)	R ²	Nb
Figure 5a	HH	15	-0.3	0.8	6.8	5.6	0.13	17
Figure 5b	HH	20	-0.1	0.9	7.7	6.7	0.00	36
Figure 5c	HH	30	0.1	0.7	7.1	5.4	0.16	37
Figure 5d	HH	40	0.6	0.8	8.7	7.6	0.32	12
Figure 5e	HV	15	-0.1	0.8	4.3	3.6	0.05	17
Figure 5f	HV	20	0.0	0.8	4.5	3.7	0.01	36
Figure 5g	HV	30	0.1	1.0	5.5	4.7	0.18	37
Figure 5h	HV	40	0.6	1.1	6.3	5.0	0.41	12

Table 7: Statistical index for each case in figure 5

Table 8 shows NDVI thresholds from which the $T^2\sigma^\circ_{\text{sol}}$ is dominated by $\sigma^\circ_{\text{veg}}$ ($T^2\sigma^\circ_{\text{sol}} < \sigma^\circ_{\text{veg}}$). In HH polarization, these thresholds are approximately 0.69, 0.74, 0.85, 0.97 for soil moisture of 15, 20, 30 and 40 Vol.%, respectively. In HV polarizations and for M_v values of 15, 20, 30

and 40 Vol.%, σ^o_{veg} dominates $T^2\sigma^o_{sol}$ for NDVI values greater than 0.62, 0.65, 0.71, and 0.79, respectively. Thus, for a given soil moisture value, the thresholds of NDVI for which the vegetation contribution dominates the soil contribution are lower in HV than in HH (Table 8).

M_v (Vol.%)	HH polarization				HV polarization			
	15	20	30	40	15	20	30	40
NDVI	0.69	0.74	0.85	0.97	0.62	0.65	0.71	0.79
LAI (m^2/m^2)	4.22	4.60	5.43	-	3.69	3.94	4.47	5.05
FAPAR	0.87	0.95	-	-	0.77	0.82	0.93	-
FCOVER	0.78	0.84	0.99	-	0.68	0.72	0.82	0.92
BIO (kg/m^2)	2.55	2.77	3.28	3.85	1.95	2.07	2.34	2.64
VWC (kg/m^2)	2.20	2.40	2.84	3.35	1.70	1.82	2.06	2.32
HVE (m)	0.70	0.76	0.90	-	0.55	0.58	0.65	0.73

Table 8. Threshold values of vegetation descriptors at which σ^o_{veg} dominates $T^2\sigma^o_{sol}$ at both HH and HV polarizations. Dash symbols mean that the σ^o_{veg} is always dominated by $T^2\sigma^o_{sol}$.

WCM components were also modelled using the LAI, FAPAR, FCOVER, BIO, VWC and HVE as vegetation descriptors. Similar results on the behavior of modelled total backscattered radar signal (σ^o_{tot}) were obtained with all vegetation descriptors. Table 8 shows the values of the vegetation descriptors at which σ^o_{veg} dominates $T^2\sigma^o_{sol}$. As an example, for soil moisture of 20 Vol.%, σ^o_{veg} in HH polarization dominates $T^2\sigma^o_{sol}$ for LAI values higher than $4.60 m^2/m^2$. In addition, for some soil moisture and vegetation descriptor conditions, the vegetation contribution is always dominated by the soil contribution (dash symbol in Table 8). As an example, for soil moisture of 40 Vol.%, the vegetation contribution in HH polarization is always dominated by the soil contribution for HVE values between 0 and 1.2 m (maximum value of HVE obtained by ground-truthed measurements and used in modelling). In addition, Table 8 shows that the vegetation contribution in HV polarization dominates the soil contribution at threshold values of vegetation descriptors which are lower than those observed in HH polarization.

4.2 Soil moisture retrieval

Synthetic and real datasets were used to estimate the soil moisture for the three inversion configurations defined in section 3.2: (1) using the radar signal in HH and one vegetation descriptor, (2) using the radar signal in HV and one vegetation descriptor, and (3) using the

radar signal in both HH and HV and one vegetation descriptor. The estimated soil moistures were compared to reference soil moisture values to evaluate the accuracy of the soil moisture estimates of each inversion configuration.

Before the use of neural networks for soil moisture estimation, the WCM model was numerically inverted. For some points of the synthetic and real datasets where the SAR backscattering coefficient is lower than the vegetation contribution simulated by the WCM, the direct inversion of the WCM is not numerically possible (about 10% of the datasets). Such limitation is overcome when using the NNs for both synthetic and real datasets. In addition, the Root Mean Square Error on M_v estimates was better with the NNs than using the direct inversion of the WCM (precision on M_v two times better). For these reasons, the neural networks inversion technique for soil moisture estimation was considered.

To estimate the soil moisture, neural networks were built for each inversion configuration using a part of the synthetic dataset. The quality of inversion approaches were studied using both the other part of the synthetic dataset and the real validation dataset.

4.2.1 Synthetic dataset

The synthetic dataset was composed of 2.10^7 elements (10 NDVI values x 8 M_v values x 500 random sampling values of the NDVI x 500 random sampling values of the simulated radar signal). According to the radiometric accuracy of the TerraSAR-X and COSMO-SkyMed signals, the radar signal simulated by the WCM model was noised using an additive Gaussian noise with zero mean and a standard deviation of 0.75 and 1 dB. The synthetic dataset was randomly divided into 80% training and 20% validation data samples. The prediction error based on a 5-fold cross-validation was estimated for each inversion configuration to assess the performance of the neural networks. Analysis of the results obtained with NDVI as the vegetation descriptor will be provided in detail whereas the results based on LAI, FAPAR, and FCover as the vegetation descriptors will be briefly described.

The Root Mean Square Error (RMSE), the Relative Root Mean Square Error (RRMSE), the Mean Absolute Percentage Error (MAPE), the associated mean deviation (bias = estimated M_v - reference M_v), and the correlation coefficient (R^2) were used to evaluate the performance of each inversion configuration. Table 9 presents statistical indexes (RMSE, RRMSE, MAPE, bias, and R^2) on M_v estimates computed from the validation dataset for reference M_v between 10 and 45 Vol.% and NDVI values between 0.45 and 0.90. Table 9 shows that the RMSE (as well as RRMSE, and MAPE) on M_v estimates is lower with HH polarization than with HV polarization (configuration 1 in comparison to configuration 2, Table 9). For a noise condition on the radar signal of ± 0.75 dB, the RMSE is 4.5 Vol.% (RRMSE and MAPE about 17 %)

with HH compared to 5.1 Vol.% (RRMSE and MAPE 19 %) with HV. In addition, results showed that the use of both HH and HV (in addition to the NDVI, configuration 3) slightly decreases the RMSE on M_v estimates (lower than 1 Vol.%). With configuration 3, the RMSE on M_v estimates reaches 3.7 Vol.% (RRMSE and MAPE about 14%) for a noise on the modeled radar signal of ± 0.75 (Table 9). Table 9 also shows that the RMSE on M_v increases when the noise added to the modeled radar signal increases. This increase is approximately 1 Vol.% when the noise on the radar signal increases from ± 0.75 dB to ± 1.00 dB (Table 9). Finally, Table 9 also shows that the three inversion configurations provide un-biased M_v estimates and significant correlation coefficient (R^2 between 0.77 and 0.90).

	Noise on σ^0_{tot}: ± 0.75 dB	Noise on σ^0_{tot}: ± 1.00 dB
Configuration 1 (HH and NDVI)	4.5 16.5 17.1 0.0 0.85	5.5 19.8 21.0 0.0 0.78
Configuration 2 (HV and NDVI)	5.1 18.5 19.2 0.0 0.81	5.7 20.7 21.8 0.0 0.77
Configuration 3 (HH, HV and NDVI)	3.7 13.6 13.7 0.0 0.90	4.5 16.2 16.7 0.0 0.85

Table 9. Statistical indexes on M_v estimates according to the three inversion configurations (RMSE (Vol.) | RRMSE (%) | MAPE (%) | bias (Vol.) | R^2). Configuration 1 uses HH and NDVI, configuration 2 uses HV and NDVI, and configuration 3 uses HH, HV and NDVI. Relative noise of the NDVI=15%.

Figure 6 illustrates the RMSE evolution of M_v estimates as a function of NDVI for values between 0.45 and 0.90 for each inversion configuration. For each value of NDVI, statistics were calculated using all M_v values. The results showed that the RMSE of M_v estimates increases with NDVI for all inversion configurations. As an example, in configuration 3 (HH, HV and NDVI), the RMSE of soil moisture estimates increases from 3.0 Vol.% for NDVI of 0.45 to 4.8 Vol.% for a NDVI of 0.9 for a noise condition on the radar signal of ± 0.75 dB (Figure 6a). The results showed that for a given NDVI value between 0.45 and 0.90, the RMSE is in same order in configurations 1 and 2 (configuration 1 is slightly better than configuration 2) (Figure 6). In addition, results obtained with HH were worse than those obtained with HH and HV.

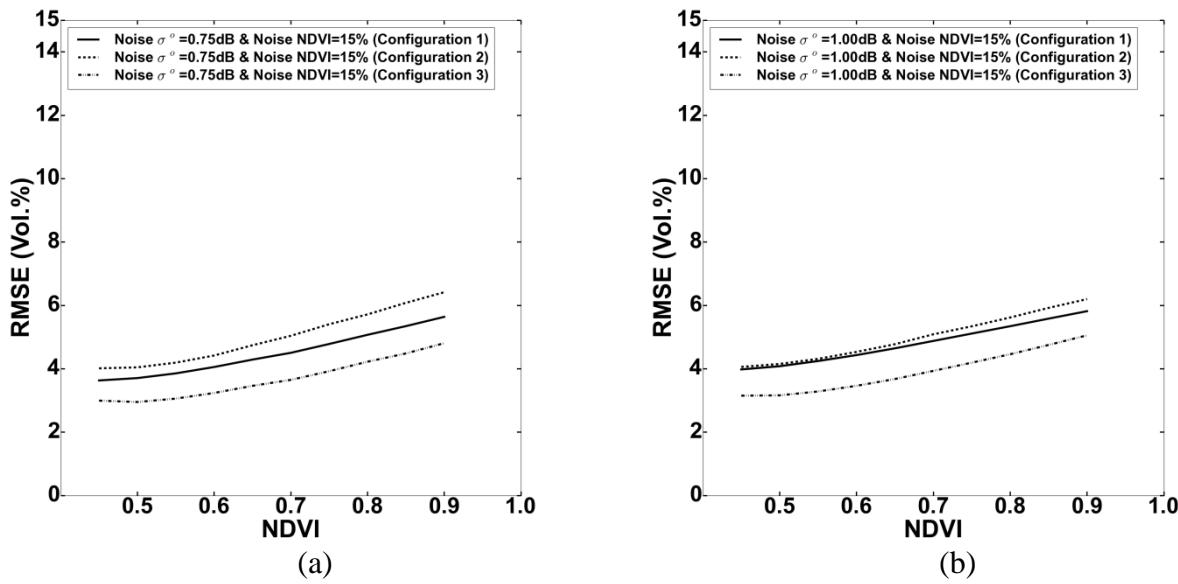


Figure 6. Evolution of RMSE of M_v estimates according to the three inversion configurations as a function of NDVI for noise conditions on the modeled radar signal of ± 0.75 dB (a), and ± 1 dB (b).

Moreover, the performances of neural networks for estimating soil moisture were analyzed according to NDVI for given M_v values (Figure 7). The results showed that the relative RMSE ($RRMSE = RMSE / M_v$) of M_v estimates increases with the NDVI for the three inversion configurations. Indeed, as the vegetation grows (i.e., increasing NDVI values) the soil contribution decreases and the backscattering coefficients become less sensitive to soil moisture. In addition, for a given NDVI between 0.45 and 0.90 the RRMSE decreases when M_v increases (Figure 7) because for a given NDVI value the soil contribution is more important for high than for low soil moisture conditions, and consequently, the errors on M_v estimates decrease when M_v increases. As an example, in configuration 1 (HH and NDVI), for a NDVI of 0.75 (LAI about $3 \text{ m}^2/\text{m}^2$), the RRMSE values are approximately 28.3, 20.0, 16.3, and 12.0% for reference M_v of 15, 20, 30 and 40 Vol.%, respectively. For low M_v (lower than 20 Vol.%), the RRMSE increases significantly with NDVI for high NDVI values (higher than 0.75, LAI about $3 \text{ m}^2/\text{m}^2$) in comparison to the RRMSE observed for higher M_v values (higher than 20 Vol.%). As an example, in configuration 3 (HH, HV and NDVI), the RRMSE on M_v estimates increases for M_v of 15 Vol.% and noise condition on the simulated radar signal of 0.75 dB from approximately 21% for NDVI=0.45 to 30% for NDVI=0.90. This increase in the RRMSE is only approximately 5% for M_v of 30 Vol.% (RRMSE increases from approximately 11% for NDVI=0.45 to 16% for NDVI=0.90) (Figure 7).

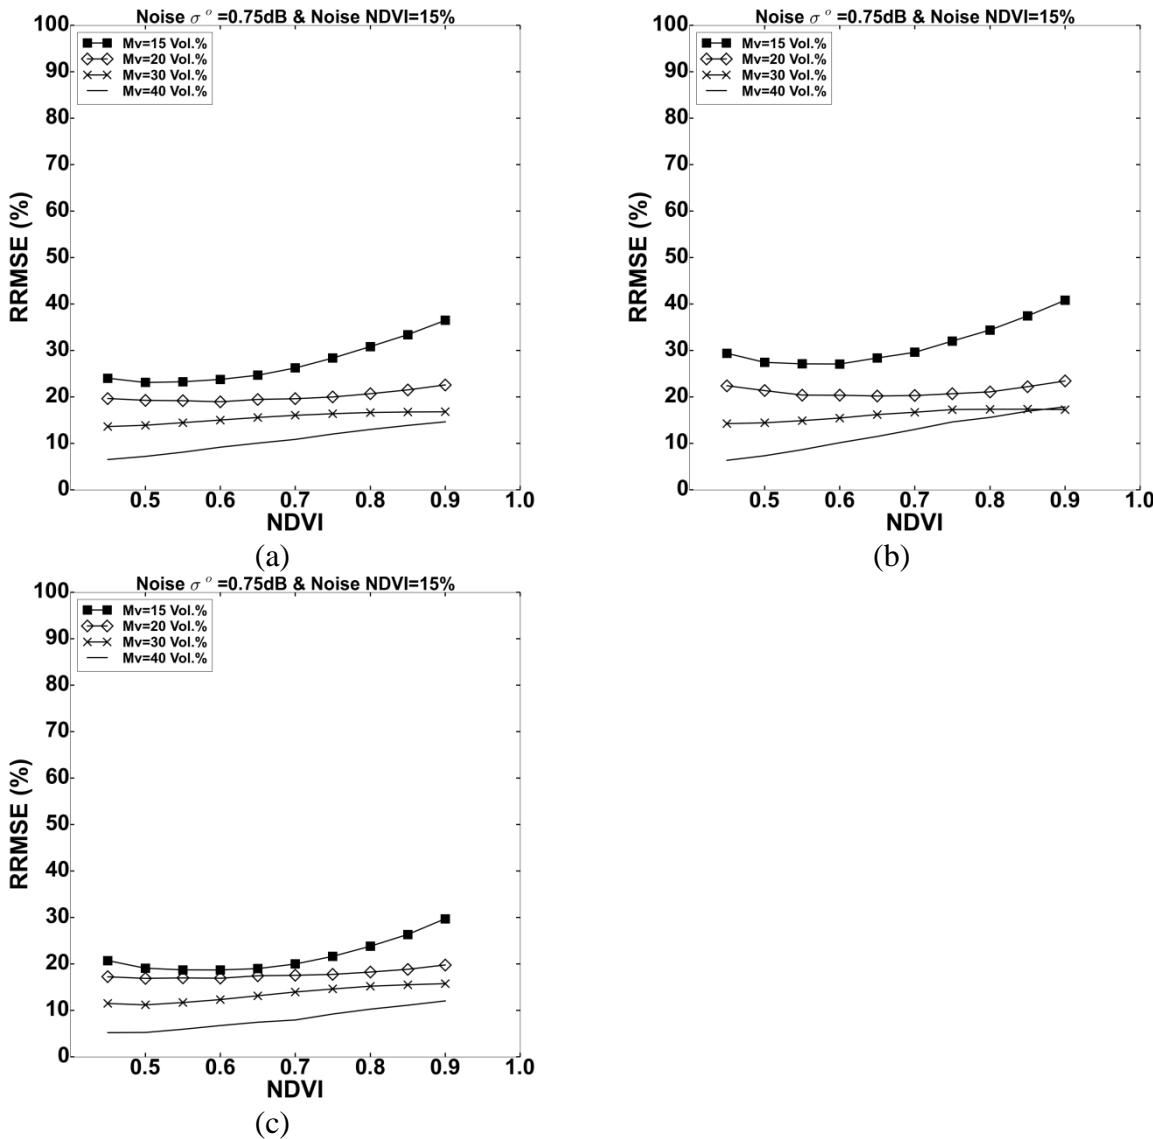


Figure 7. Evolution of the relative RMSE (in percent) of M_v estimates (RRMSE=RMSE/ M_v) according to NDVI and M_v . (a) configuration 1: HH and NDVI, (b) configuration 2: HV and NDVI, and (c) configuration 3: HH, HV and NDVI.

The difference between the estimated and reference M_v were also analyzed as a function of NDVI using for each NDVI and all M_v values (Figure 8). For a given NDVI between 0.45 and 0.90, the bias on M_v estimates is similar for radar signal noise of ± 0.75 and ± 1 dB. The results showed a slight underestimation (lower than approximately 1 Vol.%) of M_v estimates for NDVI values between 0.60 (LAI about $1\text{m}^2/\text{m}^2$) and 0.90 (LAI about $6\text{ m}^2/\text{m}^2$). In addition, a slight overestimation of M_v is observed for a NDVI lower than 0.60 (lower than approximately 1 Vol. %).

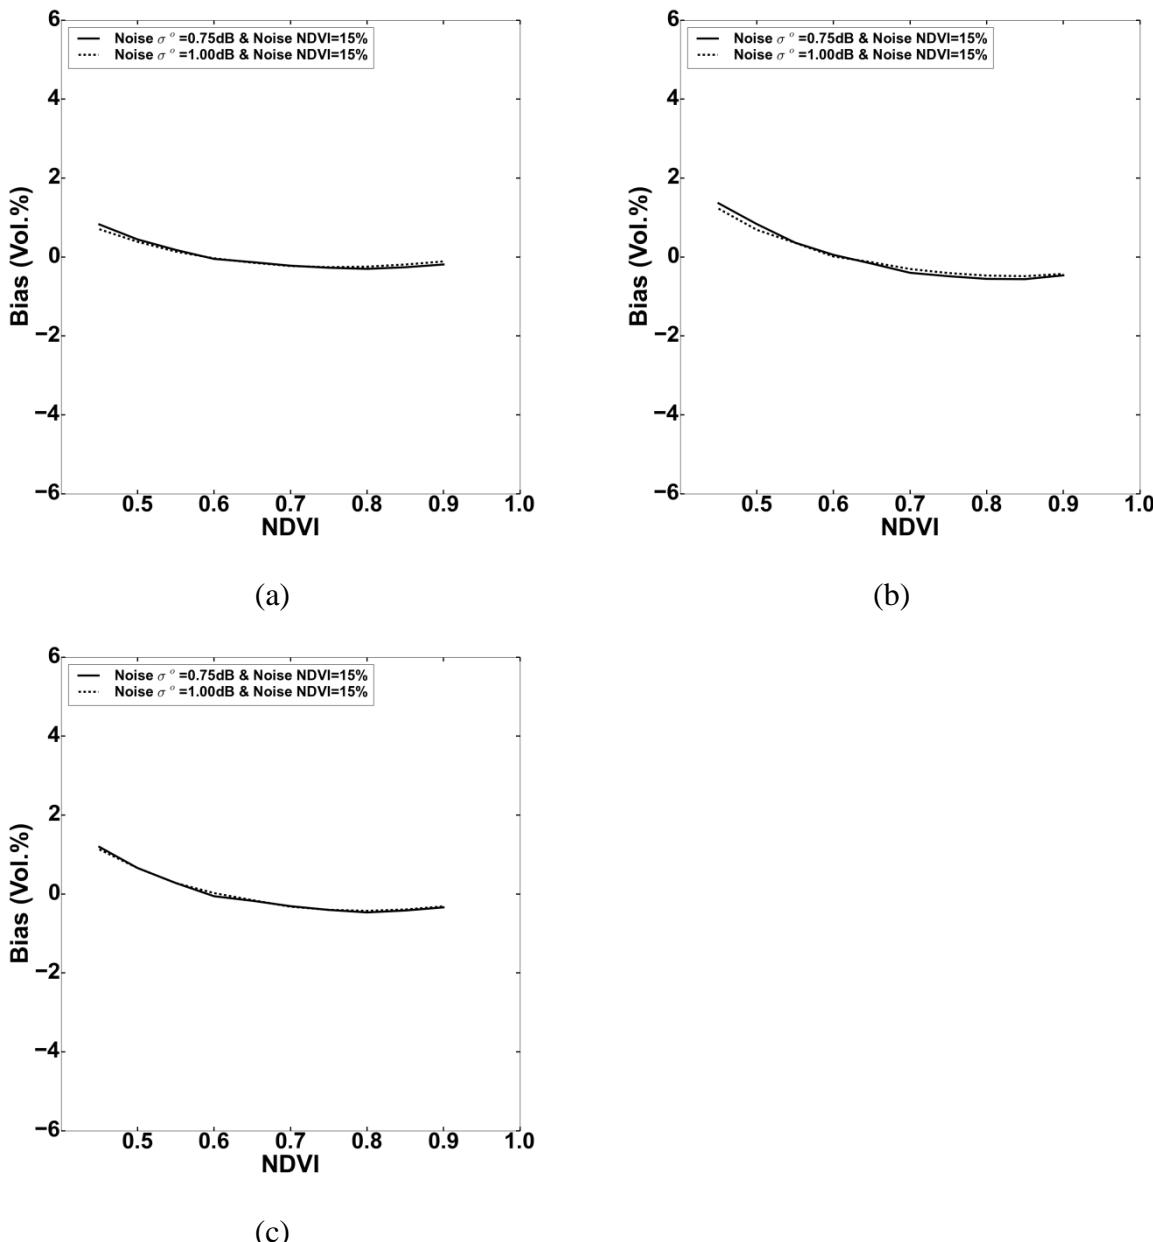


Figure 8. Evolution of the bias (estimated M_v – reference M_v) of M_v estimates according to NDVI values. (a) Inversion configuration 1, (b) inversion configuration 2, and (c) inversion configuration 3.

Figure 9 shows the evolution of bias on M_v estimates obtained for the three inversion configurations as a function of the NDVI for some M_v values (15, 20, 30 and 40 Vol.%). For NDVI values lower than approximately 0.65 (LAI about $1.5 \text{ m}^2/\text{m}^2$), the bias on M_v estimates is lower than 1.5 Vol.% for M_v between 15 and 40 Vol.%, in the case of configurations 1 and 3. For the inversion configuration 2, the bias reaches 5.4 Vol.% (for $M_v = 40$ Vol.%). In

addition, results showed that the bias increased when the NDVI increased, regardless of the M_v values. This increase was mainly observed when the NDVI was greater than 0.75 (LAI about $3 \text{ m}^2/\text{m}^2$) for low M_v values (Figure 9). An overestimation of M_v estimates is mainly observed for M_v values lower than 20 Vol.%, while an underestimation is mainly observed for M_v values higher than 30 Vol.%. Figure 9 also showed that for a given M_v , the bias is lower for configurations 1 and 3. The bias reaches 3.5 Vol.% for configurations 1 and 3 compared to 5 Vol.% for configuration 2 for $\text{NDVI} = 0.9$ and $M_v = 15 \text{ Vol.}\%$. Figure 10 shows an example of box plots calculated for the inversion of configuration 3 and some NDVI values (0.6, 0.7, 0.8 and 0.9).

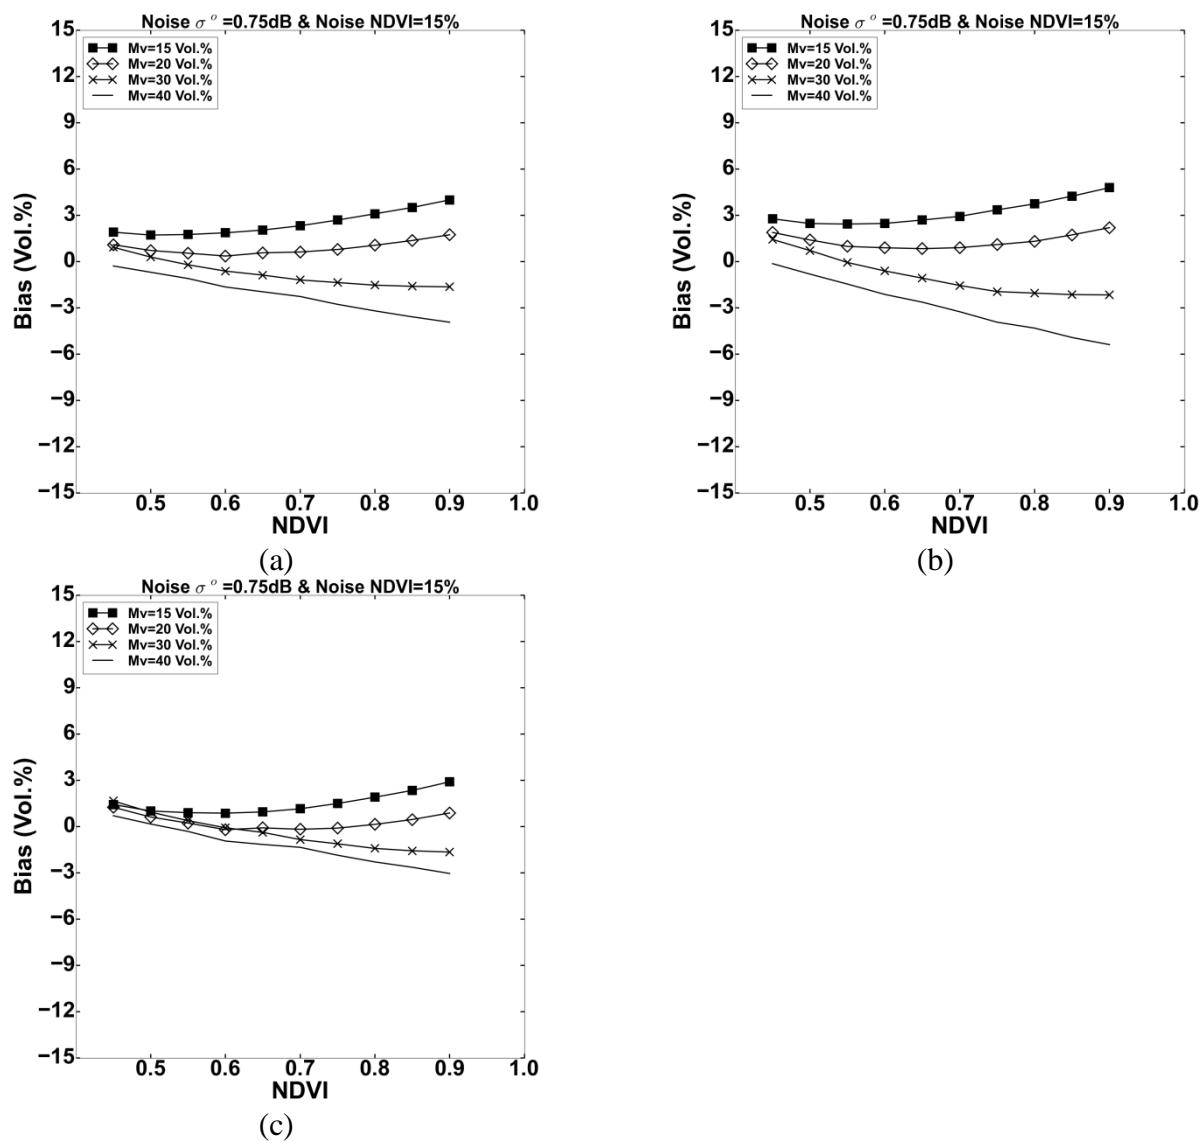


Figure 9. Evolution of the bias (estimated M_v – reference M_v) on M_v estimates according to NDVI and M_v values for noise on the modeled radar signal of 0.75 dB. (a) configuration 1, (b) configuration 2, and (c) configuration 3.

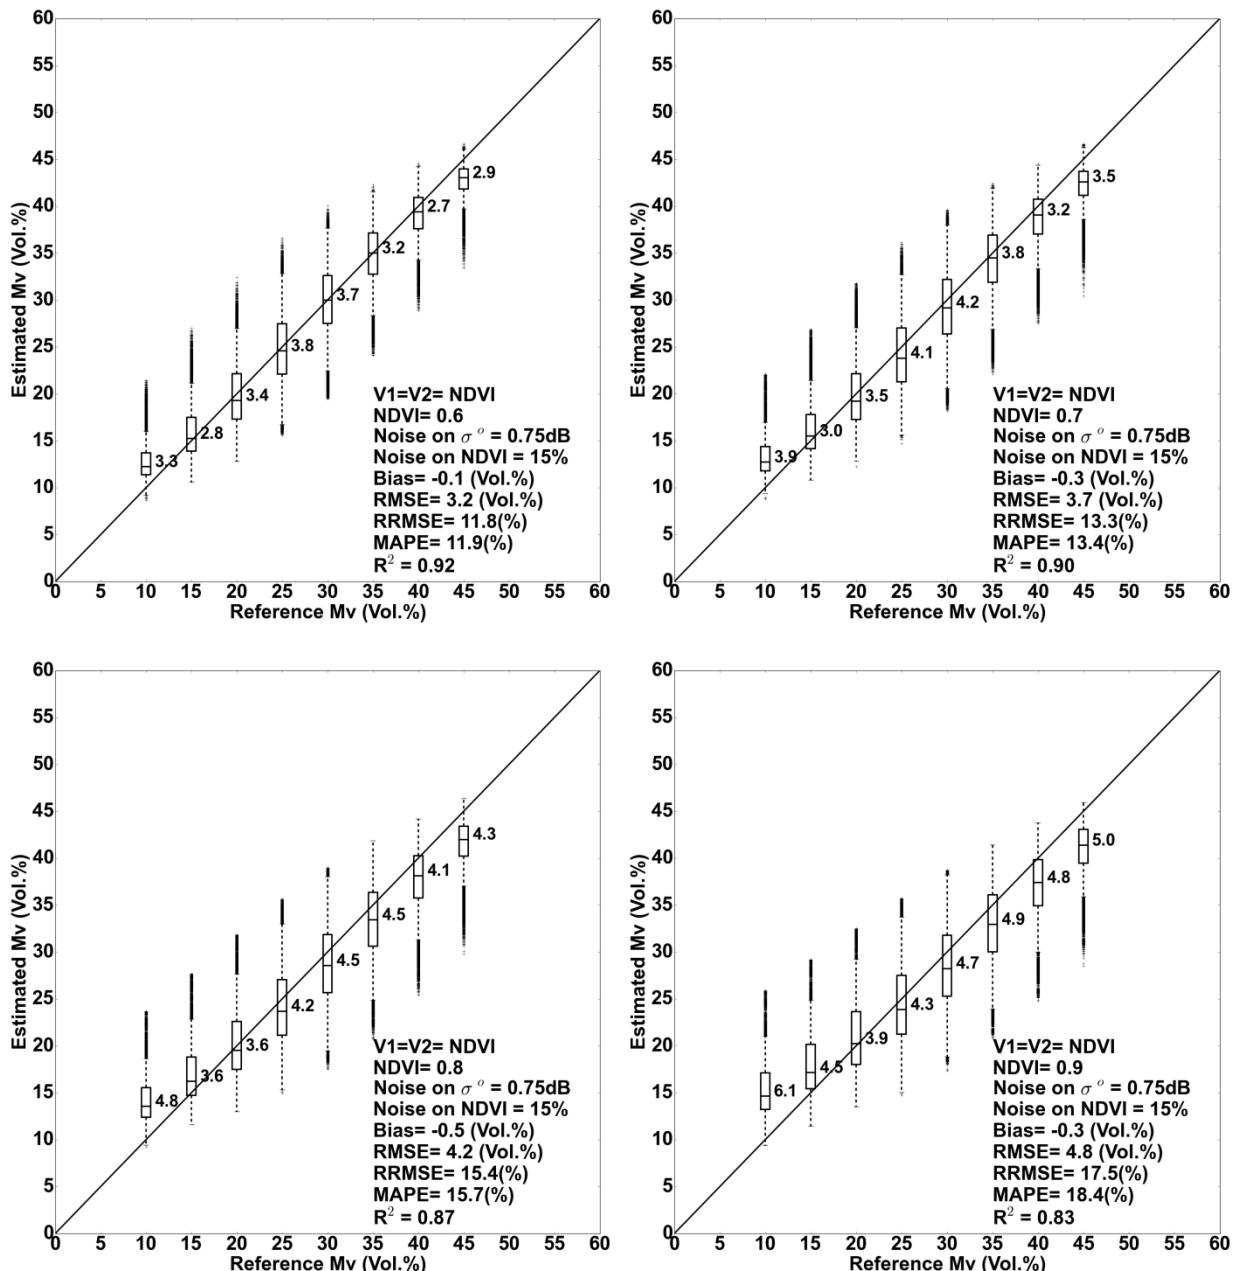


Figure 10. Box plots of M_v estimates retrieved from the synthetic dataset. Neural networks were trained and validated according to configuration 3 (using HH, HV and NDVI). Noise on the modeled radar signal is ± 0.75 dB, and noise on NDVI is 15% of the NDVI value. Values to the right of the box plots represent the RMSE on M_v estimates for a given reference M_v .

Moreover, 5-fold cross-validation was used to predict errors on M_v estimates for each inversion configuration performed using the synthetic dataset with LAI, FAPAR, and FCover as vegetation descriptors. Table 10 shows statistics (RMSE, RRMSE, MAPE, bias, and R^2) on M_v estimates computed from the validation dataset for reference M_v values

between 10 and 45 Vol.% and a LAI between 0 and 6 and FAPAR (as well as FCOER) between 0 and 1. The results show that regardless of the vegetation descriptor used, the RMSE on M_v estimates is lower using HH compared to HV polarization (configuration 1 in comparison to configuration 2). In addition, the use of HH and HV polarizations slightly decreases the RMSE on M_v estimates. Table 10 also shows that the RMSE on M_v estimates increases approximately 1 Vol.% when noise added to the radar signal increases. For each inversion configuration and for a given noise condition on the modeled radar signal, the RMSE on M_v estimates is in the same order with the use of NDVI, LAI, FAPAR, or FCOVER as a vegetation descriptor (Table 10). Finally, the results showed that whatever the vegetation descriptor used, the three inversion configurations provide un-biased M_v estimates.

	Noise on σ^0_{tot} :	Noise on σ^0_{tot} :
	± 0.75 dB	± 1.00 dB
V1=V2=NDVI		
Relative noise = 15 %		
Configuration 1	4.5 16.5 17.1 0.0 0.85	5.5 19.8 21.0 0.0 0.78
Configuration 2	5.1 18.5 19.2 0.0 0.81	5.7 20.7 21.8 0.0 0.77
Configuration 3	3.7 13.6 13.7 0.0 0.90	4.5 16.2 16.7 0.0 0.85
V1=V2=LAI		
Relative noise = 30 %		
Configuration 1	5.6 20.5 20.6 0.0 0.76	6.7 24.5 25.4 0.0 0.65
Configuration 2	7.1 26.0 26.9 0.0 0.61	8.1 29.3 31.2 0.0 0.50
Configuration 3	5.2 0.0 18.9 18.8 0.79	5.8 21.1 21.3 0.0 0.74
V1=V2=FAPAR		
Relative noise = 20 %		
Configuration 1	5.2 18.9 18.8 0.0 0.79	6.4 23.1 24.1 0.0 0.69
Configuration 2	6.3 22.8 23.3 0.0 0.70	7.3 26.7 28.0 0.0 0.59
Configuration 3	4.4 16.0 15.7 0.0 0.85	5.4 19.7 19.9 0.0 0.78
V1=V2=FCOVER		
Relative noise = 20 %		
Configuration 1	5.2 18.7 18.8 0.0 0.80	6.5 23.8 24.4 0.0 0.67
Configuration 2	7.1 25.7 26.7 0.0 0.62	7.8 28.3 30.0 0.0 0.54
Configuration 3	4.7 16.9 16.8 0.0 0.84	5.7 20.7 20.9 0.0 0.75

Table 10. RMSE and Bias on M_v estimates according to the three inversion configurations (RMSE (Vol.%) | RRMSE (%) | MAPE (%) | bias (Vol.%) | R^2). Configuration 1 uses HH and vegetation descriptor, configuration 2 uses HV and vegetation descriptor, and configuration 3 uses HH, HV and vegetation descriptor.

4.2.2 Real dataset

The capacity of the developed Neural Networks (NNs) to correctly estimate the soil moisture was then tested using the real dataset. The NNs applied to the real validation dataset are those which have been trained and validated using the synthetic dataset. NDVI, LAI, FAPAR and FCOVER derived from optical images were used as the input vegetation descriptors for the trained NNs. Inversion results obtained with the NDVI derived from optical images as the vegetation descriptor will be provided in detail, whereas the results based on the LAI, FAPAR, FCOVER derived from optical images as the vegetation descriptor will be briefly described.

First, statistics (RMSE, RRMSE, MAPE, bias, R^2) on M_v estimates were also computed for all NDVI observations (Table 11). Slightly better statistics were observed with the noise on a modeled radar signal of ± 1.00 dB. With the noise of ± 1.00 dB, the RMSE is 4.5, 6.0 and 5.5 Vol.% in configuration 1, 2 and 3, respectively. Moreover, a slight underestimation (about -0.1 Vol.%) was observed in configuration 1 for the noise conditions of ± 0.75 dB and ± 1.00 dB. For configurations 2 and 3, an underestimation of M_v estimates was observed (about -1.4 Vol.% in configuration 2 and -1 Vol.% in configuration 3).

From the synthetic dataset, the inversion results show that the best soil moisture estimates was obtained when both HH and HV polarizations were used. However, the inversion results from the real dataset show that the use of only HH polarizations allows the best soil moisture estimates. This is because the absolute errors adopted to noisy the radar signal is not equal to the real uncertainty on radar measurement. This real uncertainty depends on sensors and polarizations.

	Noise on σ^0_{tot} : ± 0.75 dB	Noise on σ^0_{tot} : ± 1.00 dB
	NDVI = [0.45-0.90]	NDVI = [0.45-0.90]
Configuration 1 (HH and NDVI)	4.9 18.4 16.4 -0.1 0.60 93	4.5 17.0 15.5 -0.1 0.63 93
Configuration 2 (HV and NDVI)	6.8 25.7 23.1 -1.3 0.37 93	6.0 22.6 19.8 -1.3 0.42 93
Configuration 3 (HH, HV and NDVI)	6.2 23.5 21.2 -0.8 0.49 93	5.5 20.5 18.0 -0.9 0.53 93

Table 11. statics on M_v estimates according to the three inversion configurations (RMSE (Vol.%) | RRMSE (%) | MAPE (%) | bias Vol.% | R^2 | samples). Configuration 1 uses HH and NDVI, configuration 2 uses HV and NDVI, and configuration 3 uses HH, HV and NDVI. Relative noise on the NDVI=15%. Real SAR measurements and the LAI derived from optical images were used to estimate M_v .

Next, the statistics were computed from the real dataset of validation for NDVI classes of 0.05 (NDVI was derived from optical images are between 0.45 and 0.9). The results showed

that the RMSE on M_v estimates was in the same order for NDVI classes between 0.45 and 0.75 (LAI about $3\text{m}^2/\text{m}^2$) on the one hand (difference lower than 1 Vol.%), and on the other hand for NDVI classes between 0.75 (LAI about $3 \text{ m}^2/\text{m}^2$) and 0.90 (LAI about $6 \text{ m}^2/\text{m}^2$). Therefore, the results of M_v estimates were presented for two classes of NDVI: NDVI lower and higher than 0.75 (Table 12). The comparison between estimated M_v and M_v ground-truthed measurements is given in Figures 11 and 12. RMSE and bias on M_v estimates are lower with the noise condition on the modeled radar signal of ± 1 dB.

Results showed that for a $\text{NDVI} < 0.75$ the trained NNs provide M_v estimates with slight bias (-0.2, -1.7, and -0.9 Vol.% in configurations 1, 2 and 3, respectively) (Table 12, Figure 11). For a $\text{NDVI} > 0.75$, a slight bias (between -1 and 0.1 Vol.%) was observed for the noise on the radar signal of ± 1 dB, with the lower value for the inversion using HH and NDVI (0.1 Vol.%) (Table 12, Figure 12). Moreover, a RMSE of 3.6 (RRMSE and MAPE about 12%), 5.4 (RRMSE and MAPE about 18%), and 4.4 (RRMSE and MAPE about 15%) Vol.% were observed for configurations 1, 2 and 3, respectively, in the case of a NDVI lower than 0.75 and for modeled radar signal noise of ± 1 dB (Table 12, Figure 11). For a NDVI higher than 0.75, the RMSE on M_v estimates is 6.1 (RRMSE and MAPE about 24%), 7.1 (RRMSE and MAPE about 28%) and 7.3 (RRMSE and MAPE about 29%) Vol.%, respectively, for configurations 1, 2 and 3 and for the noise on the modeled radar signal of ± 1 dB (Table 12, Figure 12).

The validity of the inversion method is limited for NDVI lower than 0.75 ($\text{LAI} \sim 3\text{m}^2/\text{m}^2$). Indeed, for NDVI higher than 0.75 the correlation coefficient between estimated and measured soil moisture is poor (≤ 0.10) (Table 12, Figure 12).

	Noise on σ^0_{tot} : ± 0.75 dB		Noise on σ^0_{tot} : ± 1.00 dB	
	NDVI < 0.75	NDVI > 0.75	NDVI < 0.75	NDVI > 0.75
Configuration 1	3.8 13.9 12.4 0.0 0.77 64	6.6 27.3 25.3 -0.3 0.07 29	3.6 13.1 11.8 -0.2 0.79 64	6.1 24.9 23.5 0.1 0.10 29
Configuration 2	6.0 21.7 19.8 -1.5 0.52 64	8.4 34.5 30.6 -0.8 0.04 29	5.4 19.7 17.0 -1.7 0.56 64	7.1 29.2 26.1 -0.5 0.07 29
Configuration 3	5.0 18.2 16.8 -0.7 0.67 64	8.3 34.2 30.9 -1.1 0.04 29	4.4 15.8 13.9 -0.9 0.71 64	7.3 30.1 26.9 -1.0 0.06 29

Table 12. RMSE and bias on M_v estimates according to the three inversion configurations (RMSE (Vol.%) | RRMSE (%) | MAPE (%) | bias Vol.% | R^2 | samples). Configuration 1 uses HH and NDVI, configuration 2 uses HV and NDVI, and configuration 3 uses HH, HV and NDVI. Relative noise on the NDVI=15%. Real SAR measurements and NDVI derived from optical images were used to estimate M_v .

Moreover, the SAR real validation dataset was inverted to estimate soil moisture by means of trained NNs with the use of each of the vegetation descriptors derived from optical images LAI, FAPAR, and FCOVER). Table 13 shows the (RMSE, RRMSE, MAPE, bias, R^2) s on M_v estimates in the three inversion configurations for two classes of NDVI: NDVI lower and higher than 0.75 (LAI about $3m^2/m^2$). The results showed that the RMSE (as well as RRMSE, MAPE) on M_v estimates are almost similar, regardless of which vegetation descriptors derived from optical images were used (NDVI, LAI, FAPAR, or FCOVER) (Table 13).

In conclusion, the use of HH polarization in addition to a vegetation descriptor derived from optical images (Configuration 1) provides a better estimation of the soil moisture with a RMSE approximately 4.5 and 7.0 Vol.% for a NDVI lower and higher than 0.75 (LAI about $3 m^2/m^2$), respectively. The use of HV in addition to HH slightly lowers the precision of M_v estimates.

	Noise on σ^0_{tot} : $\pm 0.75 \text{ dB}$		Noise on σ^0_{tot} : $\pm 1.00 \text{ dB}$	
	NDVI < 0.75	NDVI > 0.75	NDVI < 0.75	NDVI > 0.75
V1=V2=NDVI				
Relative noise = 15 %				
Configuration 1	3.8 13.9 12.4 0.0 0.77 64	6.6 27.3 25.3 -0.3 0.07 29	3.6 13.1 11.8 -0.2 0.79 64	6.1 24.9 23.5 0.1 0.10 29
Configuration 2	6.0 21.7 19.8 -1.5 0.52 64	8.4 34.5 30.6 -0.8 0.04 29	5.4 19.7 17.0 -1.7 0.56 64	7.1 29.2 26.1 -0.5 0.07 29
Configuration 3	5.0 18.2 16.8 -0.7 0.67 64	8.3 34.2 30.9 -1.1 0.04 29	4.4 15.8 13.9 -0.9 0.71 64	7.3 30.1 26.9 -1.0 0.06 29
V1=V2=LAI				
Relative noise = 30 %				
Configuration 1	4.7 17.1 15.9 -0.0 0.65 64	7.3 29.7 27.2 -1.5 0.02 29	4.5 16.3 15.3 0.6 0.67 64	7.5 30.6 28.9 0.3 0.00 29
Configuration 2	7.5 27.1 23.8 -1.1 0.36 64	10.0 41.0 34.9 -3.2 0.00 29	7.1 25.8 22.2 -1.1 0.35 64	9.0 36.8 31.4 -2.5 0.00 29
Configuration 3	5.6 20.1 17.3 -0.9 0.57 64	8.4 34.5 30.5 -2.5 0.00 29	5.7 20.7 17.7 -0.5 0.55 64	8.7 35.7 31.1 -2.2 0.00 29
V1=V2=FAPAR				
Relative noise = 20 %				
Configuration 1	5.0 18.1 16.2 0.5 0.63 64	7.9 32.6 30.3 -0.7 0.00 29	4.9 17.8 16.6 1.2 0.63 64	7.4 30.4 29.0 0.7 0.00 29
Configuration 2	8.1 29.2 25.8 -0.0 0.34 64	10.9 44.6 39.3 -3.1 0.00 29	7.2 26.2 22.4 -0.1 0.34 64	9.1 37.2 32.5 -1.7 0.00 29
Configuration 3	6.4 23.3 20.5 0.4 0.52 64	9.5 38.9 34.2 -2.4 0.00 29	6.2 22.4 19.5 0.9 0.51 64	8.8 36.1 32.4 -1.3 0.01 29
V1=V2=FCOVER				
Relative noise = 20 %				
Configuration 1	5.1 18.6 16.5 0.8 0.62 64	8.0 33.0 30.7 -0.7 0.01 29	5.0 18.3 17.1 0.9 0.62 64	6.8 27.5 25.2 -0.4 0.03 29
Configuration 2	7.6 27.5 23.7 -0.6 0.34 64	10.0 40.9 35.1 -3.3 0.01 29	7.2 25.9 21.8 -0.7 0.34 64	9.1 37.2 31.9 -2.5 0.01 29
Configuration 3	6.0 21.6 19.0 0.3 0.55 64	9.2 37.6 32.7 -2.5 0.01 29	5.9 21.4 18.2 0.2 0.54 64	8.4 34.5 30.1 -1.9 0.01 29

Table 13. Statics on M_v estimates according to the three inversion configurations (RMSE (Vol.%) | RRMSE (%) | MAPE (%) | bias Vol.% | R^2 | samples). Configuration 1 uses HH and NDVI, configuration 2 uses HV and NDVI, and configuration 3 uses HH, HV and NDVI. Real SAR measurements, and NDVI, LAI, FAPAR and FCOVER derived from optical images were used to estimate M_v .

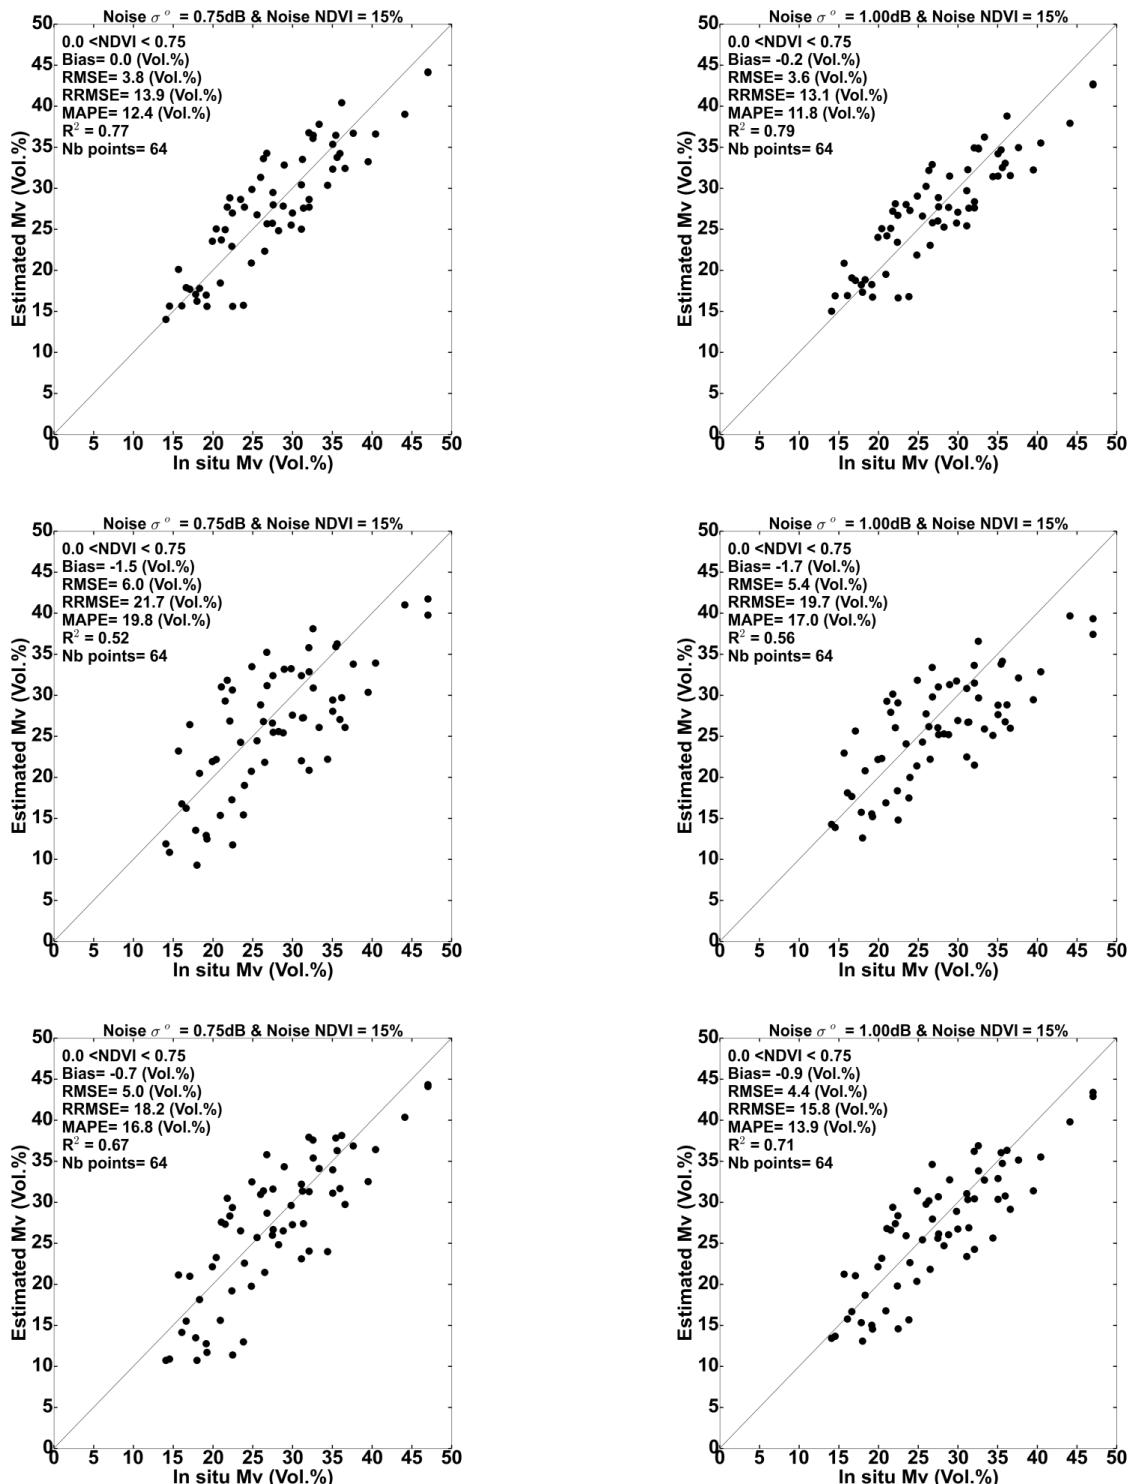


Figure 11. Retrieved soil moisture versus ground-truthed measurements for NDVI lower than 0.75. (a,b): configuration 1; (c,d): configuration 2; (e,f): configuration 3. Bias = estimated M_v - reference M_v.

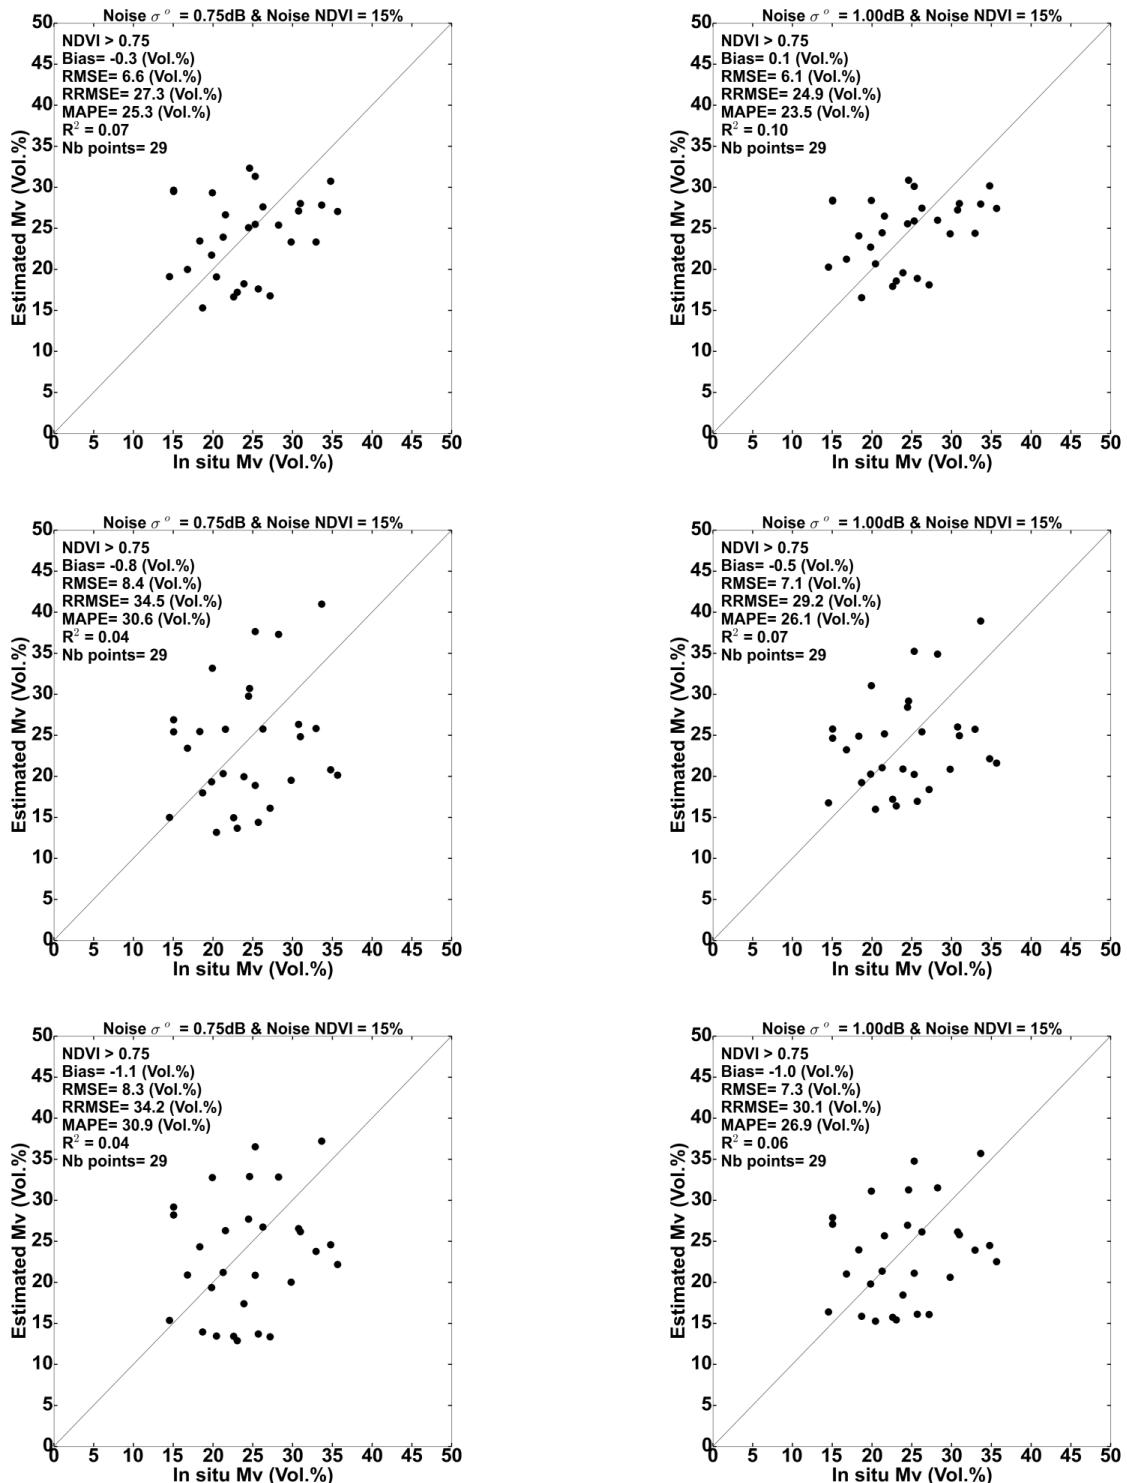


Figure 12. Retrieved soil moisture versus ground-truthed measurements for NDVI higher than 0.75 . (a,b): configuration 1; (c,d): configuration 2; (e,f): configuration 3. Bias = estimated M_v - reference M_v .

5. Conclusion

The aim of this study was to assess the potential of coupling X band SAR and optical images for soil moisture estimation over irrigated grassland areas using the Water Cloud Model (WCM). An inversion technique based on multi-layer perceptron Neural Networks (NNs) was developed to invert the WCM and estimate soil moisture. The WCM was first parameterized using 47% of the real dataset (53% were used in the validation process), and next used to generate a SAR synthetic dataset with the use of one vegetation descriptor among NDVI, LAI, FAPAR, and FCover that could be derived from optical images. The simulated backscattering coefficients from the WCM were noisy using absolute additive noise of ± 0.75 and ± 1 dB to make simulated backscattering coefficients closer to real SAR measurements. In addition, a relative additive noise was added to each vegetation descriptor value to handle the associated uncertainty (15% in case of NDVI, 30% in case of LAI, and 20% in case of FAPAR and FCover). Three inversion configurations were defined for soil moisture estimation (M_v): (1) radar signal in HH polarization with one vegetation descriptor, (2) radar signal in HV polarization with one vegetation descriptor, and (3) radar signal in both HH and HV polarizations with one vegetation descriptor. For each inversion configuration, the NNs were trained with 80% of the synthetic dataset and then applied to the remaining 20% of the synthetic dataset and to the real validation dataset to validate the inversion approach.

Inversion results of the synthetic dataset showed that the best M_v estimates were obtained with the use of HH (in addition to one vegetation descriptor: configuration 1) or in using both HH and HV (in addition to one vegetation descriptor: configuration 3). However, the use of HV (in addition to one vegetation descriptor: configuration 2) degrades the precision on M_v estimates. Moreover, results showed that the RMSE on M_v estimates is slightly sensitive to additive noise on the modelled radar signal. The RMSE increases approximately 1 Vol.% when the noise of the radar signal increases from ± 0.75 dB to ± 1.00 dB. For all NDVI values, the RMSE on M_v estimates (M_v between 10 and 45 Vol.%) was approximately 5.0 Vol.% (RRMSE and MAPE about 19 %) in configurations 1 and 3. Similar values of the RMSE (as well as RRMSE and MAPE) on M_v estimates were obtained with the use of LAI, FAPAR, and FCover as the vegetation descriptor. The accuracy of M_v estimates degrades (i.e., an increase in the RMSE, RRMSE, and MAPE) with vegetation growth (i.e., an increase in the NDVI). As an example, in configuration 3 (HH, HV and NDVI), the RMSE on M_v estimates increases from 3.6 Vol.% (RRMSE about 13%) for NDVI of 0.45 to 5.7 Vol.% (RRMSE about 21 %) for a NDVI of 0.9.

From the real validation dataset, the soil moisture estimation (53% of the real dataset) using the X band SAR (in addition to one vegetation descriptor: configuration 1) allows better

results with HH polarization than with HV or both HH and HV. With HH and NDVI information derived from optical images, the accuracy on the soil moisture estimation was 3.6 Vol.% (RRMSE and MAPE about 13%, $R^2 = 0.79$) for NDVI between 0.45 and 0.75 (LAI about 3 m^2/m^2). However, for NDVI of the grassland between 0.75 and 0.9 (LAI about 6 m^2/m^2) the estimation of soil moisture from X band SAR data (HH and NDVI) was not reliable ($R^2 = 0.1$). Similar results were obtained regardless the vegetation descriptor used. With the arrival of new satellites, such as SENTINEL-1A (launched on 3 April 2014), in addition to future satellites SENTINEL-1B, SENTINEL-2A (optical sensor), and SENTINEL-2B, it will be possible to obtain SAR (C-band) and optical remote sensing data covering global areas with high spatial and temporal resolutions (2 days with 2 SENTINEL-1 satellites, and 5 days for 2 SENTINEL-2 satellites at 10 m spatial resolution). Combining SENTINEL-1 data with optical images (SENTINEL-2, LANDSAT-7/8) will allow more precise estimation of M_v because the radar signal penetration depth into vegetation cover is higher in the C band compared to the X band. This work is in the context of preparing for SENTINEL 1 and 2 missions.

This study demonstrated that the use of NNs technique to invert X band SAR backscattering coefficients allows the estimation of soil moisture with acceptable accuracy (RMSE of 3.6 Vol.% for a NDVI lower than 0.75). Current remote sensing sensors (optical and SAR) and those available in the near future (spatial resolution better than 10 m) will allow the estimation of soil moisture at a field scale with high temporal resolution (better than weekly). Vegetation biophysical parameters (i.e., LAI) and soil moisture that can be derived from optical and SAR images could be useful to calibrate crop models for better irrigation management and crop growth monitoring. Indeed, combining optical and SAR data would enhance the relevance of remote sensing data for water and crop monitoring.

CHAPITRE 5 :

*Intégration de paramètres dérivés de la télédétection dans
les modèles de culture*

1. Objectifs

L'objectif de cette partie est d'analyser l'apport de paramètres issus de l'imagerie spatiale optique et radar pour la prédiction de la croissance de végétation dans un périmètre irrigué.

La plupart des modèles de culture utilisent le LAI comme variable d'état décrivant le stade de développement d'une culture. Par ailleurs, deux paramètres de décision importants doivent être considérés : les dates de démarrage et de fin des cycles de culture (pour notre système, il s'agit des dates de coupe), et les dates d'irrigations. Ces paramètres pourraient être estimés à partir des données optiques (LAI et dates des coupes) et à partir des données radar (dates d'irrigations). L'objectif est d'analyser la pertinence de ces estimations pour représenter l'évolution du système de culture, et notamment le rendement prédict.

2. Base des données

La base de données est la même que celle présentée dans le chapitre 3.

3. Méthode

Pour atteindre notre objectif nous avons choisi le modèle PILOTE comme cas d'application. Ce modèle, propriété d'IRSTEA et développé à l'UMR G-eau, a été paramétré sur les prairies irriguées de notre site d'étude en utilisant des données *in situ* récoltées en 2004-2006 (Mailhol and Merot, 2008). Cette section décrit la méthodologie que nous avons adaptée pour analyser l'effet de l'intégration du LAI, des dates de coupes et d'irrigations estimés à partir des données spatiales sur la prédiction de la matière sèche totale (TDM) par le modèle. L'effet de l'intégration des paramètres (LAI, dates des coupes et d'irrigation) sur le rendement prédict a été étudié séparément pour pouvoir évaluer l'effet de chaque paramètre intégré.

3.1 Le modèle PILOTE

La version Foin de Crau (Mailhol and Merot, 2008) du modèle de culture PILOTE (Mailhol et al., 1997, 2011) a été utilisée dans cette étude, adaptée pour rentrer dans le cadre de la nouvelle procédure autoPILOTE (Cheviron et al., 2015, soumis). Cette nouvelle procédure utilisée dans le cadre de cette thèse permet d'intégrer dans PILOTE des paramètres issus des données *in situ* ou spatiales, le tout sans modifier les paramétrages initiaux de PILOTE (Annexe 1). Le modèle fonctionne avec quatre forçages climatiques au pas de temps journalier (pluie ou/et irrigation, température, évapotranspiration potentielle, rayonnement global), qui est aussi le pas de temps auquel les variables calculées par le modèle sont disponibles, par exemple la réserve en eau et le drainage, l'évaporation du sol, la transpiration de la plante, l'indice foliaire et la matière sèche totale.

PILOTE est un "vrai" modèle de culture, au sens où la boucle de fonctionnement du modèle comporte de véritables interactions entre l'évolution de la réserve en eau du sol et la croissance de la plante (*Figure 10*). L'état de la réserve en eau (i.e. le remplissage des réservoirs superficiel R1, médian R2 et profond R3) est actualisé en fonction des précipitations ou/et irrigations, selon les valeurs des paramètres liés à la plante et au sol (par exemple, la capacité au champ f_{ci} et la profondeur z_i de chaque réservoir, ainsi que la profondeur d'enracinement de la plante, contrôlée par la profondeur maximale P_{max} des racines).

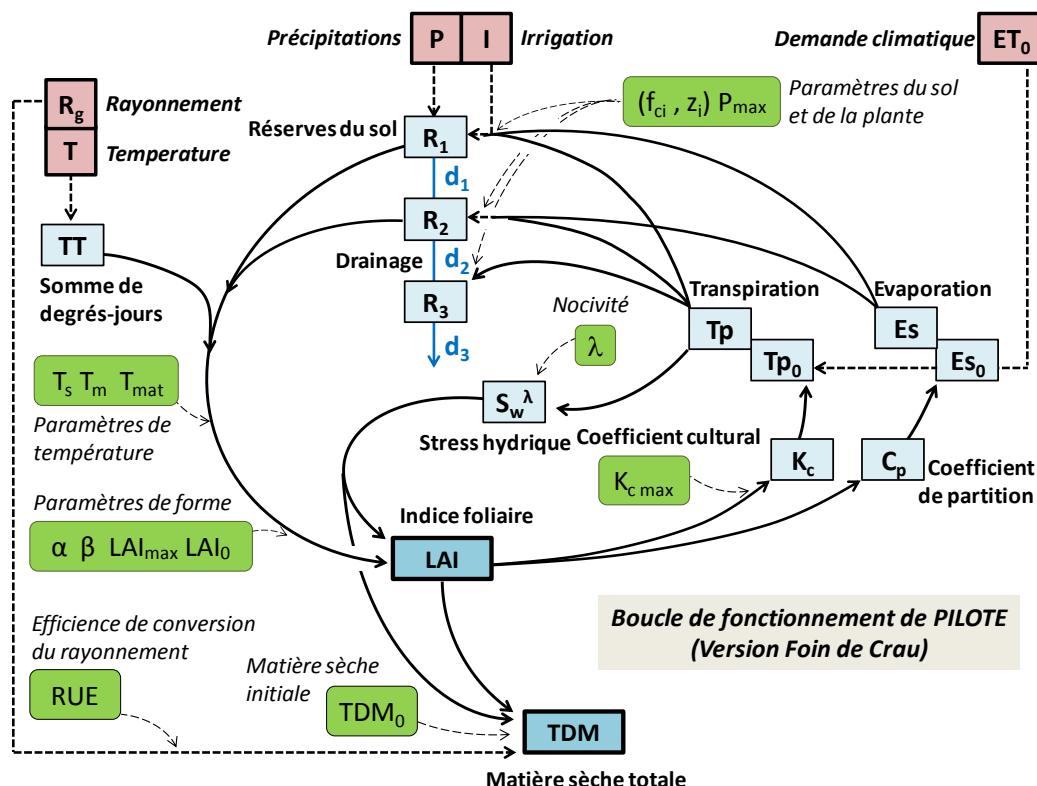


Figure 10. Boucle de fonctionnement de PILOTE. Voir le texte pour la signification des paramètres et des variables du modèle

La dynamique de croissance des plantes (indice foliaire LAI) est contrôlée conjointement par:

- l'accumulation de degrés-jours (TT indique la somme des températures moyennes journalières T depuis le démarrage du cycle),
- les paramètres de forme (α pour la phase de croissance, β pour la phase de sénescence)

- la valeur initiale du LAI (LAI_0 , LAI_{min}) et sa valeur maximale possible (LAI_{max})
- l'occurrence d'un stress hydrique

Le développement racinaire est calculé en cohérence avec celui du LAI, son moteur principal étant l'accumulation de degrés-jours. L'estimation de l'évaporation du sol (Es) et celle de la transpiration de la plante (Tp) se font en fonction de la demande climatique (évapotranspiration de référence ET_0). Ceci referme la boucle de calcul: l'absorption d'eau par les racines et les pertes par évaporation (ou drainage) sont les dernières étapes de l'actualisation de la réserve au cours d'un seul et même pas de temps journalier. La production de matière sèche (TDM) est calculée à partir du LAI et du rayonnement global (Rg), le paramètre clef de ce processus étant l'efficience de conversion du rayonnement (RUE), le stress hydrique ayant aussi un effet néfaste sur le rendement.

3.2 Intégration des valeurs LAI optique

Pour les prairies étudiées, le modèle PILOTE prédit le TDM pour trois cycles de croissance végétale. Ce modèle nécessite une valeur initiale de LAI (LAI_0) pour l'initialisation. Cette valeur représente le LAI à une date donnée à partir de laquelle un utilisateur décide de démarrer les prédictions PILOTE dans le premier cycle. Dans cette étude les prédictions ont démarré au jour julien 54, étant donné que la première mesure terrain de LAI a été réalisée à ce jour. De plus, nous disposons des estimations des valeurs de LAI à partir d'une image optique acquise ce même jour. Des valeurs (minimale et maximale) du LAI sont également nécessaires pour paramétriser PILOTE. Le LAI minimal (LAI_{min}) est utilisé par le modèle comme une valeur de départ (initiale) pour les deuxièmes et troisièmes cycles. Le LAI maximal (LAI_{max}) est un facteur d'échelle qui contrôle la prédition de LAI dans les trois cycles. Théoriquement, pour améliorer la précision sur les valeurs de TDM prédictes, le modèle PILOTE offre la possibilité de remplacer les valeurs de LAI prédictes par celles mesurées *in situ* ou dérivées à partir des données optiques. LAI_0 , LAI_{min} et LAI_{max} sont indispensables pour faire tourner PILOTE, en revanche remplacer les valeurs de LAI prédictes par PILOTE par des valeurs de LAI observées *in situ* ou dérivées des images optiques est optionnel.

Deux scénarios ont été définis pour analyser l'effet de l'intégration des valeurs de LAI optique dans PILOTE sur la prédition de TDM. Le premier scénario utilise des valeurs de LAI optique pour saisir dans le modèle seulement LAI_0 , LAI_{min} et LAI_{max} . Le deuxième scénario utilise en plus des entrées du scénario 1 les valeurs de LAI dérivées des données optiques avec un pas du temps journalier.

- Scenario 1 : pour chaque parcelle, nous avons considéré $LAI_0 = LAI$ optique au jour de l'année 54, $LAI_{min} = LAI$ minimal de toutes les valeurs de LAI optique, $LAI_{max} = LAI$ maximal de toutes les valeurs de LAI optique.
- Scenario 2 : en plus de choisir LAI_0 , LAI_{min} , et LAI_{max} comme dans le scenario 1, les valeurs de LAI prédites par PILOTE à un pas de temps journalier ont été remplacées par les valeurs de LAI optique interpolées au même pas de temps.

Pour chaque scénario, les valeurs de TDM prédites ont été comparées aux valeurs de TDM mesurées *in situ* pour analyser l'impact de l'intégration des valeurs de LAI issues des données optiques sur la prédiction de TDM. Cet impact est mesuré par l'intermédiaire des trois indices statistiques RMSE, MAPE et biais.

3.3 Effet de l'incertitude sur les dates des coupes

Les données optiques permettent de détecter les dates de coupes. Sur notre site d'étude, nous avons démontré que les coupes sont détectables en utilisant des images optiques avec une répétitivité temporelle de 16 jours ou moins (LANDSAT-8, Sentinel-2). En effet, sur notre site d'étude le NDVI des parcelles coupées a besoin de plus de 16 jours (entre 18 et 23 jours) après la coupe pour atteindre une valeur proche du NDVI d'une parcelle mature (environ 0.7).

En utilisant des données optiques, il est impossible de détecter la date exacte de la coupe dans une parcelle donnée. Seule la déduction qu'une coupe a eu lieu dans les N derniers jours est possible, N étant la répétitivité temporelle des images. La précision sur la date de coupe estimée à partir des images optiques dépend donc de la répétitivité temporelle des images optiques utilisées.

Pour analyser l'impact sur les valeurs de TDM prédites en alimentant PILOTE avec des dates de coupes estimées à partir d'images optiques, un bruit aléatoire a été rajouté aux véritables dates de coupes. Pour une position donnée (DOY) de l'image optique dans un intervalle de 16 jours après la vraie date de coupe, ce bruit est un entier (en jours) dans l'intervalle [N, M], où $M = \text{date d'image} - \text{vraie date de coupe}$, et $N = M - \text{répétitivité temporelle}$. Trois niveaux de bruit, correspondant à la répétitivité temporelle des capteurs optiques actuels ou à venir, ont été considérés.

- Configuration 1 : Cas de la constellation Sentinel-2 (2A et 2B), avec un temps de revisite de 5 jours. Pour une position donnée (DOY) de l'image optique dans un intervalle de 16 jours après la vraie date de coupe, date de coupe = vraie date de coupe + erreur sur la date de coupe (1000 entiers aléatoirement tirés entre [N, M], avec une densité de probabilité uniforme).
- Configuration 2 : Cas où Sentinel-2A est utilisé seul, avec un temps de revisite de 10 jours. Pour une position donnée (DOY) de l'image optique dans un intervalle de 16 jours après la vraie date de coupe, date de coupe = vraie date de coupe + erreur sur la date de coupe (1000 entiers aléatoirement tirés entre [N, M], avec une densité de probabilité uniforme).
- Configuration 3 : Cas où LANDSAT-8 est utilisé seul, avec un temps de revisite de 16 jours. Pour une position donnée (DOY) de l'image optique dans un intervalle de 16 jours après la vraie date de coupe, date de coupe = vraie date de coupe + erreur sur la date de coupe (1000 entiers aléatoirement tirés entre [N, M], avec une densité de probabilité uniforme).

Pour chaque configuration, les 1000 valeurs de TDM prédites ont été comparées aux valeurs de TDM de référence prédites en utilisant les vraies dates de coupes. Les indices statistiques biais, RMSE, et MAPE ont été utilisés pour évaluer l'impact de l'utilisation des dates de coupes estimées à partir des données optiques sur l'estimation de la TDM.

3.4 Effet de l'incertitude sur les dates d'irrigation

Nous avons montré que les données radar permettent de détecter les pratiques d'irrigations seulement si l'image est acquise à moins que trois jours après l'irrigation. En effet, les résultats ont montré que pendant l'irrigation le signal radar atteint un niveau maximum (double réflexion qui résulte de la présence de l'eau à l'état libre et de la végétation en position verticale), puis diminue dans les trois prochains jours avec la diminution de l'humidité du sol.

Actuellement, combiner les capteurs SAR (Synthetic Aperture Radar) disponibles, tels que TerraSAR-X (TSX), COSMO-SkyMed (CSK), et SENTINEL-1A, permet d'acquérir au moins une image par jour sur une zone donnée. Ainsi, il est supposé dans cette étude qu'acquérir deux images SAR par semaine est suffisant pour détecter toutes les irrigations. La

non-détection d'irrigations dans un cycle donné pourrait affecter les valeurs de TDM prédictes dans le cycle en cours et celui qui suivra.

En premier temps, nous avons supposé que toutes les dates d'irrigation sont détectées à partir d'images SAR. Pour pouvoir analyser l'impact de l'utilisation des dates d'irrigation estimées à partir des données SAR sur la prédiction des valeurs de TDM, toutes les vraies dates d'irrigations ont été bruitées aléatoirement (1000 tirages). Pour une position donnée (DOY) de l'image radar dans un intervalle de 3 jours après la vraie date d'irrigation, ce bruit est un entier (en jours) dans l'intervalle $[N, M]$, où $M = \text{date d'image} - \text{vraie date d'irrigation}$, et $N = M - 3$ jours. Enfin, les 1000 valeurs TDM ont été comparées aux valeurs de TDM de référence obtenues en utilisant toutes les vraies dates d'irrigation.

Pour évaluer l'effet de la non-détection d'irrigations sur les valeurs de TDM prédictes, certaines irrigations ont été délibérément ignorées. D'abord, les valeurs de TDM ont été prédictes lorsque (a) une irrigation est non-détectée dans le premier cycle, (b) une irrigation est non-détectée dans le deuxième cycle, (c) une irrigation non-détectée dans le troisième cycle. La même procédure est ensuite répétée, cette fois les valeurs de TDM ont été prédictes lorsque deux irrigations sont non-détectées dans (a) le premier, (b) le deuxième et (c) le troisième cycle.

4. Résultats et discussion

4.1 Intégration des valeurs de LAI optique

Les résultats ont montré que l'utilisation des valeurs de LAI dérivées des données optiques pour alimenter le modèle PILOTE permet d'estimer le TDM avec une précision de l'ordre de 0.44 t/ha (RMSE, ce qui correspond à MAPE~23%) pour des TDM mesurés entre 0.15 et 5.01 t/ha (*Table 1, et Figure 3*, article 3). Des résultats similaires sur la prédiction de TDM ont été obtenus en intégrant les valeurs de LAI mesurées *in situ* (RMSE = 0.49 t/ha, et MAPE= 25%). De plus, les résultats ont également montré que l'utilisation des valeurs de LAI optique avec un pas de temps journalier (scénario 2) n'apporte pas d'amélioration sur la prédiction de TDM. Ceci est principalement du au fait que les valeurs de LAI prédictes par PILOTE dans le premier scénario sont bien corrélées avec les valeurs de LAI optique (coefficient de détermination ~ 0.8) (*Figure 4*, article 3).

4.2 Effet de l'incertitude sur les dates des coupes

Les valeurs de TDM prédictes en bruitant les dates des coupes ont été comparées aux valeurs de TDM de référence (*Table 2, Figures 5 et 6*, article 3). Les résultats ont montré que quel

que soit le niveau de bruit (5, 10, et 16 jours) l'erreur sur les TDM prédites en bruitant les dates des coupes n'est pas significative ($\text{RMSE} < 0.44 \text{ t/ha}$ et $\text{MAPE} < 11\%$).

Ces résultats montrent que les données optiques avec une résolution temporelle de moins de 16 jours sont adéquates pour alimenter le modèle.

4.3 Effet de l'incertitude sur les dates d'irrigation

Les valeurs de TDM prédites en bruitant toutes les dates d'irrigation observées ont été comparées aux valeurs de TDM de référence (*Table 3, Figure 7*, article 3). Les résultats ont montré une erreur non significative sur les TDM prédites ($\text{RMSE} = 0.17 \text{ t/ha}$ et $\text{MAPE} = 4.2\%$). En conclusion, les dates d'irrigation dérivées des données radar avec une incertitude maximale de 3 jours sont appropriées pour alimenter le modèle PILOTE sans provoquer des erreurs importantes sur la prédition des valeurs de TDM.

De plus, les résultats ont montré que la non-détection d'une ou de deux irrigations pendant une période de l'année marquée par des précipitations importantes n'affecte pas la prédition de TDM dans le cycle en cours et celui suivant (*Figure 8*, article 3). Cependant, la non-détection d'une ou de deux irrigations dans une période de l'année sans précipitation provoque une prédition des TDM inférieure par rapport aux TDM de référence (*Figures 9 et 10*, article 3). Dans notre cas, une sous-estimation maximale de TDM d'environ 1.3 t/ha (TDM de référence ~3.43 t/ha) a été observée dans le deuxième cycle lorsque l'on ignore deux irrigations sur quatre dans ce même cycle (*Figure 9b*, article 3).

5. Conclusion

Le but de cette partie de la thèse était d'évaluer l'effet dans les modèles de culture de l'intégration des variables issues de la télédétection sur la prédition du rendement. Trois variables ont été discutées: l'indice foliaire (LAI), les dates des coupes et celles des irrigations. Ces paramètres ont été choisis car ils sont utilisés comme des données d'entrées dans la plupart des modèles de culture.

Les résultats ont montré le potentiel des données spatiales à alimenter les modèles de culture (tel que PILOTE), avec des variables décrivant l'état de développement de la végétation (LAI), et des variables décrivant des décisions des agriculteurs (dates de récolte, dates d'irrigation).

Un article détaillant la méthode et les résultats résumés ci-dessus a été soumis dans le journal international « *Agricultural Water Management* » :

El Hajj, M., Baghdadi, N., Cheviron, B., Belaud, G., Zribi, M. Integration of remote sensing derived parameters in crop models: application to the PILOTE model for hay production.
Submitted to Agricultural Water Management

Article 3

Integration of remote sensing derived parameters in crop models: application to the PILOTE model for hay production

1. Introduction	136
2. Materials and methods	140
2.1 Study area	140
2.2 In situ measurements	141
2.3 Spatial data	141
2.4 The PILOTE crop model	142
2.5 Method	142
2.5.1 Integration of optical LAI values	142
2.5.2 Effect of uncertainty on harvest dates	143
2.5.3 Effect of uncertainty on irrigation dates	146
3. Results and discussion	147
3.1 Integration of optical LAI values	147
3.2 Effect of uncertainty on harvest dates	151
3.3 Effect of uncertainty on the irrigation dates	154
3.3.1 All irrigation events are detected with an uncertainty on irrigation dates	154
3.3.2 Case in which some irrigation events are not detected from SAR images	156
3.3.2.1 Ignoring irrigations in the first cycle	156
3.3.2.2 Ignoring irrigations in the second cycle	158
A. Effect on predicted TDM in the second cycle	158
B. Effect on predicted TDM in the third cycle	161
3.3.2.3 Ignoring irrigations in the third cycle	161
4. Conclusion	162

Integration of remote sensing derived parameters in crop models: application to the PILOTE model for hay production

Mohammad El Hajj^{1,*}, Nicolas Baghdadi¹, Bruno Cheviron², Gilles Belaud³, and Mehrez Zribi⁴

(Version auteur de l'article soumis dans Agriculture Water Management)

¹ IRSTEA, UMR TETIS, 500 rue François Breton, 34093 Montpellier cedex 5, France;
E-Mail: (mohammad.el-hajj@teledetection.fr) ;(nicolas.baghdadi@teledetection.fr)

² IRSTEA, UMR G-EAU, 361 rue François Breton, 34196 Montpellier cedex 5, France;
E-Mail: (bruno.cheviron@irstea.fr)

³ SupAgro, UMR G-EAU, 2 place Pierre Viala, 34060 Montpellier, France;
E-Mails: (belaud@supagro.inra.fr); (Francois.Charron@supagro.inra.fr)

⁴ CNRS, CESBIO, 18 av. Edouard Belin, bpi 2801, 31401 Toulouse cedex 9, France;
E-Mails: (mehrez.zribi@ird.fr); (olivier.hagolle@cnes.fr)

Abstract: The aim of this study is to assess the effects and interests of integrating remote-sensing-derived variables (initial and maximal Leaf Area Index "LAI" values and harvest and irrigation dates) in a crop model (PILOTE) that is intended to simulate vegetation growth for hay crops. The target variable is the prediction of biomass production (Total Dry Matter, TDM) for each of the three crop growth cycles.

Two scenarios are employed to process the available remote sensing "observations" of the LAI values. In the first scenario, the model is run with initial and maximal LAI values that were obtained from optical images, which forces a specific initial LAI value at the beginning of each crop growth cycle but employs a single overall maximal LAI value for all cycles (required as a scaling factor that binds model predictions). The second scenario also forces daily interpolated optical LAI values in the model. The effect on the model predictions is discussed based on the values of the statistical indexes (bias, Root Mean Square Error: RMSE and Mean Absolute Percentage Error: MAPE). In both scenarios, the TDM predictions that were obtained with forced LAI values exhibit low deviations compared with the TDM that was measured onsite (RMSE of 0.43 t/ha, MAPE of 23% and in situ TDM values between 0.15 and 5.00 t/ha).

The interest and feasibility of using harvest dates that are derived from optical data is examined by feeding the model with randomly perturbed harvest dates. The magnitude of the perturbations matches the revisit times of SENTINEL-2A and -2B combined (5 days), SENTINEL-2A alone (10 days) and LANDSAT-8 (16 days). For each perturbation magnitude, the previous statistical indexes are employed to evaluate the deviations between the predicted TDM values and the reference TDM values that were predicted using the true harvest dates. The results showed that revisit times of up to 16 days produce acceptable errors for the predicted TDM values, with a RMSE and MAPE less than 0.42 t/ha and 15%, respectively.

The possibility of using irrigation dates that are derived from Synthetic Aperture Radar (SAR) images is also investigated, first by replacing all true irrigation dates by randomly perturbed dates (using 3-day perturbation magnitudes) and hypothesizing that one or several irrigations are "missed", i.e., undetected. The results show negligible errors for the TDM predictions when noisy irrigation dates are utilized instead of the true dates (RMSE of 0.17 t/ha and MAPE of 4.2%). Disregarding one or two irrigations within a period with important rainfalls does not induce significant errors for the predicted TDM values; however, it causes noticeable underestimations in drier periods (maximum of 1.55 t/ha).

This study enables the identification of a series of conditions by which the parameters that are derived from optical and SAR images are suitable to feed the PILOTE model without endangering the reliability of its predictions.

1. Introduction

Pre-harvest yield forecasting is a critical challenge for producers, especially for large agricultural areas. Together with occasional, frequent or real-time monitoring of soil and plant statuses, crop models are useful tools for such estimates, providing for example biomass or dry matter assessments for known or adjustable harvest dates. During previous decades, numerous crop models were developed to predict crop growth and yield, most often for wheat or maize (Brissone et al., 1992; Ritchie and Otter, 1985; Weir et al., 1984), and also for grasslands (Mailhol and Merot, 2008). A crop model is a set of equations that describes the growth of plant components, such as leaves, roots, stems and fruits, typically for a daily time step (Oteng-Darko et al., 2013). Crop models require several input variables that describe soil properties (e.g., field capacity and depths of soil horizons), plant characteristics (e.g., maximal rooting depth and thermal times associated with growth stages) and management options (e.g., sowing dates, irrigation doses and dates, and harvest dates), which are referred to as the soil, plant and management families of the parameters. Climatic forcings are also required (e.g., rain, radiation, air temperature, and climatic demand). These inputs are usually

obtained from previous evaluations or recorded from in situ sensors that are located at fixed locations in the cultivated areas, at the expected drawbacks of "one-shot spot-checks", i.e., measurements that are neither extendable in time nor extendable in space. These measurements are relevant for climatic forcings because provided climatic data does not significantly vary within an area of interest. Conversely, soil and vegetation parameters or state variables (water content, leaf area index, and total dry matter) frequently present larger spatial heterogeneities due to site history, environmental characteristics, and irrigation practices.

Remote sensing technology has been extensively applied to provide spatially distributed values of some of the accessible parameter in the soil, plant and management families and to retrieve information about previous and current climatic data. In particular, the SAR (Synthetic Aperture Radar) data were extensively applied to estimate the soil moisture in the top 5 cm of bare and vegetated soils (depending on the soil moisture value and the radar wavelength) on local plot and subplot scales. The estimation of soil moisture over bare soils was performed with an accuracy between 3 and 6 Vol.% (Aubert et al., 2011; Baghdadi et al., 2012a; Santi et al., 2013b; Srivastava et al., 2009; Zribi et al., 2005). Over vegetated agricultural areas (wheat, peas, lentil, fallow, grassland and canola) soil moisture on a local scale was estimated from SAR data with an accuracy between 2 and 8 Vol.%, depending on the vegetation conditions and the SAR configurations (De Roo et al., 2001; El Hajj et al., 2014; Gherboudj et al., 2011; He et al., 2014; Paloscia et al., 2013; Prévot et al., 1993; Soon-Koo Kweon et al., 2012; Zribi et al., 2011). Moreover, other satellites, such as Soil Moisture and Ocean Salinity (SMOS), provide soil moisture estimates on a regional scale with a temporal revisit time of 3 days. The spatial resolution of SMOS is 50 km at the swath edges (Kerr et al., 2001). Bitar et al., (2012) and Jackson *et al.* (2012) performed the validation of SMOS soil moisture estimates using in situ soil moisture measurements at a depth of 5 cm. The results showed that SMOS satellites provide soil moisture estimates with an accuracy of approximately 5 Vol.%.

On the other hand, optical remote sensing data from LANDSAT-8 and SPOT-6 showed significant potential for estimating the Leaf Area Index (LAI) of crop canopies (corn, grassland, maize, wheat, rapeseed and sunflower) with relative uncertainties between 10% and 30% (Bsaibes et al., 2009; Claverie et al., 2013; Courault et al., 2008; Duveiller et al., 2011; North, 2002). The LAI is a remotely sensed derived variable that was extensively incorporated into crop models to enhance yield estimations; it provides promising yield estimates (e.g., Barnes et al., 1997; Bogh et al., 2004; Doraiswamy et al., 2005; Guerif and Duke, 2000).

Uncertainty in crop model predictions is related to the uncertainty that affects their site parameters or management options (e.g., sowing density, harvest dates, and irrigation dates) and the model equations that simplify the physical processes of soil (evaporation), plant (stem elongation, root growth, and LAI) and soil-plant interaction (i.e., water stress). To overcome these uncertainties, many studies have incorporated information that is derived from remote sensing data (Bach, 1998; Bouman, 1995; Choudhury, 1997; Claverie et al., 2013; Courault et al., 2010; Di Bella et al., 2005; Duchemin et al., 2006, 2008; Fieuza et al., 2011; Hadria et al., 2009; Maas, 1988). The majority of these studies incorporate LAI values that are derived from optical data into crop models using forcing or simulation steering functions (Bouman et al., 1997). The use of forcing functions consists of replacing the simulated variable by the same remotely sensed variable using different techniques, such as the Kalman filter, the ensemble Kalman filter, or genetic algorithms. Simulation steering functions represent an alternative that consists of re-estimating some of the parameters by coupling the crop and radiative transfer models via some of the crop model outputs (e.g., soil moisture, LAI) (Ines et al., 2013). In simulation steering functions, crop model outputs are used as inputs for a radiative transfer model to estimate remote sensing observations.

Thorp *et al.* (2010) showed that assimilating (using both forcing and updating mechanisms) remotely sensed LAI values into the DSSAT-CSM-Wheat crop model did not enhance the maize yield estimates because the yield predictions were influenced by parameters that were more sensitive than the parameters that governed the LAI predictions. The same conclusion was obtained by Courault *et al.* (2010) in a study that was conducted over grasslands with the STICS model, using daily interpolated remote sensing LAI values for assimilation into STICS via a forcing mechanism. Ines et al. (2013) also assimilated (using the Ensemble Kalman filter) remotely sensed soil moisture and MODIS LAI products into the DSSAT-CSM-Maize crop model to improve maize yield estimation (mean in situ yield is 11.12 t/ha with a standard deviation of 0.70 t/ha). The results showed that the independent assimilation of soil moisture and LAI values decreased the RMSE of the yield estimates by 0.5 t/ha (RMSE decreased from 4.7 to 4.2 t/ha) and 1.1 t/ha (RMSE decreased from 4.7 to 3.6 t/ha), respectively. However, the simultaneous assimilation of both soil moisture and LAI decreased the RMSE from 4.7 to 2.9 t/ha. Vazifedoust et al. (2009) showed that assimilating the (remotely sensed) LAI and relative evapotranspiration into the SWAP-WOFOST crop model (using the Kalman filter) significantly reduced the error for the estimated wheat yield (relative error for predicted total dry matter compared with the measured in situ total dry matter is approximately 10%).

Several studies couple remote sensing data and crop models within simulation steering approaches (Launay and Guerif, 2005; Ma et al., 2013; Prévot et al., 2003). Launay and Guerif (2005) assimilated optical remote sensing observations to re-estimate the parameters of

the SUCROS model that were expected to have spatially distributed values. In this study, the SUCROS crop model was coupled with the SAIL radiative transfer model using the LAI to simulate optical reflectance and the Transformed Soil Adjusted Vegetation Index (TSAVI) using this reflectance. The difference between the simulated TSAVI by SUCROS coupled with SAIL and the computed TSAVI from the optical data was minimized to re-estimate the associated parameters. The RMSE for the sugar beet yield estimates was decreased from 13.0 to 9.7 kg/ha (in situ yield between 40 and 100 kg/ha). A similar approach for assimilating remote sensing data was applied by Prévot et al. (2003) using the STICS coupled with a radiative transfer model, which shows significant improvement of the estimated LAI values for wheat (RMSE from 0.63 to 0.16 m²/m²), whereas only slight improvements were observed for the yield (RMSE from 1.9 to 1.6 t/ha) (in situ yield between 1 and 15 t/ha). Ma et al. (2013) assimilated the MODIS-LAI product into the WOFOST model to reduce the RMSE on the estimated winter wheat yield from 0.98 to 0.47 t/ha (in situ yield between 5 and 6 t/ha).

The main goal of this study is to assess the effect of integrating remote-sensing-derived variables into crop models for TDM prediction. The remote sensing data that was employed in this study were acquired with high spatial resolution and high revisit times over grassland areas. This grassland area is harvested three times a year (three growth cycles). The grassland growth cycle length is short (between 50 and 70 days) compared with the growth cycle length of other crops, such as wheat, maize, and sugar beets. The model version of PILOTE that handles hay production (Mailhol and Merot, 2008), which resorts to the recently constructed auto-PILOTE procedure for scenario generation and analysis, was employed (Cheviron et al., 2015 submitted).

Three site and management parameter were targeted: The initial LAI values (after harvest or at the beginning of the simulation), the harvest dates and the irrigation dates. All could easily be estimated from optical (LAI, harvest) or radar (irrigation) images. First, optical LAIs were integrated in the crop model using two configurations: (1) initial LAI values ("LAI0": LAI for the day of the year on which the simulation commenced), the minimum LAI value (LAI_{min}), and the maximal optical LAI value (LAI_{max}) and (2) in addition to LAI0, LAI_{min} and LAI_{max}, which were fixed from the optical images, the LAI values predicted by PILOTE at daily time intervals were replaced by LAI values that were estimated from the optical images at the same interval time. Second, the integration of the harvest dates that were estimated from current and near-future optical images for feeding the crop models was also analyzed. Last, the use of irrigation date estimates using radar images to feed crop models was investigated. Section 2 of this paper presents the study area, the spatial data, the ground-truth measurements, the PILOTE model, and the methodology. The results are discussed in section 3. Section 4 presents the main conclusions.

2. Materials and methods

2.1 Study area

The study area (called “Domaine du Merle”) is an experimental farm located in southeast France (centered at 43.64° N, 5.00° E). The total area of the farm is 400 ha with 150 ha of irrigated grassland plots (50 plots) (Figure 1). The climate is Mediterranean with a rainy season between September and November. Over the study area, the average cumulative rainfall reached 457.5 mm in 2013 and varied between 350 and 800 mm over the past 20 years (Courault et al., 2010). The mean air temperature is approximately 8 and 24°C during winter and summer, respectively (Courault et al., 2010).

The topsoil texture of the irrigated plots is stony loam (15% to 20% pebbles) with depths that vary from 30 to 80 cm, depending on the plot age (between 10 years and 3 centuries) (Mérot, 2007). The soil has a moderate retention capacity with a highest density of vegetation roots in the upper 30 cm (Merot et al., 2008b).

Plots were leveled with a very gentle slope to enable irrigation by gravity (border irrigation). Irrigation is applied by means of canals, which brings water to the highest extremities of the plots. Each plot is irrigated every 10 days on average from April to September. Plots are harvested three times per year: in May, July, and September.

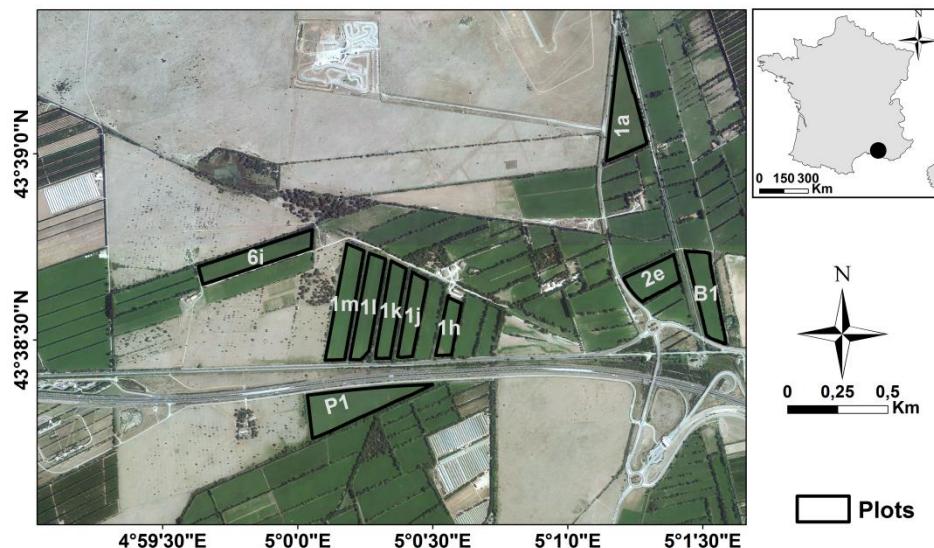


Figure 1. Location of the study site (Domaine du Merle). Black polygons delineate training irrigated grassland plots, where ground measurements were collected.

2.2 In situ measurements

In situ campaigns were conducted February and October 2013 to collect ground-truth measurements of Total Dry Matter (TDM) and Leaf Area Index (LAI) in ten training plots. The areas of the training plots varied between 2.13 and 7.23 ha. For the TDM, two vegetation samples were first clipped, using shears, over 50 cm x 50 cm squares, in each of the ten training plots. The vegetation samples were subsequently dried at a temperature of 70°C and weighed to measure the TDM. Moreover, twenty to thirty hemispherical images were acquired at nadir for each plot by means of a fish eye lens. These photos were processed using the CanEye software (<http://www6.paca.inra.fr/can-eye>) to estimate the in situ LAI values.

2.3 Spatial data

Thirty optical images were acquired by the SPOT-4/5 and LANDSAT-7/8 satellites over the study site. The optical images were calibrated, corrected for atmospheric effects and ortho-rectified. The calibration of SPOT-4 images was performed by the CESBIO (Centre d'Etudes Spatiales de la BIOsphère) in the framework of the Take 5 experiment (<http://www.cesbio.ups-tlse.fr/>). SPOT-4 images were corrected for atmospheric effects according to the method described in the study by Hagolle et al. (2008). For SPOT-5 and LANDSAT-8 images, the Simplified Method of Atmospheric Correction model (SMAC) (Rahman and Dedieu, 1994) was employed to correct for atmospheric effects. The input variables to the SMAC (aerosol optical thickness of 550 nm and water vapor contents of g/m²) were obtained from the AERONET (AErosol Robotic NETwork) website. LANDSAT-7 images that were previously corrected for atmospheric effects were directly downloaded from the NASA website. SPOT-5 images were ortho-rectified using ERDAS imagine software, whereas the LANDSAT-7/8 images were previously ortho-rectified.

The LAIs of the studied grassland were derived from the calibrated optical images (SPOT-4/5, LANDSAT-7/8) using the Biophysical Variables Neural NETwork (BV-NNET) tool that was developed based on algorithms proposed by Baret et al. (2007) and optimized via the SIRRIMED project (<http://www.sirrimed.org/index.php>). A comparison between the LAIs derived from BV-NNET (using optical images) and the LAIs derived from hemispherical photos was performed. The results showed unbiased estimations of LAI with a Root Mean Square Error (RMSE) of 0.66 m²/m² and a Relative Root Mean Square Error (RRMSE) of 29%.

2.4 The PILOTE crop model

The Crau hay version (Mailhol and Merot, 2008) of the PILOTE crop model has been utilized and adapted for this study to fit with the new auto PILOTE procedure (Cheviron et al., 2015), which enables the generation and analysis of multiple scenarios in procedures that are intended for constrained optimization. The model requires four climatic forcings (rain and/or irrigation, temperature, potential evapotranspiration, and total incoming radiation) at a daily time step, which is also the requirement for the predictions it delivers: water reserve and drainage, soil evaporation, plant transpiration, leaf area index (LAI) and total dry matter (TDM) are some of the daily updated calculated variables. PILOTE is a true crop model because a reciprocal control loop exists between the evolution of the water reserve in soils and crop growth. The status of the water reserve (i.e., filling of the superficial, root zone and deep reservoirs) is updated from rain and/or irrigation events using the values of a series of soil variables (e.g., field capacity and depths of the previously mentioned reservoirs). The dynamics of plant growth are controlled by the accumulation of degrees-days (a sum of mean daily air temperature), the values of several shape parameters (that dictate the shape of the LAI curve with increasing degrees-days) and the occurrence of water stresses (especially harmful for this crop). Root development is calculated in coherence with the increase of LAI, which allows the estimation of soil evaporation and plant transpiration from the climatic demand (potential evapotranspiration). This closes PILOTE's calculation loop: root water uptake and water losses by evaporation (or drainage) provide the last update to the water reserve terms, at the end of the calculation step, within a single day. The production of TDM is calculated from the LAI values and the incoming radiation, the key parameter being the radiation use efficiency, and water stresses also have a negative impact on the process. An additional feature of the latest (unpublished yet) version of the model is the possibility to "overrule" predicted leaf area index values by independent leaf area values, obtained from field campaigns or remote sensing.

2.5 Method

This section describes the methodology used to assess the effects associated with the integration of three remote sensing derived variables (several LAI values, harvest dates and irrigation dates) on the accuracy of TDM predictions by the PILOTE model.

2.5.1 Integration of optical LAI values

The PILOTE model predicts the TDM for three grassland growth cycles. PILOTE requires the LAI initial value (LAI_0) as an input parameter, which represents the LAI value for the given DOY (Day Of Year) from which the prediction of the first growth cycle starts. The initial

TDM value (TDM_0) is also required. The daily increments in the TDM values are calculated from the daily values of the LAI. In this study, the prediction starts at DOY=54 (year 2013), which corresponds to the first in situ measurements of LAI and TDM, and to the date of the first optical image. The minimum and maximum LAI values are also required as input parameters to run PILOTE: LAI_{\min} serves as the initial value for the second and third cycles, whereas LAI_{\max} is a scaling factor that binds the prediction of LAI. These two values were fixed from the optical images acquired within the DOY of the PILOTE prediction in 2013 and 2014.

The LAI predicted by PILOTE is an intermediate output used by the model in the procedure leading to the estimation of the TDM. To enhance the TDM predictions, PILOTE offers the possibility to replace the predicted LAI values by those measured in situ or estimated from optical images (as in the most of crop growth model). The predicted LAI values may be replaced at any selected time interval: daily, weekly or any user-defined dates. LAI_0 , LAI_{\min} , and LAI_{\max} are indispensable to running PILOTE, whereas the replacement of the predicted LAI values by in situ or optical LAI values is optional.

The effect of integrating optical LAI-values in TDM estimates was assessed by comparing the TDM predictions that were obtained with the optical LAI values with the in situ TDM measurements. Two configurations are tested:

- Configuration 1: for each plot, using LAI values estimated from all available optical images, we consider $\text{LAI}_0 = \text{optical LAI at DOY}= 54$, $\text{LAI}_{\min} = \text{minimum of all optical LAI values}$, and $\text{LAI}_{\max} = \text{maximum of all optical LAI values}$.
- Configuration 2: in addition to selecting the variables LAI_0 , LAI_{\min} and LAI_{\max} as for configuration 1, the daily LAI values predicted by PILOTE will be replaced by interpolated optical LAI values at the same daily time step.

For each configuration, a comparison between the predicted values and the in situ TDM values is performed. The statistical indexes of bias (estimated TDM – in situ TDM), RMSE (Root Mean Square Error), and MAPE (Mean Absolute Percentage Error) will be analyzed in order to evaluate the interest of incorporating optical LAI data in the course of the predictions made by the PILOTE crop model.

2.5.2 Effect of uncertainty on harvest dates

PILOTE predicts the TDM for three grassland growth cycles. Each growth cycle is completed at the associated harvest date, which is an input parameter of PILOTE. This parameter is employed by PILOTE to stop the TDM prediction for the current vegetation cycle and begin the prediction for the next cycle, which also involves reinitializing the predicted LAI value to

its starting LAI_{min} value. Harvest dates are generally obtained from in situ records that are established by a farmer.

Several studies have shown the potential of optical and SAR data for monitoring crop harvest dates (Baghdadi et al., 2009; Courault et al., 2010; Hajj et al., 2009; Lebourgeois et al., 2010). However, the detection of harvest dates can fail if the optical and radar images are acquired well after the sought harvest dates. To detect the harvest date using optical images, the images should be acquired immediately after the harvest date. Otherwise, this detection becomes very complicated because vegetation growth adversely affects the NDVI index, which is extensively applied used for harvest monitoring. The NDVI values rapidly increase to the NDVI values for the mature plots ("saturation" of the index). A temporal NDVI series that is computed from SPOT-4/5 and LANDSAT-7/8 (2013 and 2014) was employed to assess the required revisit time for harvest detection in the study irrigated grassland area. The analysis shows that a few days after harvest, the NDVI of harvest plots is approximately 0.4 (regardless of the crop growth cycle), whereas the NDVI of mature plots ranges between 0.8 and 0.85 (higher values are observed for the third cycle) (Figure 2). To detect the harvest, a current optical image must be acquired when the NDVI of recently harvested plots does not exceed a threshold well below 0.8. To determine this threshold, the uncertainty in the NDVI calculation and the decrease in the NDVI due to water stress (although relatively slight in thoroughly irrigated grasslands) must be considered. El Hajj *et al.* (2008) discovered that the relative uncertainty in the NDVI computed from SPOT-5 surface reflectance data over sugarcane fields was approximately 15%. When using this relative uncertainty as a rule of thumb, a threshold of approximately 0.68 is recommended to ensure reliable detections of the harvest dates. An analysis of the temporal evolution of NDVI values for all training plots showed that the NDVI of harvested plots reached a selected threshold of 0.68 approximately 18 to 23 days after harvest. Figure 2 shows an example of the temporal evolution of the NDVI for the "1J" plot out of the available set of ten. In conclusion, for our study grassland, the revisit times of LANDSAT-8 (16 days) and SENTINEL-2 (10 days with SENTINEL-2A only) are suitable for identifying whether a harvest has occurred or not between two images.

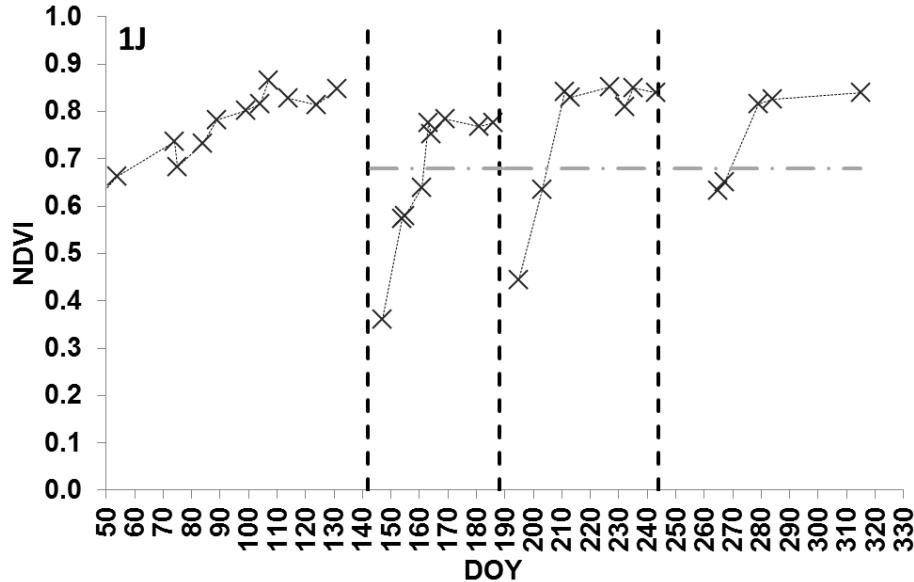


Figure 2. Temporal evolution of NDVI for a given plot (1J). Black vertical dashed lines represent the harvest dates. Horizontal dashed line corresponds to a NDVI threshold of 0.68, which is found adequate for harvest detection.

The current LANDSAT-8 optical sensor and the recently launched SENTINEL-2A (in operation since June 2015) enables crop monitoring with 16-day and 10-day revisit times, respectively. The upcoming launch of SENTINEL-2B (mid-2016) will enable optical images with 5-day revisit times. The precision of the harvest dates that are estimated from optical images is certainly related to their revisit times. For example, with the current temporal series of LANDSAT-8 images (16 days), if the NDVI of a mature plot (high NDVI) significantly decreases at a given DOY between two successive acquisitions, there is no doubt the harvest occurred within the last 16 days.

To analyze the effect of uncertainty of harvest dates (estimated from optical images) on the predicted TDM, a random noise was added to the true harvest dates (recorded in situ), whose magnitude is dependent on the revisit times. For a given position (DOY) of the optical image within 16 days after the true harvest dates, this added uncertainty is a random integer in the $[N, M]$ range, where (i) M is the optical image date - the true harvest date, and N is M - revisit time of a given sensor. Indeed, from some of the optical acquisition dates, it is possible to detect that a harvest occurred in the last R days ($R = \text{revisit time}$) but it is impossible to identify its exact date of occurrence, which introduces uncertainty (dispersion) in model predictions (the TDM in this study). Three uncertainty levels of the harvest dates, depending

on the sensor revisit time, were considered in this study for the assessment of associated dispersions:

- Configuration 1: case in which SENTINEL-2A and SENTINEL-2B are employed, with a revisit time of 5 days. For each position (DOY) of the optical image within 16 days after the true irrigation dates, optical harvest date = true harvest date + error on the harvest date in the [N , M] range, which yields 1000 random negative integers between -5 and 0.
- Configuration 2: case in which only SENTINEL-2A is employed, with a revisit time of 10 days. For each position (DOY) of the optical image within 16 days after the true irrigation dates, optical harvest date = true harvest date + error on the harvest date in the [N , M] range, which yields 1000 random negative integers between -10 and 0.
- Configuration 3: case in which only LANDSAT-8 is employed, with a revisit time of 16 days. For each position (DOY) of the optical image within 16 days after the true irrigation dates, optical harvest date = true harvest date + error on the harvest date in the [N , M] range, which yields 1000 random negative integers between -16 and 0.

For each uncertainty level, the 1000 "perturbed" TDM values were compared with the reference TDM values obtained from predictions using the true harvest dates. The differences are analyzed based on statistical indexes (bias, RMSE, and MAPE).

2.5.3 Effect of uncertainty on irrigation dates

As for the harvest dates, the irrigation dates are input parameters for PILOTE in this study, with an expected effect on TDM predictions. At irrigation dates provided to the model, the soil water reserve is re-filled due to the irrigation technique (border irrigation).

In agricultural areas, the increase in soil moisture is caused by irrigation or rainfall events. The use of SAR sensors to track irrigation events is possible because the radar signal is highly sensitive to soil moisture variations (the radar signal increases with soil moisture). This sensitivity is dependent on target conditions (bare soil or vegetation cover). In a recent study of the same area, El Hajj *et al.* (2014) showed that the radar signal was sensitive to soil moisture variations even for dense vegetation covers. This sensitivity was approximately 0.13 dB/Vol.% and 0.08 dB/Vol.% for biomass that is lower than 1 kg/m^2 (LAI approximately $3 \text{ m}^2/\text{m}^2$) and biomass that is higher than 1 kg/m^2 , respectively. A sensitivity of 0.13 dB/% indicates an increase in the radar signal by 1.3 dB as the soil moisture increases by 10 vol.%.

Furthermore, El Hajj *et al.* (2014) concluded that the radar images can be utilized to identify "three-day-old" irrigated plots, i.e., plots that have been irrigated for a maximum of three days prior to SAR acquisition. The results showed that the radar signal attained a maximum level during the irrigation event (double-bounce scattering between the water surface and the vertical stems and leaves of the vegetation) and subsequently decreased in the next three days with decreasing soil moisture.

Currently, combining available SAR sensors, such as TerraSAR-X, COSMO-Sky-Med, and SENTINEL-1, enables acquisition of at least one image per day on a given study site. However, it is assumed here that two SAR images per week are sufficient to detect all irrigations over our study area it has been demonstrated that the irrigation is detectable on SAR image if it occurs at most three days prior to SAR acquisition. Missing the detection of irrigation in a given cycle could affect the predicted TDM in the current and the next cycle only.

Accordingly, we assumed that all irrigation dates are detected from SAR images. This, in turn, allows investigating the impact of uncertainties on the irrigation dates derived from SAR. To do this, for a given position (DOY) of the radar image within 3 days after the true harvest dates, this added uncertainty is a random integer in the [N , M] range, where (i) M = radar image date - true irrigation date, and N = M - revisit time. The revisit time is equal to 3 because we suppose that two SAR images per week are sufficient to detect all irrigations. Finally, the 1000 "perturbed" TDM values were compared to reference TDM values, which are obtained from predictions using all true irrigation dates. The differences are analyzed based on the statistical indexes (bias, RMSE, and MAPE).

To assess the effect of missed (or undetected) irrigations on the predicted TDM values, some irrigations have been deliberately missed, first by examining the predicted TDM values when (a) one irrigation is missed in the first cycle, (b) one irrigation is missed in the second cycle, and (c) one irrigation is missed in the third cycle. The same procedure is then repeated; this time, two irrigations are missed in (a) the first cycle, (b) the second cycle and (c) the third cycle. Whenever one and two irrigations are missed, the predicted TDM values were compared to reference the TDM predictions, which were obtained using all true irrigation dates by statistical indexes (bias, RMSE, and MAPE).

3. Results and discussion

3.1 Integration of optical LAI values

The TDM was predicted according to the two scenarios defined in section 2.4.1. In the first scenario, the model input variables of LAI_0 , LAI_{\min} , and LAI_{\max} are derived from the optical LAI values. In addition, the second scenario also forces the optical LAI values, which are interpolated at daily time intervals, into the model. For both scenarios, the predicted TDM values are compared with the *in situ* TDM values with statistical indexes (bias, RMSE, and MAPE) (Figure 3, Table 1). For the first scenario, the results show a similar bias (predicted TDM – *in situ* TDM) for the three crop growth cycles (absolute bias of approximately 0.17 t/ha). In addition, the RMSE on predicted TDM was slightly higher in the first cycle (0.57 t/ha) compared with the second and third cycles (0.39 t/ha) (Table 1). The MAPEs were 14 and 23% for the first, and second and third cycle, respectively (Table 1). The statistics calculated using all cycles combined show a RMSE of 0.41 t/ha and a MAPE of 22% for the first scenario (Table 1). For the second scenario, the comparison between the predicted TDM and the *in situ* TDM shows very similar results (as obtained in scenario 1) for all cycles combined or with a focus on each of the three cycles (bias -0.08 t/ha, RMSE 0.47 t/ha and MAPE 24%; Table 1). Therefore, forcing optical LAI values that are interpolated at daily time intervals has almost no effect on the accuracy of the prediction of the TDM because the LAI predicted by PILOTE in the first scenario (LAI_0 , LAI_{\min} , and LAI_{\max} fixed from optical LAI values) is well correlated with the optical LAI values, with a coefficient of determination of 0.8. Figure 4 shows these predicted LAI values as a function of the optical LAI values. In a study conducted over grassland areas using the STICS crop model, Courault *et al.* (2010) also observed that replacing daily predicted LAI values with optical LAI values that were interpolated at daily time intervals did not enhance the accuracy of the yield estimates. Finally, same results on TDM prediction were obtained by forcing *in situ* LAI-values instead of optical LAI-values.

	Cycle	Bias (t/ha)	RMSE (t/ha)	MAPE (%)	NB
Scenario 1	Cycle1	0.17	0.57	13.6	21
	Cycle2	0.15	0.40	24.3	56
	Cycle3	-0.18	0.37	22.8	96
	All cycles	-0.03	0.41	21.9	173
Scenario 2	Cycle1	-0.17	0.65	13.5	21
	Cycle2	0.29	0.45	28.6	56
	Cycle3	-0.27	0.44	24.1	96
	All cycles	-0.08	0.47	24.2	173

Table 1. Statistical indexes (bias, RMSE, and MAPE) of the comparison between the predicted TDM and the in situ TDM for configurations 1 and 2. Scenario 1: LAI₀, LAI_{min} and LAI_{max} are fixed from the optical images. Scenario 2: LAI₀, LAI_{min}, and LAI_{max} are fixed from optical images, and the LAI values predicted by PILOTE at daily time intervals are replaced by the LAI values estimated from optical images at the same time interval. NB: number of in situ TDM samples. Bias = predicted TDM – in situ TDM.

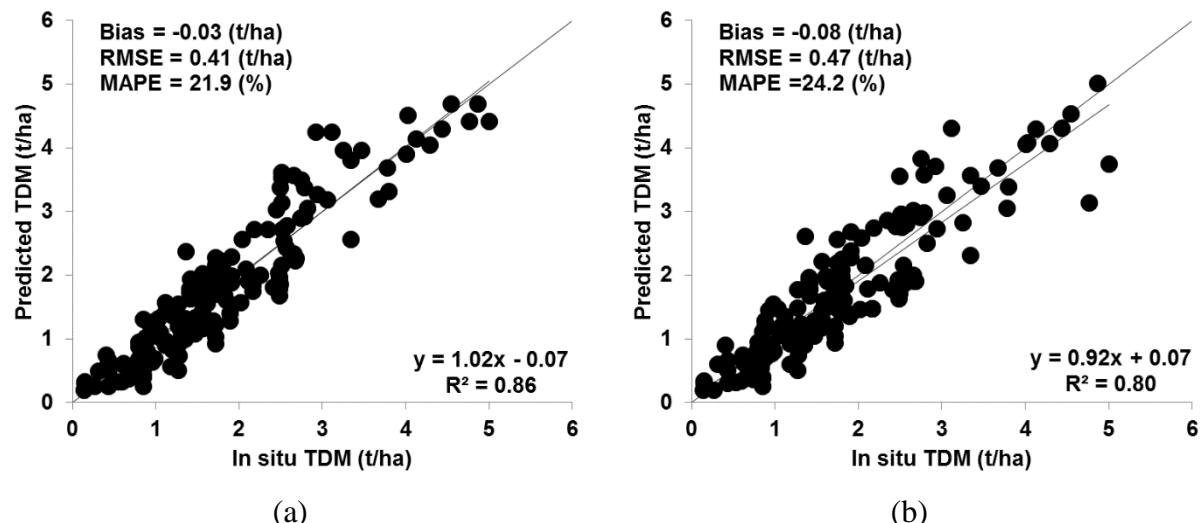


Figure 3. Predicted TDM as a function of in situ TDM for all cycles. (a) Configuration 1: LAI₀, LAI_{min} and LAI_{max} fixed from optical images. (c) Configuration 2: LAI₀, LAI_{min}, and LAI_{max} fixed from optical images and LAI values predicted by PILOTE at daily time intervals are replaced by LAI values estimated from optical images at the same interval time. Bias = predicted TDM – in situ TDM.

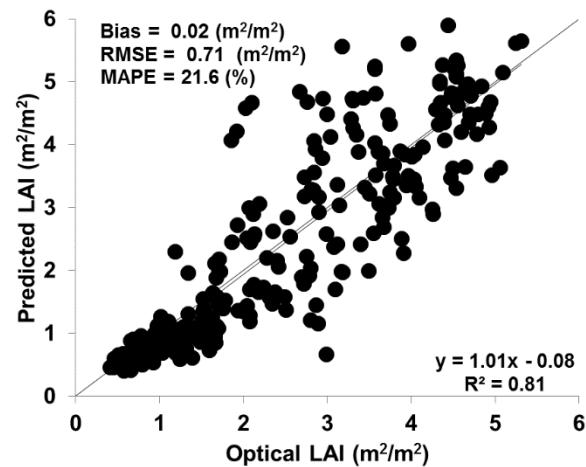


Figure 4. LAI predicted by PILOTE according to configuration 1 (using optical LAI values to fix LAI_0 , LAI_{\min} and LAI_{\max} in the model) as a function of optical LAI values for all three cycles.

3.2 Effect of uncertainty on harvest dates

The effect of the uncertainty on harvest dates (as derived from optical images) on the prediction of TDM values is evaluated in this section. The TDM values that were predicted using noisy harvest dates (1000 random draws) are compared with the reference TDM values, which were predicted by PILOTE from the true harvest dates (Figure 5). Table 2 shows the associated statistical indexes (bias, RMSE and MAPE) that were separately calculated for each of the three cycles, for all cycles combined, and for each "uncertainty level" of the harvest dates (i.e. 5, 10 and 16 days).

For all uncertainty levels, a slight difference between the predicted TDM and the reference predicted TDM for each cycle was observed (bias between -0.18 and 0.14) (Table 2). Moreover, the RMSE on TDM predictions is approximately similar for each of the three cycles for a given uncertainty level on harvest dates (Table 2). As an example, for the uncertainty level of 10 days, the RMSE is 0.20, 0.28 and 0.24 (t/ha) for the first, second, and third cycle, respectively. In addition, as expected, the RMSE increases with the level of uncertainty (e.g. first cycle, RMSE of 0.10 t/ha, 0.20 t/ha and 0.33 t/ha for uncertainty levels of 5, 10, and 16 days). Finally, the lowest MAPE value is associated with the first cycle and the highest MAPE value is associated with the third cycle (e.g. uncertainty level of 10 days, MAPE values of 2.7%, 6.0%, and 8.6% for the first cycle, second cycle and third cycle, respectively).

When the precision on the predicted TDM values is evaluated using all cycles combined, the difference between the perturbed TDM predictions (noisy harvest dates) and the reference TDM predictions (true harvest dates) is insensitive to the increase in the uncertainty level on the harvest dates. A near-zero bias was obtained for all uncertainty levels on the harvest dates and the RMSE and the MAPE only slightly increased with uncertainty level the harvest dates for all cycles (Figure 5, Table 2). The RMSE on predicted TDM values using noisy harvest dates was 0.16 t/ha (MAPE 4%), 0.24 t/ha (MAPE 6%) and 0.37 t/ha (MAPE 9%) for uncertainty levels on the true harvest dates of 5, 10, 16 days, respectively.

As a conclusion, the harvest dates that were estimated from optical images with temporal revisit times of 5 (SENTINEL-2A/B), 10 (SENTINEL-2A) or 16 (LANDSAT-8) days are suitable to feed PILOTE with harvest dates without inducing significant errors on the predicted TDM values (RMSE < 0.35 t/ha and MAPE < 12%).

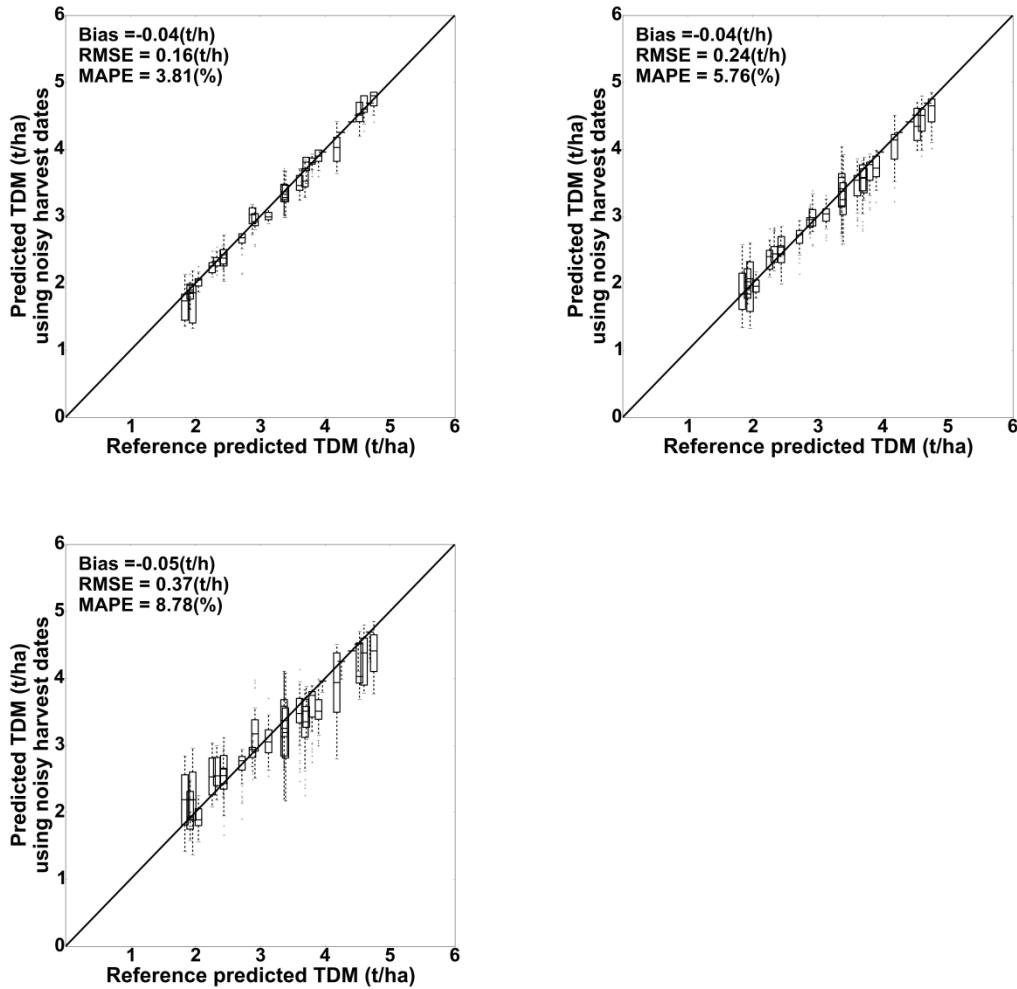


Figure 5. TDM predicted using noisy harvest dates as a function of reference TDM predicted using the true harvest dates. (a) Uncertainty level of 5 days. (b) Uncertainty level of 10 days. (c) Uncertainty level of 16 days. Bias = predicted TDM using noisy harvest dates – reference TDM.

	Bias (t/ha)	RMSE (t/ha)	MAPE (%)
Uncertainty level = 5 days			
Cycle1	0.00	0.10	1.3
Cycle2	-0.06	0.18	4.1
Cycle3	-0.07	0.19	6.0
All cycles	-0.04	0.16	3.8
Uncertainty level = 10 days			
Cycle1	-0.08	0.20	2.7
Cycle2	-0.07	0.28	6.0
Cycle3	0.04	0.24	8.6
All cycles	-0.04	0.24	5.8
Uncertainty level = 16 days			
Cycle1	-0.18	0.33	4.6
Cycle2	-0.11	0.43	9.2
Cycle3	0.14	0.35	12.5
All cycles	-0.05	0.37	8.8

Table 2. Statistical indexes (bias, RMSE, and MAPE) of the comparison between the predicted TDM using noisy harvest dates and the reference TDM predicted using true harvest dates for each of the three cycles and all cycles. Bias = predicted TDM using noisy harvest dates – reference TDM.

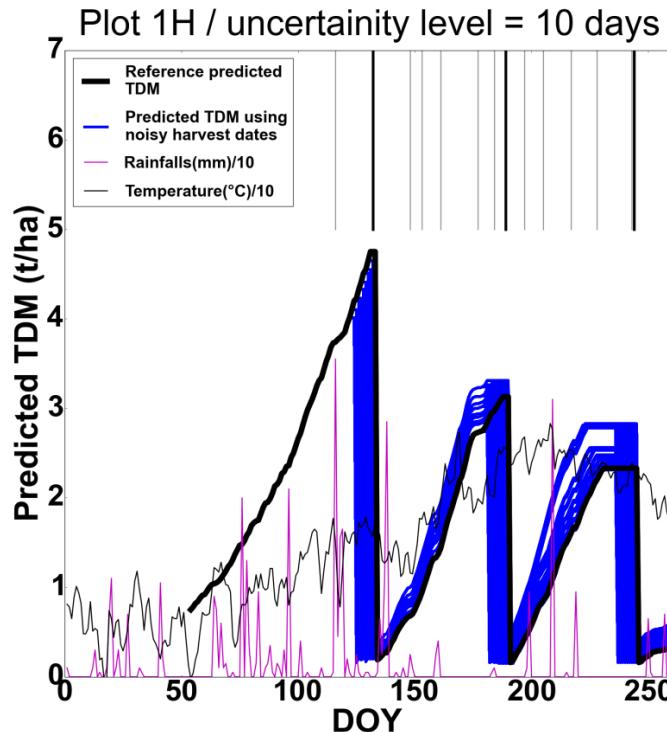


Figure 6. Evolution of the predicted TDM using noisy harvest dates and reference TDM for a given plot (1H). The bold black line represents the reference TDM. The blue lines represent the 1000 predicted TDM with uncertainty level for the harvest dates of 10 days. The magenta line represents the daily average precipitation (mm) divided by 10. The thin black line represents traces the daily average temperature divided by 10. The vertical gray lines indicate the irrigation dates and the vertical bold black lines figure the three true harvest dates.

3.3 Effect of uncertainty on the irrigation dates

In this section, we evaluate the effect (on the predicted TDM values) of the uncertainty on the irrigation dates (up to three days when considering two radar acquisitions per week; refer to Section 2.5.3) and the effect of the non-detection of certain irrigation events (irrigation events more than three days prior to radar acquisitions are difficult to detect, as discussed in Section 2.5.3).

3.3.1 All irrigation events are detected with an uncertainty on irrigation dates

At the end of each crop growth cycle, the TDM values that were predicted from noisy irrigation dates (1000 random draws) were compared to the reference TDM values that were predicted by PILOTE from the true irrigation dates (Figure 7). Table 3 shows the statistical indexes (bias, RMSE, and MAPE) that were separately calculated for each of the three cycles, then for all cycles combined, and for a maximum uncertainty level of 3 days on irrigation dates (i.e. on each of the irrigation dates).

The bias was almost equal to zero for each one of the three cycles (Table 3), and the RMSE on the first cycle was low (0.01 t/ha, with MAPE = 0.2%) compared to that on the second and third cycles (approximately 0.14 t/ha with MAPE = 4.7%). The error for the TDM prediction in the second and third cycles was higher than the error for the TDM prediction in the first cycle; this difference may be related to the irrigations (the noisy irrigation dates) due to the greater number of irrigations in the second cycle and third cycle (a minimum of four and three irrigations in the second cycle and third cycle, respectively).

Finally, the statistics obtained from the combined results of all cycles show un-biased differences between the TDM values that were predicted from noisy irrigation dates and the reference TDM values (predicted from the true irrigation dates) with a low RMSE of 0.14 t/ha and a low MAPE of 3.2% (Table 3, Figure 7). As a conclusion, the irrigation dates that were derived from radar data with a maximum uncertainty of 3 days are appropriate to feed the PILOTE model without inducing significant errors on the prediction of the TDM values.

	Bias (t/ha)	RMSE (t/ha)	MAPE (%)
Cycle 1	0.00	0.01	0.2
Cycle 2	0.01	0.20	4.7
Cycle 3	-0.04	0.14	4.6
All cycles	-0.01	0.14	3.2

Table 3. Statistical indexes (bias, RMSE, and MAPE) of the comparison between the predicted TDM using irrigation dates noised with a maximum uncertainty for irrigation dates of 3 days and the reference TDM predicted using all true irrigation dates. All irrigations are assumed to be detected. Bias = predicted TDM using noisy irrigation dates – reference TDM.

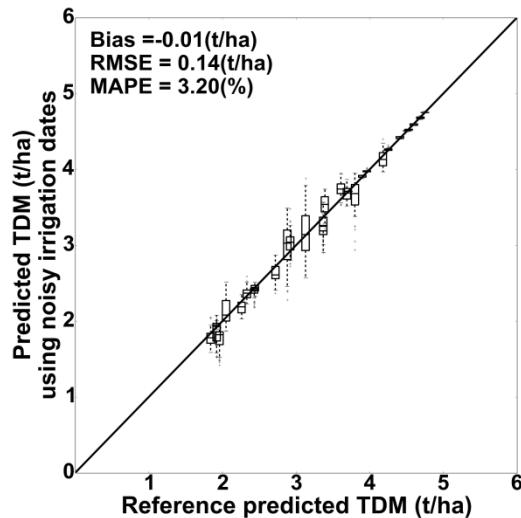


Figure 7. TDM predicted using irrigation dates noised with a maximum uncertainty on irrigation dates of 3 days as a function of reference TDM predicted using all true irrigation dates (data of three cycles are plotted). It is assumed that all the irrigation events are detected. Bias = predicted TDM using noisy irrigation dates – reference TDM.

3.3.2 Case in which some irrigation events are not detected from SAR images

Some irrigation events may be missed if the radar images are acquired more than three days after them. Missing the detection of irrigation events in a given cycle possibly affects the predicted TDM values in the current but also in the next cycle, as the soil water status is inherited from the previous cycle even when crops are harvested.

To investigate the effect of missing irrigation events on the predicted TDM values, one or two irrigations were deliberately ignored within each cycle. The associated errors on the predicted TDM values were quantified by comparing, at the end of each cycle, between the perturbed TDM values and the reference TDM values, which were predicted from all true irrigation dates.

3.3.2.1 Ignoring irrigations in the first cycle

Ignoring one or two irrigations in the first cycle did not affect the prediction of TDM in the first and second cycle due to frequent and heavy rainfall during the first cycle between March and May (DOY between 50 and 150 in Figure 8). When ignoring one (Figures 8a, 8b) or two simultaneous irrigations (Figure 8c) for a given plot, the soil water reserve that was predicted by PILOTE becomes clearly lower (for example, at DOY 113 and DOY 123 in Figure 8a and Figure 8b, respectively) than the soil water reserve in the reference conditions. This

discrepancy subsequently vanishes due to the cited rainfalls, which enables PILOTE to correctly predict the TDM in the first cycle.

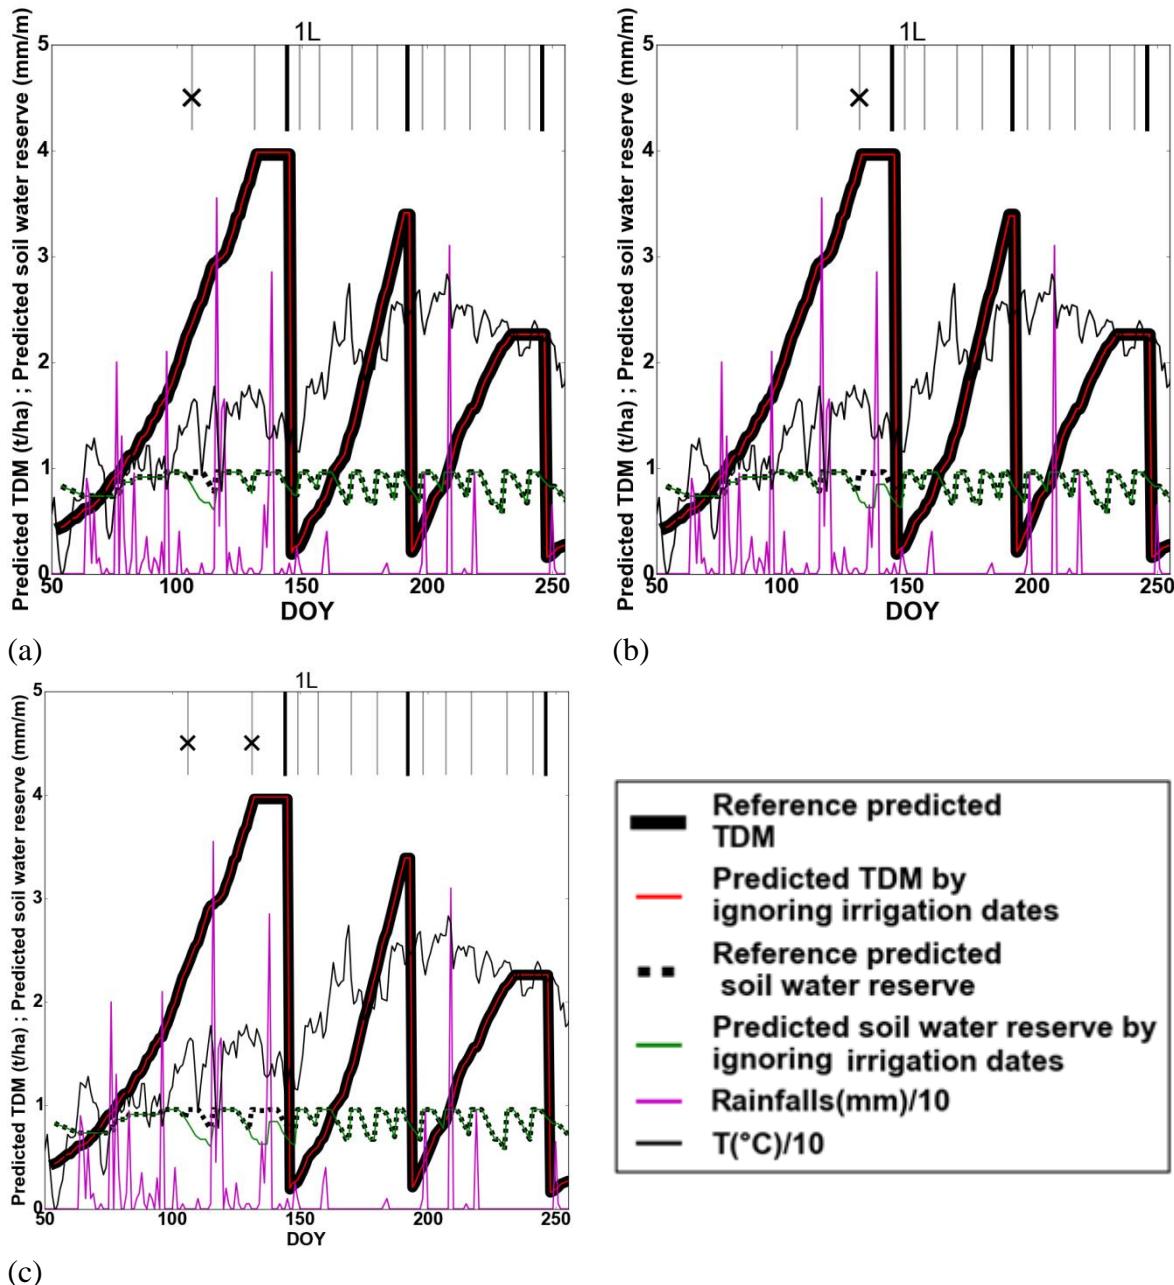


Figure 8. Evolution of the predicted TDM when ignoring one or two irrigations in the first cycle for a given plot (1L). (a) Ignoring the first irrigation. (b) Ignoring the second irrigation. (c) Ignoring both the first and second irrigations. The reference soil water reserve was predicted using all true irrigation dates. The vertical gray line represents the real irrigation dates. The black cross mark indicates the ignored irrigation. The magenta line represents the daily average precipitation (unit: 0.1 mm). The black line represents the daily average temperature divided by 10. The bold black vertical lines represent the three true harvest dates.

3.3.2.2 Ignoring irrigations in the second cycle

Ignoring irrigations in the second cycle affects the TDM that was predicted in the second and third cycles.

A. Effect on predicted TDM in the second cycle

Ignoring one or two irrigations in the second cycle produces predicted TDM values that are less than the TDM values in the reference conditions (Figures 9a and 9d). However, Figure 9a shows that the underestimation when the first and fourth irrigations are ignored (approximately -0.5 t/ha) is less than the underestimation when the second and third irrigations are ignored (approximately -1.0 t/ha). This finding is explained by the important rainfall (~29 mm) that occurred near the occurrence of the first irrigation of the second cycle, i.e., before the irrigation for some plots and after the irrigation for other plots. In all cases, this rainfall event enables compensation of the loss in the predicted soil water reserve that is associated with the missed first irrigation, which in turn allows correctly predicts the TDM (Figure 10a). Conversely, the second and third irrigations of the second cycle occurred in a dry period of the year (Figure 10b): ignoring these irrigations creates a distinct deficit in the predicted soil water reserve, which leads to clearly underestimates the biomass production. The fourth irrigation of the second cycle also occurred after a period without significant rainfall (Figure 10c) but was near the harvest date, and the predicted TDM was already near its asymptotic plateau value, which induces less underestimation than the underestimation in previous cases. Moreover, Figure 9d shows that the effect on the predicted TDM values tends to increase when two successive irrigations are ignored (Figures 9a and 9d). A bias of -1.3 t/ha was observed in the second cycle when ignoring irrigations 1&2, 1&3, 2&3, 2&4 and 3&4, whereas a bias of 0.87 t/ha was obtained when ignoring irrigations 1&4, which was the lowest bias of all tests (Figure 9d). As an example, Figure 10d, shows for a given plot that simultaneously ignores the second and third irrigations produces more significant lower predicted TDM in comparison to reference TDM than ignor the third irrigation (Figure 10b).

An RMSE of 0.7 t/ha (MAPE of 15.8%) was obtained when ignoring the first and fourth irrigations, and an RMSE of 1.2 t/ha (MAPE of 31.8%) was obtained when ignoring the second and third irrigations (Figures 9b, 9c). The effect of simultaneously ignoring two irrigations yields a larger error for the predicted TDM in the second cycle. As an example, the RMSE on predicted TDM in the second cycle when the first and second irrigations are simultaneously ignored is 1.59 t/ha (MAPE = 37.1%) (Figure 9e, 9f) compared with 0.68 t/ha (MAPE = 12.6%) when only the first irrigation is ignored. Simultaneously ignoring 1&4 irrigations yields less error (RMSE = 1.01 t/ha, MAPE = 25.2%) on predicted TDM with respect to the error obtained when 1&2, 1&3, 2&3, 2&4, and 3&4 are simultaneously ignored

(RMSE approximately 1.52 t/ha MAPE approximately 39.2%). Indeed, the first irrigation occurred before and after important rainfall (~29 mm), and the fourth irrigation is the last irrigation in the case of several plots.

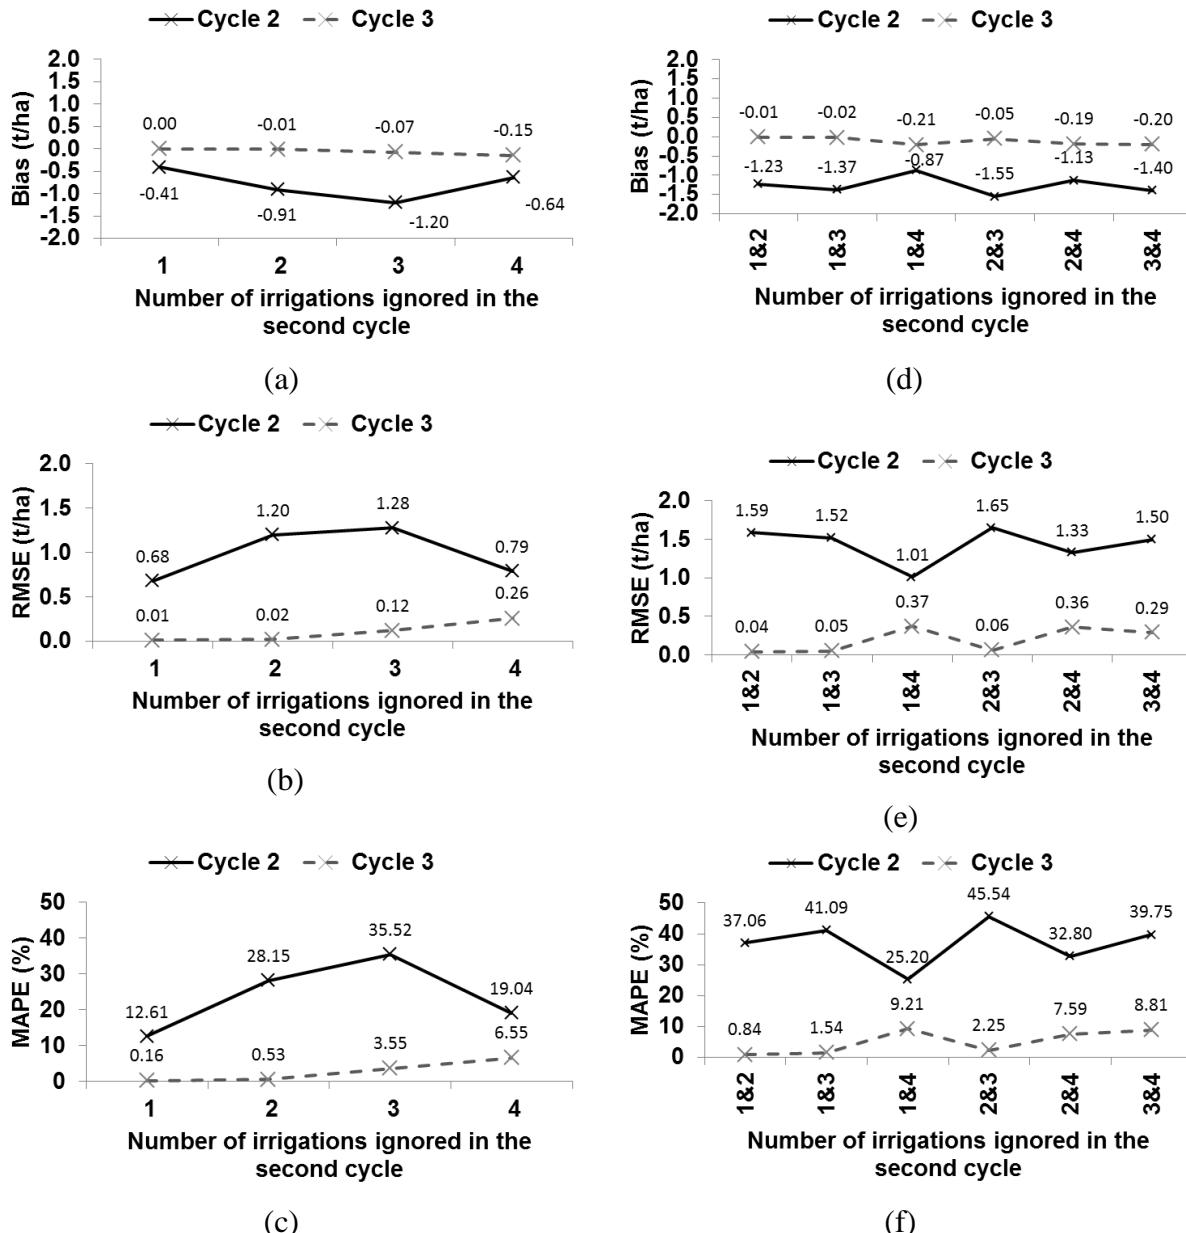


Figure 9. Bias (t/ha), RMSE (t/ha), and MAPE (%) on predicted TDM in the second and third cycles by ignoring one irrigation (a, b, c) and two irrigations (d, e, f) in the second cycle. Bias = predicted TDM by ignoring irrigation – reference TDM.

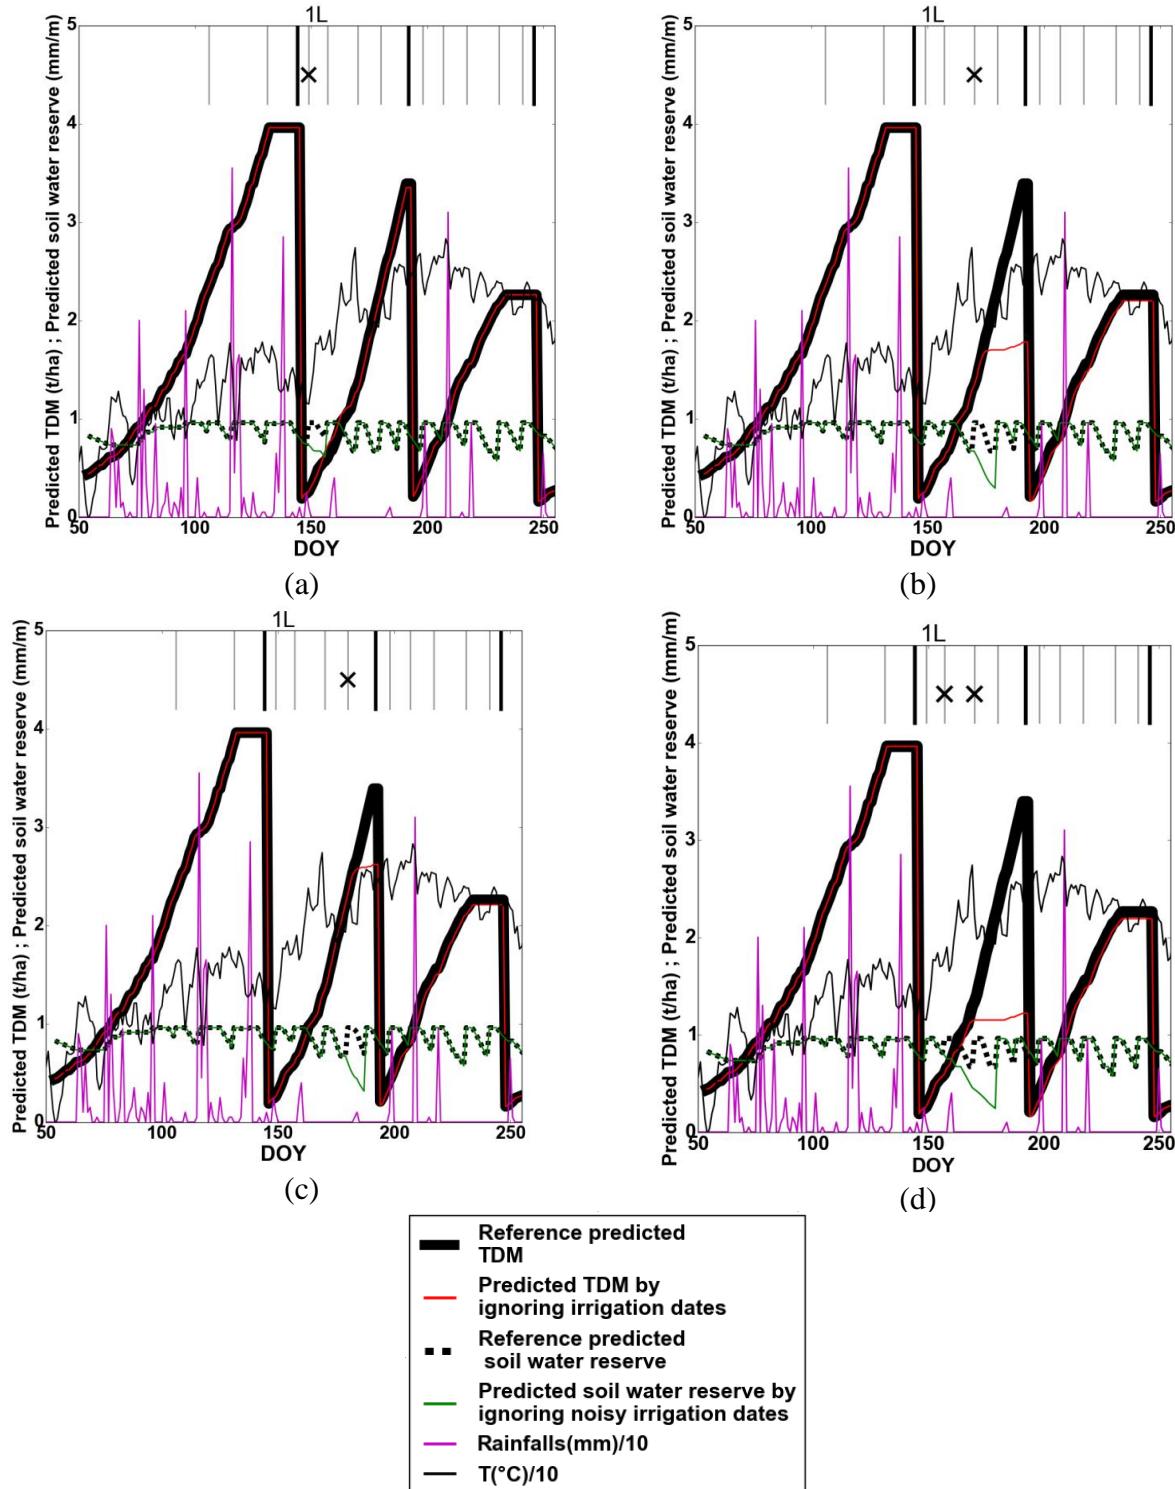


Figure 10. Evolution of the predicted TDM when ignoring one or two irrigations in the second cycle for a given plot (1L). (a) Ignoring the first irrigation. (b) Ignoring the third irrigation. (c) Ignoring the fourth irrigation. (d) Ignoring both first and second irrigations. Reference soil water reserve was predicted using all true irrigation dates. The vertical gray line represents the real irrigation dates. The black cross mark indicates the ignored irrigation. The magenta line reveals the daily average precipitation (mm) divided by 10. The black Line: daily average temperature divided by 10. Bold black vertical lines: the three true harvest dates.

B. Effect on predicted TDM in the third cycle

Ignoring one or two irrigations in the second cycle induces slightly lower TDM predictions in the third cycle compared with the reference TDM (bias between 0 and -0.20 t/ha) (Figures 9a, 9d). The effect of undetected irrigation is not pronounced because rainfall events have occurred in the third crop growth cycle (Figure 10). The higher underestimations were obtained when the fourth irrigation was one of the irrigations ignored. The fourth irrigation in the second cycle is near the beginning of the third crop growth cycle. Thus, ignoring the fourth irrigation induces an underestimation in the predicted soil water reserve at the beginning of the third cycle, which causes an associated underestimation in the TDM that was predicted in the third cycle (the effect is transmitted from the second crop growth cycle to the third crop growth cycle by changing the initial water content conditions for the third cycle).

The RMSE on predicted TDM is negligible in the third cycle when ignoring one irrigation of the second cycle ($\text{RMSE} < 0.26 \text{ t/ha}$, and $\text{MAPE} < 6.6\%$) (Figures 9b, 9c). The RMSE increases slightly when two irrigations are simultaneously ignored (Figures 9e and 9f), especially when the fourth irrigation of the second cycle is one of the two irrigations ignored.

3.3.2.3 Ignoring irrigations in the third cycle

Ignoring irrigations in the third cycle potentially affects the predicted TDM values of the third cycle only. Figure 11a shows that the underestimation of the predicted TDM values was stronger when the first (-0.79 t/ha) or second (-0.42 t/ha) irrigation was ignored compared with ignoring the third irrigation (-0.22 t/ha). This finding is attributed to the nonexistent rainfall and small rainfall during the period preceding the first irrigation and second irrigation of the third cycle, respectively. Accordingly, the underestimation increases when simultaneously ignoring irrigations 1&2 (-1.43 t/ha), 1&3 (-0.97 t/ha) and 2&3 (-0.68 t/ha) irrigations (Figure 11d).

Finally, the RMSE and MAPE when ignoring the first ($\text{RMSE} = 0.88 \text{ t/ha}$, $\text{MAPE} = 35.0\%$) or second irrigation ($\text{RMSE} = 0.56 \text{ t/ha}$, $\text{MAPE} = 18.6\%$) were higher than the RMSE and MAPE when ignoring the third irrigation ($\text{RMSE} = 0.28 \text{ t/ha}$, $\text{MAPE} = 10.1\%$) (Figures 11b and 11c). The importance of these errors increases when two irrigations are simultaneously ignored. RMSE is 1.54 t/ha ($\text{MAPE} = 63.6\%$), 1.06 t/ha ($\text{MAPE} = 43.3\%$) and 0.75 t/ha ($\text{MAPE} = 30.4\%$) when irrigations 1 &2, 1&3, and 2&3 are ignored, respectively (Figures 11e, and 11f).

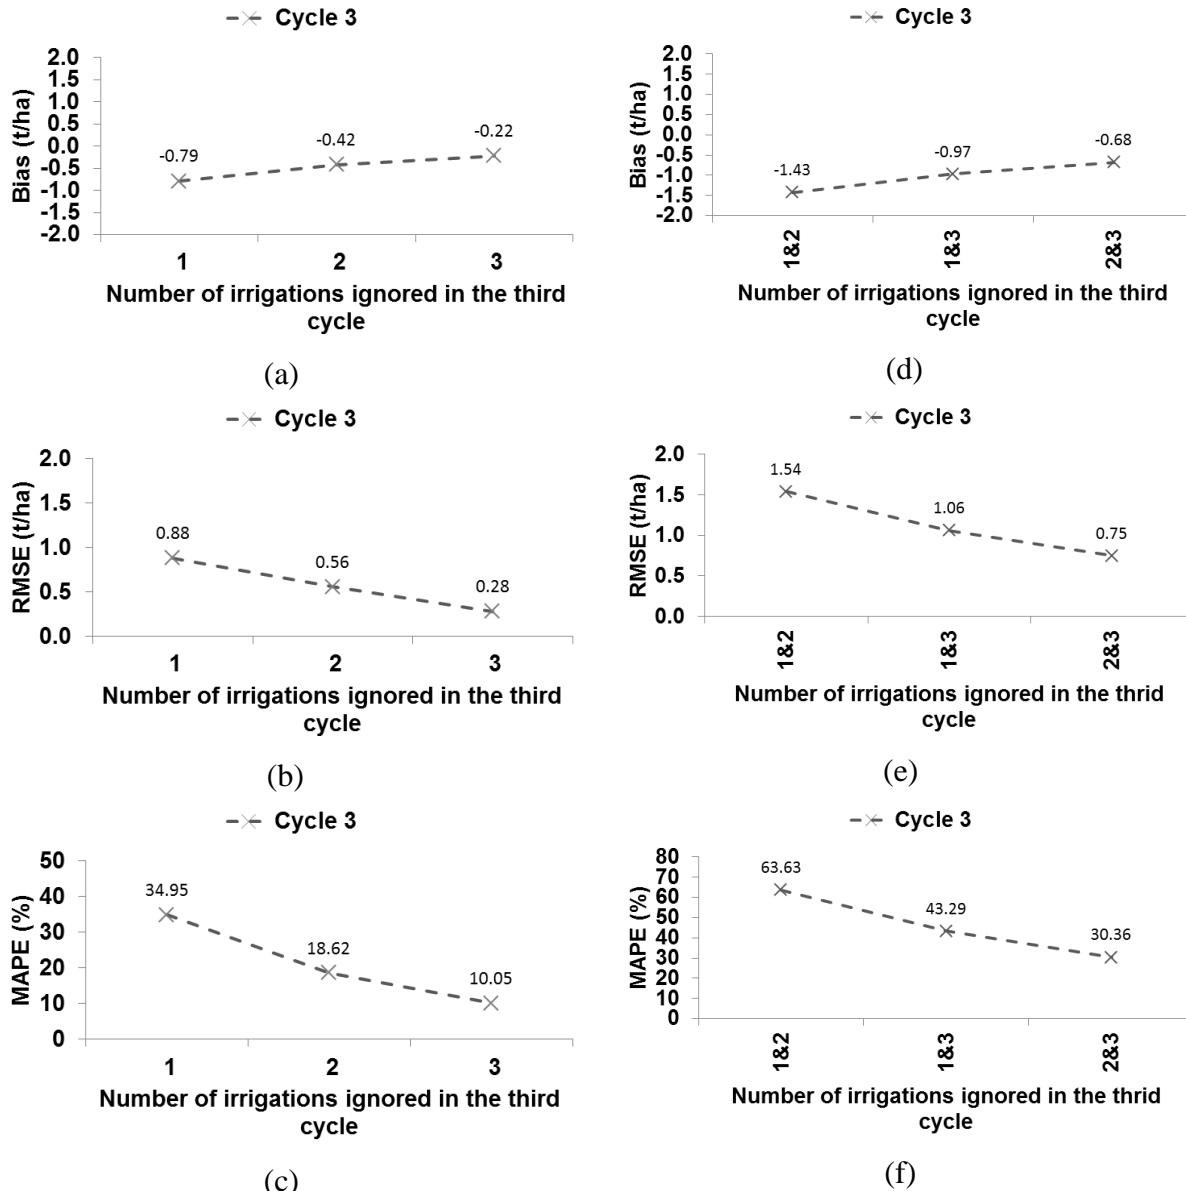


Figure 11. Bias (t/ha), RMSE (t/ha), and MAPE (%) on predicted TDM in the third cycle by ignoring one irrigation (a, b, and c) and two irrigations (d, e, and f) in the third cycle. Bias = predicted TDM by ignoring irrigation – reference TDM.

4. Conclusion

The aim of this study was to address the feasibility, merits and limitations of forcing remote-sensing-derived variables (initial and maximal LAI values and harvest and irrigation dates) in the PILOTE crop model, targeting the predictions of biomass production, in this study in the form of the Total Dry Matter (TDM) of hay crops. LAI values and harvest dates may be

estimated from optical images while irrigation dates are inferred from SAR (Synthetic Aperture Radar) data.

For the explored scenarios, the use of optical images to provide some of the input parameters of the LAI type required by PILOTE was deemed appropriate. Feeding the model with remote-sensing-derived estimates of the initial and maximal LAI values may spare *costly in situ* measurements while still ensuring correct model execution (Root Mean Square Error-RMSE on TDM: 0.43 t/ha, Mean Absolute Percentage Error-MAPE: 23%). In addition, the use of daily-interpolated LAI values that were obtained from optical images did not provide any significant increase in the model reliability, which may also reduce acquisition costs.

Forcing randomly perturbed harvest dates in PILOTE (to simulate imperfect detections) did not drastically affect the TDM predictions, at least when assuming uncertainties over the harvest dates equal to the revisit times of SENTINEL-2A and/or -2B, and LANDSAT-8. For the latter, when drawing the three random harvest dates in the [-16, 0] days interval before the true ones, and repeating the procedure 1000 times, one still obtains satisfying error statistics (RMSE of 0.41 t/ha and MAPE of 15%).

Finally, feeding PILOTE with noisy irrigation dates that were estimated from SAR images also enabled reliable model predictions, at least when attaching a random uncertainty of "only" 3 days to the real known irrigation dates. This test procedure is consistent with the availability of two radar images per week, which yielded RMSE and MAPE values of 0.17 t/ha and 4.2%, respectively. The case of one or several "missed" irrigations has also been explored, with the expected conclusion that undetected irrigations significantly affect model predictions only in dry periods. Otherwise, the effect on model predictions results from the interplay between rain amounts, soil's holding capacity and initial reserve, and plant's ability to resist to water stresses. For the tested soil properties and climatic conditions, a maximum underestimation of TDM of approximately 1.3 t/ha (reference TDM of 3.43 t/ha) was observed in the second crop growth cycle when ignoring two irrigations out of four in this same cycle. In the specific case of Crau hay, certified for its floristic composition, water stress conditions may affect the growth of some species. These subtle effects were not considered here.

This study emphasizes the importance of assimilating of remote sensing derived variables in crop model. In particular, the use of LAI values and harvest dates derived from optical sensors and that of irrigation dates derived from SAR sensors are effective to feed crop models (such as PILOTE) to estimate and monitor the yield all along vegetation growth. This opens way to multiple application cases in crop growth monitoring in agricultural areas.

CHAPITRE 6 :

Conclusions et perspectives

1. Synthèse de recherche

Les travaux menés dans la cadre de cette thèse ont permis d'apporter de nouvelles connaissances, d'une part, sur le potentiel du signal radar en bande X pour le suivi et l'estimation de l'humidité du sol en présence de la végétation, d'autre part sur l'intérêt de l'intégration des données spatiales dans les modèles de culture.

Il est connu que la profondeur de pénétration du signal radar en bande X (longueur d'onde $\lambda \sim 3$ cm) dans la végétation est faible, comparativement à celle du signal radar en bandes C et L ($\lambda \sim 6$ cm et ~ 23 cm, respectivement). Pour cette raison, peu d'études ont utilisé les données radar en bande X pour estimer l'humidité du sol en présence de végétation. Dans cette thèse, nous avons souhaité néanmoins évaluer le potentiel de la bande X pour les raisons suivantes: (1) les capteurs bande X permettent des acquisitions avec des résolutions métriques, adaptée à des parcelles de petites tailles, ce qui doit permettre de mieux différencier les pratiques d'une parcelle à l'autre ; de ce fait, dès lors que les états hydriques résultent de décisions individuelles (cas des périmètres irrigués), cette résolution spatiale nous semble nécessaire, (2) l'utilisation de la bande X sur un site irrigué est innovant car peu d'études sont disponibles avec cette longueur d'onde, (3) les capteurs bande X TerraSAR-X et COSMO-SkyMed sont les seuls à permettre un suivi journalier, ce qui permet de suivre finement les évolutions de l'humidité superficielle du sol et d'identifier ainsi des calendriers d'irrigation.

Les résultats de la sensibilité des données radar en bande X (polarisations HH et HV) à l'humidité du sol en présence de la végétation ont montré que le signal radar pénètre le couvert végétal et la rétrodiffusion radar est sensible à l'état hydrique du sol, même pour les parcelles avec un couvert végétal dense (hauteur ~ 1 m, LAI $\sim 6 \text{ m}^2/\text{m}^2$, Biomasse $\sim 4.2 \text{ kg/m}^2$). Les résultats ont également montré que le signal radar en bande X pourra être utilisé pour le suivi de l'irrigation, même si l'image est acquise trois jours après l'achèvement de l'irrigation.

Une méthode opérationnelle a ensuite été développée pour l'estimation de l'humidité du sol en présence de végétation, basée sur le couplage de données radar et optique. Les résultats ont montré qu'en utilisant la polarisation HH seule (meilleur résultat avec HH qu'avec HV seul ou avec HH et HV ensemble) et le NDVI qui peut être dérivé facilement à partir des images optiques l'humidité du sol pourra être estimée avec une précision d'environ 5 Vol.%, même en présence d'un couvert végétal dense (hauteur ~ 1 m, LAI $\sim 6 \text{ m}^2/\text{m}^2$, Biomasse $\sim 4.2 \text{ kg/m}^2$). Une précision similaire sur l'estimation de l'humidité du sol est obtenue en utilisant d'autres variables de la végétation dérivées à partir des données optiques (LAI, FAPAR, et FCover) au lieu du NDVI.

L'impact de l'intégration dans le modèle de culture PILOTE des paramètres dérivés des données spatiales sur la prédiction de la matière sèche totale (TDM) de la végétation a été analysé. L'originalité de cette partie est l'utilisation de données spatiales à très haute résolution spatio-temporelle, pour alimenter un modèle de culture par des paramètres de végétation (LAI) et des pratiques agricoles (dates de début/fin de cycle et dates d'irrigation), sur un site de prairie irriguée.

L'analyse s'est appuyée sur un périmètre irrigué du Sud de la France où sont irriguées des prairies par gravité, selon un tour d'eau d'en moyenne 10 jours. Le cycle de culture est relativement court (entre 50 et 70 jours), ce qui permet d'évaluer, dans ce contexte, la pertinence et les limites de la télédétection à haute résolution temporelle. Le modèle de culture PILOTE a été utilisé car il a été calé et validé sur les prairies irriguées de notre site d'étude.

Les résultats montrent que l'intégration dans PILOTE des valeurs de LAI dérivées des données optiques peut nous épargner des mesures *in situ*, tout en assurant une prédiction précise du rendement. En effet, l'intégration de LAI "optiques" permet de prédire le TDM avec une précision similaire à celle obtenue en intégrant le LAI *in situ*. La comparaison entre les valeurs de TDM prédites et *in situ* donne un RMSE de l'ordre 0.45 t/ha (erreur relative de 24%). De plus, l'intégration des valeurs de LAI dérivées des données optiques et interpolées à un pas de temps journalier n'apporte pas d'amélioration sur la précision des valeurs de TDM prédites, ce qui permet d'économiser des acquisitions satellitaires fréquentes.

L'utilisation dans PILOTE de dates de coupes estimées à partir d'images optiques de répétitivité temporelle inférieure à 16 jours n'entraîne pas d'erreur significative sur les prédictions de TDM. Le RMSE de la comparaison entre les TDM prédits et les TDM de référence (prédits avec les vraies dates de coupe « *in situ* ») est inférieur à 0.42 t/ha (erreur relative inférieure à 15%).

Enfin, l'effet de l'intégration dans PILOTE des dates d'irrigation dérivées à partir des images radar a été analysé. Les résultats montrent que l'utilisation de dates d'irrigation dérivées des données radar, acquises deux fois par semaine, n'affecte pas significativement la prédiction des valeurs de TDM (en supposant toutefois que toutes les irrigations sont détectables). Le RMSE de la comparaison entre TDM prédits et TDM de référence (prédits avec les vraies dates d'irrigation) est égale à 0.17 t/ha (erreur relative de seulement 4.2%). En complément, la non-détection des irrigations dans une période riche en précipitations n'affecte pas la prédiction de TDM, tandis que la non-détection des irrigations dans une période sans précipitation induit une sous-estimation des valeurs de TDM prédites d'environ 1.3 t/ha (pour des TDM de référence d'environ 3.43 t/ha).

2. Perspectives de recherche

Plusieurs perspectives de recherche se dégagent de mes travaux de thèse. Elles portent, d'une part, sur le potentiel des capteurs SAR pour l'estimation et le suivi de l'humidité du sol et des paramètres de la végétation, et d'autre part, sur le potentiel des données spatiales à alimenter des modèles de culture pour le suivi du rendement et la gestion de l'irrigation.

2.1 Couplage radar-radar ou radar-optique pour une meilleure estimation de l'humidité du sol et des paramètres des prairies

Les capteurs radar actuels en bande X (TSX et CSK) permettent d'acquérir sans difficulté une image quotidienne sur n'importe zone géographique. Avec l'arrivée récente des nouveaux capteurs Sentinel-1 (bande C) et ALOS-2 (bande L), il est également possible d'acquérir des images radar en bandes C et L avec une répétitivité temporelle de 3 et 14 jours, respectivement. De plus, avec les capteurs Sentinel-2 et Landsat-8, l'acquisition des images optiques est possible avec des répétitivités temporelles de 10 jours (Sentinel-2A seul), 5 jours (Sentinel-2A et Sentinel-2B), et 16 jours (Landsat-8). Un autre avantage des capteurs Sentinel-1/2 est la gratuité des données. La haute spatio-temporelle de ces capteurs radar (bandes X, C et L) et optique (domaine de visible et infra-rouge) ouvre des perspectives encourageantes pour développer des approches opérationnelles de cartographie de l'humidité et des paramètres de la végétation. Ces approches seront basées sur l'utilisation en conjonction des deux configurations radar (soit deux fréquences et deux incidences, soit une fréquence et deux incidences), ou le couplage des données radar et optique.

Le signal radar rétrodiffusé en bande X à forte incidence est dominé par la contribution de la végétation (Balenzano et al., 2011). Cependant, pour des courtes longueurs d'onde (bandes X et C) à faible et moyenne incidences, ou pour une grande longueur d'onde (bande L) le signal radar rétrodiffusé est modélisé comme la somme de la contribution du sol et de celle de la végétation (Balenzano et al., 2011; Brown et al., 2003). Ainsi, utiliser en conjonction deux configurations radar, la première sensible principalement à la végétation (bande X à forte incidence), et la deuxième particulièrement sensible à l'humidité du sol, permet d'améliorer la précision sur l'estimation de l'humidité du sol et des paramètres de la végétation (Bindlish and Barros, 2001; Prévot et al., 1993; Taconet et al., 1994). Une première perspective serait d'utiliser en conjonction deux configurations radar pour estimer l'humidité du sol et les paramètres de la végétation. Quatre cas d'étude qui tiennent en compte la répétitivité temporelle des images radar sont envisageables :

- Cas 1 : images en bande X à faible (ou moyenne) incidence et images en bandes X à forte incidence
- Cas 2 : images en bande C à faible (ou moyenne) incidence et images en bande X à forte incidence
- Cas 3 : images en bande L et images en bande X.
- Cas 4 : images en bande L et images en bande C.

Peu d'études ont utilisé en conjonction deux configurations radar pour estimer l'humidité du sol et les paramètres de la végétation. Prévot *et al.* (1993) ont montré que l'utilisation en conjonction des deux configurations radar (C-HH-20° et X-VV-40°) permettait d'estimer l'humidité du sol et le LAI du blé (LAI entre 0.1 et 8 m²/m²).

Une deuxième perspective serait de coupler les données radar et optique pour estimer l'humidité du sol et les paramètres de la végétation. Sur des sols nus, de nombreuses études (Aubert *et al.*, 2011; Baghdadi *et al.*, 2012b) ont montré que l'estimation de l'humidité du sol est deux fois plus précise en bande X qu'en bande C. En présence de végétation, on s'attend à une estimation moins précise de l'humidité du sol avec la bande X qu'avec les bandes C et L (plus précise en bande L qu'en bande C car la pénétration du signal radar est plus importante dans le couvert). Cependant, la haute répétitivité temporelle et la gratuité des données radar Sentinel-1 (bande C) pourra nous amener à préférer l'estimation de l'humidité du sol à partir de données bande C, même si elle est légèrement moins précise que celle qui sera obtenue avec la bande L. Trois cas d'étude sont possibles :

- Cas 1 : images radar en bande X (à faible ou moyenne incidence) et images optiques
- Cas 2 : images radar en bande C (à faible ou moyenne incidence) et images optiques
- Cas 3 : images radar en bande L et images optiques

Enfin, appliquer les deux approches (radar-radar ou radar-optique) permet de définir l'approche méthodologique la plus pertinente pour estimer l'humidité du sol et les paramètres de la végétation.

2.2 Supervision du rendement, et gestion de l'irrigation des systèmes irrigués

Dans le cadre de la thèse, nous avons montré que l'intégration dans PILOTE des paramètres dérivés des données spatiales (LAI, dates de coupes et d'irrigations) permet d'alimenter le modèle et de prédire le rendement avec une bonne précision. Dans PILOTE, la prédiction du rendement dépend des valeurs d'humidité du sol qui sont prédites par le modèle dans deux réservoirs du sol. Le premier réservoir représente les 10 premiers centimètres du sol, tandis le

deuxième réservoir à une épaisseur de 60 cm (sur ce site). L'intégration dans PILOTE des valeurs d'humidité du sol dérivées des données radar (ainsi que l'intégration du LAI) pourrait améliorer la prédiction des valeurs du rendement. Nous avons ici considéré l'information radar pour la détection des dates d'irrigation, parcelle par parcelle. Pour aller plus loin, on peut envisager d'assimiler les humidités radar dans PILOTE, selon une fréquence dépendant des capteurs utilisés (cf section précédente), afin d'améliorer la connaissance des états hydriques en temps réel et affiner la prédiction des rendements. Toutefois, l'imagerie radar permet d'estimer l'humidité du sol au mieux dans les premiers 5 cm du sol, tandis que PILOTE prédit et utilise l'humidité du sol dans des couches du sol plus profondes que 5 cm. Pour lever cette difficulté, plusieurs études ont montré que l'humidité dans la zone racinaire pourrait être dérivée à partir de l'humidité surfacique grâce à des modèles d'infiltration de l'eau dans le sol (Calvet et al., 1998; Ceballos et al., 2005; Crow and Wood, 2003; Paris Anguela et al., 2008; Verstraeten et al., 2006; Wagner et al., 1999; Wigneron et al., 1999).

Pour montrer la pertinence des données spatiales, nous avons choisi de forcer les états à partir des données observées. Pour aller plus loin, et disposant maintenant d'une meilleure connaissance de la précision des données, nous pouvons aller vers des techniques d'assimilation de données qui permettent d'estimer les états avec une pondération entre les états observés et les états simulés. Le forçage, utilisé dans la thèse, est donc un cas particulier où la mise à jour ne se fait qu'avec les observations. L'intégration des valeurs de l'humidité dans PILOTE pourra ainsi être réalisée en utilisant des méthodes mathématiques d'assimilation comme le filtre de Kalman (Irmak and Kamble, 2009; Kamble et al., 2013; Montzka et al., 2011). En effet, les méthodes mathématiques d'assimilation s'appuient sur une valeur d'humidité (dérivée d'une image) à un temps t_n pour ajuster la prédiction d'humidité et du rendement par le modèle aux temps t_n et t_{n-k} . Ceci passe par une re-calibration des paramètres ou des états du modèle qui contrôle l'évolution de la prédiction de l'humidité du sol dans le temps, tenant en compte les pratiques d'irrigation et l'effet de la précipitation. La technique de forçage de l'humidité du sol (cas particulier d'assimilation) pourra être utilisée à la place des méthodes mathématiques d'assimilation si et seulement si les valeurs d'humidité du sol sont dérivées à partir des images radar, à un pas de temps journalier (pas de temps de prédiction des modèles de culture) ce qui n'est pas possible actuellement avec les capteurs gratuits. Enfin, reconstituer l'évolution de la réserve en eau des sols au cours du temps permet de définir des critères pour le déclenchement d'irrigations, et par conséquence la gestion des ressources en eau.

Grâce à leur haute résolution spatiale, notamment les futurs Sentinel-1/2, les données radar et optiques permettent de fournir des paramètres du sol et de la végétation à l'échelle intra-parcellaire; l'assimilation des données spatiales à haute résolution spatiale dans les modèles

Chapitre 6 : Conclusions et perspectives

de culture pourra être réalisée à l'échelle intra-parcellaire. Une perspective serait d'intégrer les paramètres dérivés des données spatiales à l'échelle intra-parcellaire pour détecter des hétérogénéités spatiales liées aux caractéristiques physiques des parcelles ou aux pratiques d'irrigation, et prédire plus finement le rendement.

Annexe 1

Annexe 1

Parameter	Description	Units	Value	Source	Version Pilote	Reference
climate	Name of the climate file (max. 20 characters, no blank spaces)			base de données Agroclim, INRA Avignon	PILOTE	Mailhol and Merolt (2008)
ian	Simulation year (indicates data to read in the <i>climate</i> file)	-	2013	-	PILOTE	Mailhol and Merolt (2008)
fc1	Field capacity of the first reservoir	-	0.28	Literature	PILOTE	Mailhol and Merolt (2008)
wp1	Wilting point of the first reservoir	-	0.12	Literature	PILOTE	Mailhol and Merolt (2008)
z1	Depth of the first reservoir	m	0.1	Literature	PILOTE	Mailhol and Merolt (2008)
fc2	Field capacity of the second reservoir	-	0.28	Literature	PILOTE	Mailhol and Merolt (2008)
wp2	Wilting point of the second reservoir	-	0.12	Literature	PILOTE	Mailhol and Merolt (2008)
z2	Depth of the second reservoir	m	0.6	Literature	PILOTE	Mailhol and Merolt (2008)
fc3	Field capacity of the third reservoir	-	0.25	Literature	PILOTE	Mailhol and Merolt (2008)
wp3	Wilting point of the third reservoir	-	0.15	Literature	PILOTE	Mailhol and Merolt (2008)
profz	Maximal rooting depth	m	1	Literature	PILOTE	Mailhol and Merolt (2008)
rkrz	Ratio between the easily-usable reserve and the useful reserve	-	0.3	Literature	PILOTE	Mailhol and Merolt (2008)
hu1	Volumetric water content in the first reservoir	%	0.22	Literature	PILOTE	Mailhol and Merolt (2008)
hu2	Volumetric water content in the second reservoir	%	0.27	Literature	PILOTE	Mailhol and Merolt (2008)
hu3	Volumetric water content in the third reservoir	%	0.25	Literature	PILOTE	Mailhol and Merolt (2008)
rckm	Maximum value of the crop coefficient	-	1	Literature	PILOTE	Mailhol and Merolt (2008)
rlaimx	Maximum LAI value	-	[4-5] depending on plot	Images optiques	PILOTE	Mailhol and Merolt (2008)

Annexe 1

rmg	Radiation use efficiency	-	0.37	Literature	PILOTE	Mailhol and Merolt (2008)
trf	Temperature above which the radiation use efficiency is reduced (about the start of the third cycle)	°C	2800	Literature	PILOTE	Mailhol and Merolt (2008)
psi	Parameter that controls the severity of the above effect	-	0.0005	Literature	PILOTE	Mailhol and Merolt (2008)
rlai0	LAI value for the starting day of the simulation	-	<i>[0.1-0.3] depending on plot</i>	Images optiques	PILOTE	Mailhol and Merolt (2008)
	LAI value after a cut but only if rlai0>rlaimin					
rlaimin	Minimal LAI value (after a cut)	-	<i>[0.1-0.3] depending on plot</i>	Images optiques	PILOTE	Mailhol and Merolt (2008)
tdm01	Total dry matter at the beginning of the simulation (jstart0)	t ha ⁻¹	0.15	In situ	autoPILOTE	Cheviron et al. (2015)
tdm02	Total dry matter after the first cut	t ha ⁻¹	0.15	In situ	autoPILOTE	Cheviron et al. (2015)
tdm03	Total dry matter after the second and third cuts	t ha ⁻¹	0.15	In situ	autoPILOTE	Cheviron et al. (2015)
jstart0	Starting day for the simulation	-	54	In situ	PILOTE	Mailhol and Merolt (2008)
jrecol	Latest possible harvest date	-	310	Literature	PILOTE	Mailhol and Merolt (2008)
tm	Temperature for which the max. LAI value is reached (would be true in absence of water stress)	°C	900	Literature	PILOTE	Mailhol and Merolt (2008)
tfmat	Temperature of maturity	°C	1020	Literature	PILOTE	Mailhol and Merolt (2008)
coefe	Parameter that accounts for the harmfulness of water stresses	-	10	Literature	PILOTE	Mailhol and Merolt (2008)
etax	Potential EvapoTranspiration above which the radiation use efficiency is affected	mm	8	Literature	PILOTE	Mailhol and Merolt (2008)
dcx	Coefficient that controls the severity of the previous effect	-	5	Literature	PILOTE	Mailhol and Merolt (2008)
coefrg	Stress coefficient for too low radiation values (1.0 = neutral, no such effect)	-	1	Literature	PILOTE	Mailhol and Merolt (2008)

Annexe 1

rgopt	Optimal daily radiation value above which no "low radiation stress" exists	MJ m ⁻²	1500	Literature	PILOTE	Mailhol and Merolt (2008)
alpha1	Shape parameter of the LAI curve (rising limb)	-	3.7	Literature	PILOTE	Mailhol and Merolt (2008)
alpha2	Shape parameter of the LAI curve (falling limb)	-	4.4	Literature	PILOTE	Mailhol and Merolt (2008)
gama	Shape parameter of the LAI curve	-	3	Literature	PILOTE	Mailhol and Merolt (2008)
xt0	Temperature for crop emergence	°C	0	Literature	PILOTE	Mailhol and Merolt (2008)
tbase	Base temperature	°C	0	Literature	PILOTE	Mailhol and Merolt (2008)
itest	itest=0 if there is an irrigation scheduling, see the <i>jour(i)</i> parameters	-	0/1	Literature	PILOTE	Mailhol and Merolt (2008)
	itest=1 if irrigation is triggered by the <i>epuise</i> parameter				PILOTE	Mailhol and Merolt (2008)
epuise	Level of depletion of the useful reserve that triggers irrigation	%	30	Literature	PILOTE	Mailhol and Merolt (2008)
dosap	Irrigation dose applied at each irrigation (itest=1 only)	mm	100	Literature	PILOTE	Mailhol and Merolt (2008)
jdir	Number of days after sowing, opens the irrigation window	-	32	Literature	PILOTE	Mailhol and Merolt (2008)
jfir	Number of days after sowing, closes the irrigation window	-	250	Literature	PILOTE	Mailhol and Merolt (2008)
ndc	Number of cuts during the season (known and fixed to ndc=3)	-	3	Literature	PILOTE	Mailhol and Merolt (2008)
idcoup(1)	Date of the first cut	-	132	In situ	PILOTE	Mailhol and Merolt (2008)
idcoup(2)	Date of the second cut	-	181	In situ	PILOTE	Mailhol and Merolt (2008)
idcoup(3)	Date of the third cut	-	232	In situ	PILOTE	Mailhol and Merolt (2008)
jour(1)	Date of the first irrigation (itest=0 only)		120	In situ	PILOTE	Mailhol and Merolt (2008)
dose(1)	Dose of the first irrigation (itest=0 only)	mm	100	In situ	PILOTE	Mailhol and Merolt (2008)

Annexe 1

jour(15)	Date of the 15 th irrigation (itest=0 only)	-	250	In situ	PILOTE	Mailhol and Merolt (2008)
dose(15)	Dose of the 15 th irrigation (itest=0 only)	mm	100	In situ	PILOTE	Mailhol and Merolt (2008)
f1	Fixed irrigation costs (wages, subscription)	k€ ha ⁻¹	not used	-	autoPILOTE	Cheviron et al. (2015)
f2	Cost for irrigation water	€ m ⁻³	not used	-	autoPILOTE	Cheviron et al. (2015)
f3	Selling price for hay	k€ ton ⁻¹	not used	-	autoPILOTE	Cheviron et al. (2015)

Table 3 : Description of PILOTE model parameters including the source of parameters values

Liste des figures et des tableaux

Liste des figures

Chapitre 2 - Description du site d'étude et de la base de données:

Figure 1. Site d'étude « Domaine du Merle ». En noir toutes les parcelles du domaine. En bleu les parcelles témoins. En rouge la limite du domaine.....	22
Figure 2. Courbe de calibration de Theta probe. Cercles noir représentent les mesures d'humidité	24
Figure 3. (a) Mesures d'humidité sur une parcelle témoin (1a), les points rouges représentent le positionnement des mesures d'humidité, ici 30 mesures. (b) l'instrument Thetaprobe.	24
Figure 4. Profilomètre à aiguilles pour la mesure de la rugosité.....	26
Figure 5. Photo hémisphérique pour l'estimation du LAI.....	27
Figure 6 . LAI issues des traitements des photos hémisphériques avec CanEye en fonction de LAI destructive (Demarez et al., 2008).....	28
Figure 7. (a) Image optique acquise par SPOT-4 le 14 Mai 2013, composition colorée : R = PIR, V = Rouge, B = vert. (b) Image radar (TSX) acquise le même jour (14/05/2013), composition colorée : R = HH (dB), V = HV (dB), B = HH (dB)-HV (dB). L'image optique a été coupée pour ajuster l'étendue géographique de l'image radar. (c) Zoom dans l'image optique sur le site d'étude, (d) zoom dans l'image radar sur le site d'étude.....	35
Figure 8. Comparaison entre les moyennes de NDVI des parcelles témoins issues des différents capteurs LANDSAT-7/8 et SPOT-4/5	41
Figure 9. (a) BIO <i>in situ</i> en fonction VWC <i>in situ</i> , (b) LAI <i>in situ</i> en fonction de FAPAR <i>in situ</i> , (c) LAI <i>in situ</i> en fonction de FCover <i>in situ</i>	42

Chapitre 3 - Sensibilité des données radar en bande X aux paramètres du sol et de la végétation:

Figure 1. Location of the study site in France (Domaine du Merle). Black polygons delineate the sampled plots. (a) TerraSAR-X image was acquired on April 24, 2013 in RGB colors (R: HH, G: HV, B, HH-HV). (b) SPOT-4 image acquired on April 22, 2013 in RGB colors (R: NIR, G: R, B: G).....	54
Figure 2. Daily air temperature recorded over the study area.	55
Figure 3. LAI measurements according to vegetation height (a), Biomass measurements according to vegetation height (b).....	60
Figure 4. Temporal evolution of vegetation parameters for the sampled plot 1a. Vertical lines indicate cut dates.....	61
Figure 5. The relationship between the NDVI derived from the optical images and the vegetation measurements ((a) LAI, (b) HVE, (c) BIO and (d) VWC).....	62

Figure 6. An example of the temporal variation in SAR X-band signals in a given training plot (plot 2e) according to soil moisture (a), and vegetation biomass and height (b). In (c) Photos with associated Fraction vegetation cover (Fr) for plot 2e.	64
Figure 7. Sensitivity of X-band to soil moisture for biomass lower than 1 kg/m ² ((a) HH, (b) HV) and for biomass higher than 1 kg/m ² ((c) HH, (d) HV).	66
Figure 8. Detection of flooded parts of irrigated plots (in red) (a-d). Δt_b (in hours) = SAR acquisition time–start irrigation time; Δt_e (in hours) = SAR acquisition time–end irrigation time; Wd = Water body depth. Black arrows indicate open canal locations used for border irrigation. Images are in RGB colors (R: HH, G: HV, B: HH-HV).	67
Figure 9. Sensitivity of X-band ((a,c,e) HH, and (b,d,f) HV) to LAI in three soil moisture (M _v) classes.	71
Figure 10. Sensitivity of X-band ((left) HH, and (right) HV) to vegetation height in three soil moisture (M _v) classes.....	72
Figure 11. Sensitivity of X-band ((left) HH, and (right) HV) to BIO in three soil moisture (M _v) classes.....	73
Figure 12. Sensitivity of X-band ((left) HH, and (right) HV) to VWC in three soil moisture (M _v) classes.....	74

Chapitre 4 - Estimation de l'humidité du sol à partir d'images radar en bande X

Figure 1. Location of the study site (Domaine du Merle). Black polygons delineate training irrigated grassland plots where ground measurements were made.....	91
Figure 2. Photo clicked for some training plots with associated in situ measurements	95
Figure 3. Sensitivity of radar signal in both HH and HV polarization to volumetric soil moisture... ..	102
Figure 4. Behavior of WCM components ($\sigma^{\circ}_{\text{veg}}$, $T^2\sigma^{\circ}_{\text{sol}}$, and $\sigma^{\circ}_{\text{tot}}$) in both HH and HV polarizations according to M _v . Black points represent the SAR data ($\sigma^{\circ}_{\text{tot}}$: real validation dataset) associated with NDVI measurements within ± 0.1 of the NDVI used in the modelling.	106
Figure 5. Behavior of WCM components ($\sigma^{\circ}_{\text{veg}}$, $T^2\sigma^{\circ}_{\text{sol}}$, and $\sigma^{\circ}_{\text{tot}}$) in both HH and HV polarizations according to NDVI. Black points represent the SAR data ($\sigma^{\circ}_{\text{tot}}$: real validation dataset) associated with M _v measurements within ± 5 vol. % of the M _v used in the modelling.....	107
Figure 6. Evolution of RMSE of M _v estimates according to the three inversion configurations as a function of NDVI for noise conditions on the modeled radar signal of ± 0.75 dB (a), and ± 1 dB (b).111	
Figure 7. Evolution of the relative RMSE (in percent) of M _v estimates (RRMSE=RMSE/ M _v) according to NDVI and M _v . (a) configuration 1: HH and NDVI, (b) configuration 2: HV and NDVI, and (c) configuration 3: HH, HV and NDVI.....	112

Figure 8. Evolution of the bias (estimated M_v – reference M_v) of M_v estimates according to NDVI values. (a) Inversion configuration 1, (b) inversion configuration 2, and (c) inversion configuration 3.	113
Figure 9. Evolution of the bias (estimated M_v – reference M_v) on M_v estimates according to NDVI and M_v values for noise on the modeled radar signal of 0.75 dB. (a) configuration 1, (b) configuration 2, and (c) configuration 3.	114
Figure 10. Box plots of M_v estimates retrieved from the synthetic dataset. Neural networks were trained and validated according to configuration 3 (using HH, HV and NDVI). Noise on the modeled radar signal is ± 0.75 dB, and noise on NDVI is 15% of the NDVI value. Values to the right of the box plots represent the RMSE on M_v estimates for a given reference M_v .	115
Figure 11. Retrieved soil moisture versus ground-truthed measurements for NDVI lower than 0.75. (a,b): configuration 1; (c,d): configuration 2; (e,f): configuration 3. Bias = estimated M_v - reference M_v .	121
Figure 12. Retrieved soil moisture versus ground-truthed measurements for NDVI higher than 0.75 . (a,b): configuration 1; (c,d): configuration 2; (e,f): configuration 3. Bias = estimated M_v - reference M_v .	122

Chapitre 5 - Intégration de paramètres dérivés de la télédétection dans les modèles de culture:

Figure 10. Boucle de fonctionnement de PILOTE. Voir le texte pour la signification des paramètres et des variables du modèle.	127
Figure 1. Location of the study site (Domaine du Merle). Black polygons delineate training irrigated grassland plots, where ground measurements were collected.	140
Figure 2. Temporal evolution of NDVI for a given plot (1J). Black vertical dashed lines represent the harvest dates. Horizontal dashed line corresponds to a NDVI threshold of 0.68, which is found adequate for harvest detection.	145
Figure 3. Predicted TDM as a function of in situ TDM for all cycles. (a) Configuration 1: LAI_0 , LAI_{min} and LAI_{max} fixed from optical images. (c) Configuration 2: LAI_0 , LAI_{min} , and LAI_{max} fixed from optical images and LAI values predicted by PILOTE at daily time intervals are replaced by LAI values estimated from optical images at the same interval time. Bias = predicted TDM – in situ TDM.....	149
Figure 4. LAI predicted by PILOTE according to configuration 1 (using optical LAI values to fix LAI_0 , LAI_{min} and LAI_{max} in the model) as a function of optical LAI values for all three cycles.	150
Figure 5. TDM predicted using noisy harvest dates as a function of reference TDM predicted using the true harvest dates. (a) Uncertainty level of 5 days. (b) Uncertainty level of 10 days. (c) Uncertainty level of 16 days. Bias = predicted TDM using noisy harvest dates – reference TDM.....	152
Figure 6. Evolution of the predicted TDM using noisy harvest dates and reference TDM for a given plot (1H). The bold black line represents the reference TDM. The blue lines represent the 1000 predicted TDM with uncertainty level for the harvest dates of 10 days. The magenta line represents the daily average precipitation (mm) divided by 10. The thin black line represents traces the daily average	

temperature divided by 10. The vertical gray lines indicate the irrigation dates and the vertical bold black lines figure the three true harvest dates..... 154

Figure 7. TDM predicted using irrigation dates noised with a maximum uncertainty on irrigation dates of 3 days as a function of reference TDM predicted using all true irrigation dates (data of three cycles are plotted). It is assumed that all the irrigation events are detected. Bias = predicted TDM using noisy irrigation dates – reference TDM..... 156

Figure 8. Evolution of the predicted TDM when ignoring one or two irrigations in the first cycle for a given plot (1L). (a) Ignoring the first irrigation. (b) Ignoring the second irrigation. (c) Ignoring both the first and second irrigations. The reference soil water reserve was predicted using all true irrigation dates. The vertical gray line represents the real irrigation dates. The black cross mark indicates the ignored irrigation. The magenta line represents the daily average precipitation (unit: 0.1 mm). The black line represents the daily average temperature divided by 10. The bold black vertical lines represent the three true harvest dates..... 157

Figure 9. Bias (t/ha), RMSE (t/ha), and MAPE (%) on predicted TDM in the second and third cycles by ignoring one irrigation (a, b, c) and two irrigations (d, e, f) in the second cycle. Bias = predicted TDM by ignoring irrigation– reference TDM..... 159

Figure 10. Evolution of the predicted TDM when ignoring one or two irrigations in the second cycle for a given plot (1L). (a) Ignoring the first irrigation. (b) Ignoring the third irrigation. (c) Ignoring the fourth irrigation. (d) Ignoring both first and second irrigations. Reference soil water reserve was predicted using all true irrigation dates. The vertical gray line represents the real irrigation dates. The black cross mark indicates the ignored irrigation. The magenta line reveals the daily average precipitation (mm) divided by 10. The black Line: daily average temperature divided by 10. Bold black vertical lines: the three true harvest dates..... 160

Figure 11. Bias (t/ha), RMSE (t/ha), and MAPE (%) on predicted TDM in the third cycle by ignoring one irrigation (a, b, and c) and two irrigations (d, e, and f) in the third cycle. Bias = predicted TDM by ignoring irrigation– reference TDM..... 162

Liste des tableaux

Chapitre 2 - Description du site d'étude et de la base de données:

Table 1. Caractéristiques des images radars.....	32
Table 2. Calendrier des acquisitions spatiales (radar et optique) et des mesures <i>in situ</i>	34
Table 3. Caractéristiques des images optiques.....	36

Chapitre 3 - Sensibilité des données radar en bande X aux paramètres du sol et de la végétation:

Table 1. Acquisition dates of the SAR and optical images (all within 2013).	56
Table 2. Main characteristics of the SAR images (TSX and CSK, all in HH and HV polarizations), and a summary of the ground-truth measurements performed on our sampled plots used in this study. θ : radar incidence angle ($^{\circ}$), Mv: volumetric soil moisture (cm^3/cm^3), VWC: vegetation water content (kg/m^2), BIO: vegetation biomass (kg/m^2), HVE vegetation height (m), LAI: Leaf Area Index (m^2/m^2).	57

Chapitre 4 - Estimation de l'humidité du sol a partir d'images radar en bande X

Table 1. Acquisition dates of SAR and optical images (in 2013). Ground measurements are soil moisture and roughness, LAI, FAPAR, FCOVER, BIO, VWC, and HVE (described in section below).	93
Table 2. Main characteristics of the SAR images (TSX and CSK, all in HH and HV polarizations), and a summary of training plots measurements (made on ten to twelve plots).....	96
Table 3. The minimum, maximum, and step values of WCM inputs.....	99
Table 4. ranges of variation of real training and validation datasets.....	101
Table 5. Fit of WCM parameters for HH and HV polarizations (real validation dataset).....	104
Table 6. Statistical index for each case in figure 4.....	106
Table 7: Statistical index for each case in figure 5.....	107
Table 8. Threshold values of vegetation descriptors at which $\sigma^{\circ}_{\text{veg}}$ dominates $T^2\sigma^{\circ}_{\text{sol}}$ at both HH and HV polarizations. Dash symbols mean that the $\sigma^{\circ}_{\text{veg}}$ is always dominated by $T^2\sigma^{\circ}_{\text{sol}}$	108
Table 9. Statistical indexes on M_v estimates according to the three inversion configurations (RMSE (Vol.%) RRMSE (%) MAPE (%) bias (Vol.%) R^2). Configuration 1 uses HH and NDVI, configuration 2 uses HV and NDVI, and configuration 3 uses HH, HV and NDVI. Relative noise of the NDVI=15%.	110

Table 10. RMSE and Bias on M_v estimates according to the three inversion configurations (RMSE (Vol.%)) | RRMSE (%) | MAPE (%) | bias (Vol.%)) | R^2). Configuration 1 uses HH and vegetation descriptor, configuration 2 uses HV and vegetation descriptor, and configuration 3 uses HH, HV and vegetation descriptor..... 116

Table 11. statics on M_v estimates according to the three inversion configurations (RMSE (Vol.%)) | RRMSE (%) | MAPE (%) | bias Vol.% | R^2 | samples). Configuration 1 uses HH and NDVI, configuration 2 uses HV and NDVI, and configuration 3 uses HH, HV and NDVI. Relative noise on the NDVI=15%. Real SAR measurements and the LAI derived from optical images were used to estimate M_v 117

Table 12. RMSE and bias on M_v estimates according to the three inversion configurations (RMSE (Vol.%)) | RRMSE (%) | MAPE (%) | bias Vol.% | R^2 | samples). Configuration 1 uses HH and NDVI, configuration 2 uses HV and NDVI, and configuration 3 uses HH, HV and NDVI. Relative noise on the NDVI=15%. Real SAR measurements and NDVI derived from optical images were used to estimate M_v 118

Table 13. Statics on M_v estimates according to the three inversion configurations (RMSE (Vol.%)) | RRMSE (%) | MAPE (%) | bias Vol.% | R^2 | samples). Configuration 1 uses HH and NDVI, configuration 2 uses HV and NDVI, and configuration 3 uses HH, HV and NDVI. Real SAR measurements, and NDVI, LAI, FAPAR and FCOVER derived from optical images were used to estimate M_v 120

Chapitre 5 - Intégration de paramètres dérivés de la télédétection dans les modèles de culture:

Table 1. Statistical indexes (bias, RMSE, and MAPE) of the comparison between the predicted TDM and the in situ TDM for configurations 1 and 2. Scenario 1: LAI₀, LAI_{min} and LAI_{max} are fixed from the optical images. Scenario 2: LAI₀, LAI_{min}, and LAI_{max} are fixed from optical images, and the LAI values predicted by PILOTE at daily time intervals are replaced by the LAI values estimated from optical images at the same time interval. NB: number of in situ TDM samples. Bias = predicted TDM – in situ TDM..... 149

Table 2. Statistical indexes (bias, RMSE, and MAPE) of the comparison between the predicted TDM using noisy harvest dates and the reference TDM predicted using true harvest dates for each of the three cycles and all cycles. Bias = predicted TDM using noisy harvest dates – reference TDM..... 153

Table 3. Statistical indexes (bias, RMSE, and MAPE) of the comparison between the predicted TDM using irrigation dates noised with a maximum uncertainty for irrigation dates of 3 days and the reference TDM predicted using all true irrigation dates. All irrigations are assumed to be detected. Bias = predicted TDM using noisy irrigation dates – reference TDM..... 155

Bibliographie

- Agapiou, A., Hadjimitsis, D.G., Papoutsas, C., Alexakis, D.D., and Papadavid, G. (2011). The importance of accounting for atmospheric effects in the application of NDVI and interpretation of satellite imagery supporting archaeological research: the case studies of Palaepaphos and Nea Paphos sites in Cyprus. *Remote Sens.* *3*, 2605–2629.
- Agenzia Spaziale Italiana (2007a). COSMO-SkyMed System Description & User Guide.
- Agenzia Spaziale Italiana (2007b). COSMO-SkyMed System Description & User Guide.
- Al Bitar, A., Leroux, D., Kerr, Y.H., Merlin, O., Richaume, P., Sahoo, A., and Wood, E.F. (2012). Evaluation of SMOS soil moisture products over continental US using the SCAN/SNOTEL network. *Geosci. Remote Sens. IEEE Trans.* *On 50*, 1572–1586.
- Allen, R.G., Pereira, L.S., Raes, D., and Smith, M. (1998). Crop evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56. FAO Rome *300*, 6541.
- Altese, E., Bolognani, O., Mancini, M., and Troch, P.A. (1996). Retrieving soil moisture over bare soil from ERS 1 synthetic aperture radar data: Sensitivity analysis based on a theoretical surface scattering model and field data. *Water Resour. Res.* *32*, 653–661.
- Anderson, M.C., Neale, C.M.U., Li, F., Norman, J.M., Kustas, W.P., Jayanthi, H., and Chavez, J. (2004). Upscaling ground observations of vegetation water content, canopy height, and leaf area index during SMEX02 using aircraft and Landsat imagery. *Remote Sens. Environ.* *92*, 447–464.
- Anguela, T.P., Zribi, M., Baghdadi, N., and Loumagne, C. (2010). Analysis of local variation of soil surface parameters with TerraSAR-X radar data over bare agricultural fields. *Geosci. Remote Sens. IEEE Trans. On 48*, 874–881.
- Asrar, G., Fuchs, M., Kanemasu, E.T., and Hatfield, J.L. (1984). Estimating absorbed photosynthetic radiation and leaf area index from spectral reflectance in wheat. *Agron. J.* *76*, 300–306.
- Attema, E.P.W., and Ulaby, F.T. (1978). Vegetation modeled as a water cloud. *Radio Sci.* *13*, 357–364.
- Aubert, M., Baghdadi, N., Zribi, M., Douaoui, A., Loumagne, C., Baup, F., El Hajj, M., and Garrigues, S. (2011). Analysis of TerraSAR-X data sensitivity to bare soil moisture, roughness, composition and soil crust. *Remote Sens. Environ.* *115*, 1801–1810.
- Aubert, M., Baghdadi, N.N., Zribi, M., Ose, K., El Hajj, M., Vaudour, E., and Gonzalez-Sosa, E. (2013). Toward an Operational Bare Soil Moisture Mapping Using TerraSAR-X Data Acquired Over Agricultural Areas. *Sel. Top. Appl. Earth Obs. Remote Sens. IEEE J. Of* *6*, 900–916.
- Bach, H. (1998). Yield estimation of corn based on multitemporal LANDSAT-TM data as input for an agrometeorological model. *Pure Appl. Opt. J. Eur. Opt. Soc. Part A* *7*, 809.

Bibliographie

- Baghdadi, N., Bernier, M., Gauthier, R., and Neeson, I. (2001). Evaluation of C-band SAR data for wetlands mapping. *Int. J. Remote Sens.* 22, 71–88.
- Baghdadi, N., Gaultier, S., and King, C. (2002). Retrieving surface roughness and soil moisture from SAR data using neural networks. In *Retrieval of Bio-and Geo-Physical Parameters from SAR Data for Land Applications*, (Sheffield, UK.: ESTEC Publishing Division), pp. 315–319.
- Baghdadi, N., Holah, N., and Zribi, M. (2006). Soil moisture estimation using multi-incidence and multi-polarization ASAR data. *Int. J. Remote Sens.* 27, 1907–1920.
- Baghdadi, N., Zribi, M., Loumagne, C., Ansart, P., and Anguela, T.P. (2008a). Analysis of TerraSAR-X data and their sensitivity to soil surface parameters over bare agricultural fields. *Remote Sens. Environ.* 112, 4370–4379.
- Baghdadi, N., Cerdan, O., Zribi, M., Auzet, V., Darboux, F., El Hajj, M., and Kheir, R.B. (2008b). Operational performance of current synthetic aperture radar sensors in mapping soil surface characteristics in agricultural environments: application to hydrological and erosion modelling. *Hydrol. Process.* 22, 9–20.
- Baghdadi, N., Boyer, N., Todoroff, P., El Hajj, M., and Bégué, A. (2009). Potential of SAR sensors TerraSAR-X, ASAR/ENVISAT and PALSAR/ALOS for monitoring sugarcane crops on Reunion Island. *Remote Sens. Environ.* 113, 1724–1738.
- Baghdadi, N., Cresson, R., Todoroff, P., and Moinet, S. (2010). Multitemporal observations of sugarcane by TerraSAR-X images. *Sensors* 10, 8899–8919.
- Baghdadi, N., Saba, E., Aubert, M., Zribi, M., and Baup, F. (2011). Evaluation of Radar Backscattering Models IEM, Oh, and Dubois for SAR Data in X-Band Over Bare Soils. *Geosci. Remote Sens. Lett. IEEE* 8, 1160–1164.
- Baghdadi, N., Cresson, R., El Hajj, M., Ludwig, R., and La Jeunesse, I. (2012a). Estimation of soil parameters over bare agriculture areas from C-band polarimetric SAR data using neural networks. *Hydrol. Earth Syst. Sci.* 16, 1607–1621.
- Baghdadi, N., Aubert, M., and Zribi, M. (2012b). Use of TerraSAR-X data to retrieve soil moisture over bare soil agricultural fields. *Geosci. Remote Sens. Lett. IEEE* 9, 512–516.
- Baghdadi, N., Cresson, R., Pottier, E., Aubert, M., Zribi, M., Jacome, A., and Benabdallah, S. (2012c). A potential use for the C-band polarimetric SAR parameters to characterize the soil surface over bare agriculture fields. *Geosci. Remote Sens. IEEE Trans. On* 50, 3844–3858.
- Balenzano, A., Mattia, F., Satalino, G., and Davidson, M. (2011). Dense temporal series of C- and L-band SAR data for soil moisture retrieval over agricultural crops. *Sel. Top. Appl. Earth Obs. Remote Sens. IEEE J. Of* 4, 439–450.
- Baret, F., and Guerif, M. (2006a). Remote detection and quantification of plant stress: opportunities remote sensing observations. In *Comparative Biochemistry and Physiology a-Molecular & Integrative Physiology*, (ELSEVIER SCIENCE INC 360 PARK AVE SOUTH, NEW YORK, NY 10010-1710 USA), pp. S148–S148.

Bibliographie

- Baret, F., and Guerif, M. (2006b). Remote detection and quantification of plant stress: opportunities remote sensing observations. *Comp. Biochem. Physiol. -Mol. Integr. Physiol.* 143(4): S148–S148.
- Baret, F., and Guyot, G. (1991). Potentials and limits of vegetation indices for LAI and APAR assessment. *Remote Sens. Environ.* 35, 161–173.
- Baret, F., Hagolle, O., Geiger, B., Bicheron, P., Miras, B., Huc, M., Berthelot, B., Niño, F., Weiss, M., and Samain, O. (2007). LAI, fAPAR and fCover CYCLOPES global products derived from VEGETATION: Part 1: Principles of the algorithm. *Remote Sens. Environ.* 110, 275–286.
- Barnes, E.M., Pinter, P.J., Kimball, B.A., Wall, G.W., LaMorte, R.L., Hunsake, D.J., Adamsen, F., Leavitt, S., Thompson, T., and Mathius, J. (1997). Modification of CERES-Wheat to accept leaf area index as an input variable. In ASAE Annual International Meeting. Paper, pp. 49085–49659.
- Beaudoin, A., Le Toan, T., and Gwyn, Q.H.J. (1990). SAR observations and modeling of the C-band backscatter variability due to multiscale geometry and soil moisture. *Geosci. Remote Sens. IEEE Trans. On* 28, 886–895.
- Bindlish, R., and Barros, A.P. (2001). Parameterization of vegetation backscatter in radar-based, soil moisture estimation. *Remote Sens. Environ.* 76, 130–137.
- Bogh, E., Thorsen, M., Butts, M.B., Hansen, S., Christiansen, J.S., Abrahamsen, P., Hasager, C.B., Jensen, N.O., van der Keur, P., and Refsgaard, J.C. (2004). Incorporating remote sensing data in physically based distributed agro-hydrological modelling. *J. Hydrol.* 287, 279–299.
- Botha, E.J., Leblon, B., ZebARTH, B., and Watmough, J. (2007). Non-destructive estimation of potato leaf chlorophyll from canopy hyperspectral reflectance using the inverted PROSAIL model. *Int. J. Appl. Earth Obs. Geoinformation* 9, 360–374.
- Botha, E.J., Leblon, B., ZebARTH, B.J., and Watmough, J. (2010). Non-destructive estimation of wheat leaf chlorophyll content from hyperspectral measurements through analytical model inversion. *Int. J. Remote Sens.* 31, 1679–1697.
- Botraud, J.C., Bornand, M., and Servat, E. (1984). Mesures de résistivité appliquées à la cartographie en pédologie. *Sci. Sol* 4, 279–294.
- Bouman, B.A.M. (1995). Crop modelling and remote sensing for yield prediction. *NJAS Wagening. J. Life Sci.* 43, 143–161.
- Bouman, B.A.M., Van Diepen, C.A., Vossen, P., and van Der Wal, T. (1997). Simulation and systems analysis tools for crop yield forecasting. In *Applications of Systems Approaches at the Farm and Regional Levels Volume 1*, (Springer), pp. 325–340.
- Brereton, A.J., and Hope-Cawdery, M. (1988). Drumlin soils: the depression of herbage yield by shallow water table depth. *Ir. J. Agric. Res.* 167–178.

Bibliographie

- Brisson, N., King, D., Nicoullaud, B., Ruget, F., Ripoche, D., and Darthout, R. (1992). A crop model for land suitability evaluation a case study of the maize crop in France. *Eur. J. Agron.* *1*, 163–175.
- Brisson, N., Gary, C., Justes, E., Roche, R., Mary, B., Ripoche, D., Zimmer, D., Sierra, J., Bertuzzi, P., and Burger, P. (2003). An overview of the crop model STICS. *Eur. J. Agron.* *18*, 309–332.
- Brown, S.C., Quegan, S., Morrison, K., Bennett, J.C., and Cookmartin, G. (2003). High-resolution measurements of scattering in wheat canopies-Implications for crop parameter retrieval. *Geosci. Remote Sens. IEEE Trans.* *On 41*, 1602–1610.
- Bsaibes, A., Courault, D., Baret, F., Weiss, M., Olioso, A., Jacob, F., Hagolle, O., Marloie, O., Bertrand, N., and Desfond, V. (2009). Albedo and LAI estimates from FORMOSAT-2 data for crop monitoring. *Remote Sens. Environ.* *113*, 716–729.
- Calvet, J.C., Noilhan, J., and Bessemoulin, P. (1998). Retrieving the root-zone soil moisture from surface soil moisture or temperature estimates: A feasibility study based on field measurements. *J. Appl. Meteorol.* *37*, 371–386.
- Carlson, T.N., and Ripley, D.A. (1997). On the relation between NDVI, fractional vegetation cover, and leaf area index. *Remote Sens. Environ.* *62*, 241–252.
- Carlson, T.N., Gillies, R.R., and Perry, E.M. (1994). A method to make use of thermal infrared temperature and NDVI measurements to infer surface soil water content and fractional vegetation cover. *Remote Sens. Rev.* *9*, 161–173.
- Ceballos, A., Scipal, K., Wagner, W., and Martinez-Fernandez, J. (2005). Validation of ERS scatterometer-derived soil moisture data in the central part of the Duero Basin, Spain. *Hydrol. Process.* *19*, 1549–1566.
- Ceccato, P., Flasse, S., Tarantola, S., Jacquemoud, S., and Grégoire, J.-M. (2001). Detecting vegetation leaf water content using reflectance in the optical domain. *Remote Sens. Environ.* *77*, 22–33.
- Chai, S.-S., Walker, J.P., Makarynskyy, O., Kuhn, M., Veenendaal, B., and West, G. (2009). Use of soil moisture variability in artificial neural network retrieval of soil moisture. *Remote Sens.* *2*, 166–190.
- Champion, I. (1991). Etude et mise au point de modèles Semi-empiriques représentant la réponse de couverts végétaux dans le domaine hyperfréquence. Complémentarité avec le domaine optique. Thèse, Université Paris VII. France.
- Champion, I., and Guyot, G. (1991). Generalized formulation for semi-empirical radar models representing crop backscattering. *ESA Phys. Meas. Signat. Remote Sens.* *1*, 269–272.
- Chaumet, J.M., Delpeuch, F., Dorin, B., Ghersi, G., Hubert, B., Le Cotté, T., Paillard, S., Petit, M., Rastoin, J.L., and Ronzon, T. (2009). Agrimonde, Agricultures et alimentations du monde en 2050: Scénarios et défis pour un développement durable. INRA CIRAD 205.

- Chen, D., Huang, J., and Jackson, T.J. (2005). Vegetation water content estimation for corn and soybeans using spectral indices derived from MODIS near-and short-wave infrared bands. *Remote Sens. Environ.* *98*, 225–236.
- Cheviron, B., Albasha, R., Le Priol, C., Dairon, R., and Mailhol, J.C. (2015). A procedure and framework to automate crop models for agricultural yield scenarios and irrigation optimisation: application to the PILOTE model, Submitted to. *Environ. Model. Softw.*
- Choudhury, B.J. (1997). Global pattern of potential evaporation calculated from the Penman-Monteith equation using satellite and assimilated data. *Remote Sens. Environ.* *61*, 64–81.
- Claverie, M., Vermote, E.F., Weiss, M., Baret, F., Hagolle, O., and Demarez, V. (2013). Validation of coarse spatial resolution LAI and FAPAR time series over cropland in southwest France. *Remote Sens. Environ.* *139*, 216–230.
- Coletta, A., Angino, G., Battazza, F., Caltagirone, F., Impagnatiello, F., Valentini, G., Capuzi, A., Fagioli, S., and Leonardi, R. (2007). COSMO-SkyMed program: Utilization and description of an advanced space EO dual-use asset. In Proc. Envisat Symp, pp. 23–27.
- Cookmartin, G., Saich, P., Quegan, S., Cordey, R., Burgess-Allen, P., and Sowter, A. (2000). Modeling microwave interactions with crops and comparison with ERS-2 SAR observations. *Geosci. Remote Sens. IEEE Trans. On* *38*, 658–670.
- Courault, D., Bsaibes, A., Kpemlie, E., Hadria, R., Hagolle, O., Marloie, O., Hanocq, J.-F., Olioso, A., Bertrand, N., and Desfonds, V. (2008). Assessing the potentialities of FORMOSAT-2 data for water and crop monitoring at small regional scale in South-Eastern France. *Sensors* *8*, 3460–3481.
- Courault, D., Hadria, R., Ruget, F., Olioso, A., Duchemin, B., Hagolle, O., and Dedieu, G. (2010). 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.* *7*, 1731–1744.
- Crow, W.T., and Wood, E.F. (2003). The assimilation of remotely sensed soil brightness temperature imagery into a land surface model using ensemble Kalman filtering: A case study based on ESTAR measurements during SGP97. *Adv. Water Resour.* *26*, 137–149.
- Darvishzadeh, R., Skidmore, A., Schlerf, M., and Atzberger, C. (2008a). Inversion of a radiative transfer model for estimating vegetation LAI and chlorophyll in a heterogeneous grassland. *Remote Sens. Environ.* *112*, 2592–2604.
- Darvishzadeh, R., Skidmore, A., Atzberger, C., and van Wieren, S. (2008b). Estimation of vegetation LAI from hyperspectral reflectance data: Effects of soil type and plant architecture. *Int. J. Appl. Earth Obs. Geoinformation* *10*, 358–373.
- Del Frate, F., and Solimini, D. (2004). On neural network algorithms for retrieving forest biomass from SAR data. *Geosci. Remote Sens. IEEE Trans. On* *42*, 24–34.

Bibliographie

- Del Frate, F., Ferrazzoli, P., and Schiavon, G. (2003). Retrieving soil moisture and agricultural variables by microwave radiometry using neural networks. *Remote Sens. Environ.* *84*, 174–183.
- Demarez, V., Duthoit, S., Baret, F., Weiss, M., and Dedieu, G. (2008). Estimation of leaf area and clumping indexes of crops with hemispherical photographs. *Agric. For. Meteorol.* *148*, 644–655.
- De Roo, R.D., Du, Y., Ulaby, F.T., and Dobson, M.C. (2001). A semi-empirical backscattering model at L-band and C-band for a soybean canopy with soil moisture inversion. *Geosci. Remote Sens. IEEE Trans. On* *39*, 864–872.
- Di Bella, C., Faivre, R., Ruget, F., and Seguin, B. (2005). Using VEGETATION satellite data and the crop model STICS-Prairie to estimate pasture production at the national level in France. *Phys. Chem. Earth Parts ABC* *30*, 3–9.
- Doraiswamy, P.C., Sinclair, T.R., Hollinger, S., Akhmedov, B., Stern, A., and Prueger, J. (2005). Application of MODIS derived parameters for regional crop yield assessment. *Remote Sens. Environ.* *97*, 192–202.
- Dubois, P.C., Van Zyl, J., and Engman, T. (1995). Measuring soil moisture with imaging radars. *Geosci. Remote Sens. IEEE Trans. On* *33*, 915–926.
- Duchemin, B., Hadria, R., Erraki, S., Boulet, G., Maisongrande, P., Chehbouni, A., Escadafal, R., Ezzahar, J., Hoedjes, J.C.B., and Kharrou, M.H. (2006). Monitoring wheat phenology and irrigation in Central Morocco: On the use of relationships between evapotranspiration, crops coefficients, leaf area index and remotely-sensed vegetation indices. *Agric. Water Manag.* *79*, 1–27.
- Duchemin, B., Hagolle, O., Mougenot, B., Simonneaux, V., Benhadj, I., Hadria, R., Ezzahar, J., Hoedges, J., Khabba, S., and Kharrou, M.H. (2008). Agrometeorological study of semi-arid areas: an experiment for analysing the potential of FORMOSAT-2 time series of images in the Marrakech plain. *Int J Remote Sens.* *29*, 5291–5300.
- Duveiller, G., Weiss, M., Baret, F., and Defourny, P. (2011). Retrieving wheat Green Area Index during the growing season from optical time series measurements based on neural network radiative transfer inversion. *Remote Sens. Environ.* *115*, 887–896.
- Edirisinghe, A., Hill, M.J., Donald, G.E., and Hyder, M. (2011). Quantitative mapping of pasture biomass using satellite imagery. *Int. J. Remote Sens.* *32*, 2699–2724.
- Eineder, M., Fritz, T., Mittermayer, J., Roth, A., Boerner, E., and Breit, H. (2008). TerraSAR-X Ground Segment, Basic Product Specification Document. (Munich, Germany: DTIC Document, Cluster Applied Remote Sensing. Available online: https://tandemx-science.dlr.de/pdfs/TX-GS-DD-3302_Basic-Products-Specification-Document_V1.6.pdf (accessed on 22 April 2011)).
- El Hajj, M., Bégué, A., Lafrance, B., Hagolle, O., Dedieu, G., and Rumeau, M. (2008). Relative radiometric normalization and atmospheric correction of a SPOT 5 time series. *Sensors* *8*, 2774–2791.

Bibliographie

- El Hajj, M., Baghdadi, N., Belaud, G., Zribi, M., Cheviron, B., Courault, D., Hagolle, O., and Charron, F. (2014). Irrigated grassland monitoring using a time series of terraSAR-X and COSMO-skyMed X-Band SAR Data. *Remote Sens.* *6*, 10002–10032.
- Fensholt, R., Sandholt, I., and Rasmussen, M.S. (2004). Evaluation of MODIS LAI, fAPAR and the relation between fAPAR and NDVI in a semi-arid environment using in situ measurements. *Remote Sens. Environ.* *91*, 490–507.
- Ferrazzoli, P., Paloscia, S., Pampaloni, P., Schiavon, G., Sigismondi, S., and Solimini, D. (1997). The potential of multifrequency polarimetric SAR in assessing agricultural and arboreous biomass. *Geosci. Remote Sens. IEEE Trans. On* *35*, 5–17.
- Ferreira, L.G., Fernandez, L.E., Sano, E.E., Field, C., Sousa, S.B., Arantes, A.E., and Araújo, F.M. (2013). Biophysical properties of cultivated pastures in the Brazilian savanna biome: An analysis in the spatial-temporal domains based on ground and satellite data. *Remote Sens.* *5*, 307–326.
- Fieuza, R., Duchemin, B., Jarlan, L., Zribi, M., Baup, F., Merlin, O., Hagolle, O., and Garatuza-Payan, J. (2011). Combined use of optical and radar satellite data for the monitoring of irrigation and soil moisture of wheat crops. *Hydrol. Earth Syst. Sci.* *15*, 1117–1129.
- Fieuza, R., Baup, F., and Marais-Sicre, C. (2013). Monitoring Wheat and Rapeseed by Using Synchronous Optical and Radar Satellite Data—From Temporal Signatures to Crop Parameters Estimation. *Adv. Remote Sens.* *2*, 162.
- Fontanelli, G., Paloscia, S., Zribi, M., and Chahbi, A. (2013). Sensitivity analysis of X-band SAR to wheat and barley leaf area index in the Merguellil Basin. *Remote Sens. Lett.* *4*, 1107–1116.
- Fung, A.K., Li, Z., and Chen, K.S. (1992). Backscattering from a randomly rough dielectric surface. *Geosci. Remote Sens. IEEE Trans. On* *30*, 356–369.
- Gao, B.-C. (1996). NDWI—a normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sens. Environ.* *58*, 257–266.
- Gao, S., Niu, Z., Huang, N., and Hou, X. (2013). Estimating the Leaf Area Index, height and biomass of maize using HJ-1 and RADARSAT-2. *Int. J. Appl. Earth Obs. Geoinformation* *24*, 1–8.
- Gherboudj, I., Magagi, R., Berg, A.A., and Toth, B. (2011). Soil moisture retrieval over agricultural fields from multi-polarized and multi-angular RADARSAT-2 SAR data. *Remote Sens. Environ.* *115*, 33–43.
- Goel, N.S., and Strelbel, D.E. (1983). Inversion of vegetation canopy reflectance models for estimating agronomic variables. I. Problem definition and initial results using the Suits model. *Remote Sens. Environ.* *13*, 487–507.
- Gorrab, A., Zribi, M., Baghdadi, N., Mougenot, B., and Chabaane, Z.L. (2015). Potential of X-Band TerraSAR-X and COSMO-SkyMed SAR Data for the Assessment of Physical Soil Parameters. *Remote Sens.* *7*, 747–766.

- Gu, Y., Brown, J.F., Verdin, J.P., and Wardlow, B. (2007). A five-year analysis of MODIS NDVI and NDWI for grassland drought assessment over the central Great Plains of the United States. *Geophys. Res. Lett.* *34*.
- Guerif, M., and Duke, C.L. (2000). Adjustment procedures of a crop model to the site specific characteristics of soil and crop using remote sensing data assimilation. *Agric. Ecosyst. Environ.* *81*, 57–69.
- Guerschman, J.P., Hill, M.J., Renzullo, L.J., Barrett, D.J., Marks, A.S., and Botha, E.J. (2009). Estimating fractional cover of photosynthetic vegetation, non-photosynthetic vegetation and bare soil in the Australian tropical savanna region upscaling the EO-1 Hyperion and MODIS sensors. *Remote Sens. Environ.* *113*, 928–945.
- Hadria, R., Duchemin, B., Baup, F., Le Toan, T., Bouvet, A., Dedieu, G., and Le Page, M. (2009). Combined use of optical and radar satellite data for the detection of tillage and irrigation operations: Case study in Central Morocco. *Agric. Water Manag.* *96*, 1120–1127.
- Hagolle, O., Dedieu, G., Mougenot, B., Debaecker, V., Duchemin, B., and Meygret, A. (2008). Correction of aerosol effects on multi-temporal images acquired with constant viewing angles: Application to Formosat-2 images. *Remote Sens. Environ.* *112*, 1689–1701.
- Hajj, M. El, Bégué, A., Guillaume, S., and Martiné, J.-F. (2009). Integrating SPOT-5 time series, crop growth modeling and expert knowledge for monitoring agricultural practices—The case of sugarcane harvest on Reunion Island. *Remote Sens. Environ.* *113*, 2052–2061.
- He, B., Xing, M., and Bai, X. (2014). A Synergistic Methodology for Soil Moisture Estimation in an Alpine Prairie Using Radar and Optical Satellite Data. *Remote Sens.* *6*, 10966–10985.
- Hegarat-Mascle, L., Zribi, M., Alem, F., Weisse, A., and Loumagne, C. (2002). Soil moisture estimation from ERS/SAR data: Toward an operational methodology. *Geosci. Remote Sens. IEEE Trans. On* *40*, 2647–2658.
- Hong, S. (2014). Optimisation des tours d'eau sur un réseau de canaux d'irrigation. Thèse. SupAgro-SIBAGHE.
- Hong, S., Malaterre, P.-O., Belaud, G., and Dejean, C. (2013). Optimization of water distribution for open-channel irrigation networks. Press J. Hydroinformatics.
- Hosseini, M., and Saradjian, M.R. (2011). Soil moisture estimation based on integration of optical and SAR images. *Can. J. Remote Sens.* *37*, 112–121.
- Ines, A.V., Das, N.N., Hansen, J.W., and Njoku, E.G. (2013). Assimilation of remotely sensed soil moisture and vegetation with a crop simulation model for maize yield prediction. *Remote Sens. Environ.* *138*, 149–164.
- Inoue, Y., Kurosu, T., Maeno, H., Uratsuka, S., Kozu, T., Dabrowska-Zielinska, K., and Qi, J. (2002). Season-long daily measurements of multifrequency (Ka, Ku, X, C, and L) and full-polarization backscatter signatures over paddy rice field and their relationship with biological variables. *Remote Sens. Environ.* *81*, 194–204.

- Iorio, M., Mecozzi, R., and Torre, A. (2010). Cosmo SkyMed: antenna elevation pattern data evaluation. *Ital. J Remote Sens* 42, 69–77.
- Irmak, A., and Kamble, B. (2009). Evapotranspiration data assimilation with genetic algorithms and SWAP model for on-demand irrigation. *Irrig. Sci.* 28, 101–112.
- Jackson, T.J., Chen, D., Cosh, M., Li, F., Anderson, M., Walthall, C., Doriaswamy, P., and Hunt, E. (2004). Vegetation water content mapping using Landsat data derived normalized difference water index for corn and soybeans. *Remote Sens. Environ.* 92, 475–482.
- Jackson, T.J., Bindlish, R., Cosh, M.H., Zhao, T., Starks, P.J., Bosch, D.D., Seyfried, M., Moran, M.S., Goodrich, D.C., and Kerr, Y.H. (2012). Validation of soil moisture and ocean salinity (SMOS) soil moisture over watershed networks in the US. *Geosci. Remote Sens. IEEE Trans. On* 50, 1530–1543.
- Jones, J.W., Hoogenboom, G., Porter, C.H., Boote, K.J., Batchelor, W.D., Hunt, L.A., Wilkens, P.W., Singh, U., Gijsman, A.J., and Ritchie, J.T. (2003). The DSSAT cropping system model. *Eur. J. Agron.* 18, 235–265.
- Kamble, B., Irmak, A., Hubbard, K., and Gowda, P. (2013). Irrigation scheduling using remote sensing data assimilation approach. *Adv. Remote Sens.* 2, 258.
- Kerr, Y.H., Waldteufel, P., Wigneron, J.-P., Martinuzzi, J.-M., Font, J., and Berger, M. (2001). Soil moisture retrieval from space: The Soil Moisture and Ocean Salinity (SMOS) mission. *Geosci. Remote Sens. IEEE Trans. On* 39, 1729–1735.
- Kseneman, M., Gleich, D., and Potočnik, B. (2012). Soil-moisture estimation from TerraSAR-X data using neural networks. *Mach. Vis. Appl.* 23, 937–952.
- Launay, M., and Guerif, M. (2005). Assimilating remote sensing data into a crop model to improve predictive performance for spatial applications. *Agric. Ecosyst. Environ.* 111, 321–339.
- Lebourgeois, V., Begue, A., Degenne, P., and Bappel, E. (2010). Improving harvest and planting monitoring for smallholders with geospatial technology: the Reunion Island experience. *Int. Sugar J.* 109, 109–119.
- Leenhardt, D., Trouvat, J.-L., Gonzalès, G., Pérarnaud, V., Prats, S., and Bergez, J.-E. (2004). Estimating irrigation demand for water management on a regional scale: I. ADEAUMIS, a simulation platform based on bio-decisional modelling and spatial information. *Agric. Water Manag.* 68, 207–232.
- Li, F., Chen, W., Zeng, Y., Zhao, Q., and Wu, B. (2014). Improving Estimates of Grassland Fractional Vegetation Cover Based on a Pixel Dichotomy Model: A Case Study in Inner Mongolia, China. *Remote Sens.* 6, 4705–4722.
- Lievens, H., Vernieuwe, H., Alvarez-Mozos, J., De Baets, B., and Verhoest, N.E. (2009). Error in radar-derived soil moisture due to roughness parameterization: an analysis based on synthetical surface profiles. *Sensors* 9, 1067–1093.

Bibliographie

- Lin, H., Chen, J., Pei, Z., Zhang, S., and Hu, X. (2009). Monitoring sugarcane growth using ENVISAT ASAR data. *Geosci. Remote Sens. IEEE Trans.* On 47, 2572–2580.
- Liu, C., Shang, J., Vachon, P.W., and McNairn, H. (2013). Multiyear crop monitoring using polarimetric RADARSAT-2 data. *Geosci. Remote Sens. IEEE Trans.* On 51, 2227–2240.
- Ma, G., Huang, J., Wu, W., Fan, J., Zou, J., and Wu, S. (2013). Assimilation of MODIS-LAI into the WOFOST model for forecasting regional winter wheat yield. *Math. Comput. Model.* 58, 634–643.
- Maas, S.J. (1988). Using satellite data to improve model estimates of crop yield. *Agron. J.* 80, 655–662.
- Macelloni, G., Paloscia, S., Pampaloni, P., Marliani, F., and Gai, M. (2001). The relationship between the backscattering coefficient and the biomass of narrow and broad leaf crops. *Geosci. Remote Sens. IEEE Trans.* On 39, 873–884.
- Mailhol, J.C., and Merot, A. (2008). SPFC: a tool to improve water management and hay production in the Crau region. *Irrig. Sci.* 26, 289–302.
- Mailhol, J.C., Olufayo, O., and Ruelle, P. (1997). AET and yields assessments based on the LAI simulation. Application to sorghum and sunflower crops. *Agric Water Manag* 35, 167–182.
- Mailhol, J.C., Ruelle, P., Walser, S., Schütze, N., and Dejean, C. (2011). Analysis of AET and yield predictions under surface and buried drip irrigation systems using the Crop Model PILOTE and Hydrus-2D. *Agric. Water Manag.* 98, 1033–1044.
- Manning, D.A. (2015). How will minerals feed the world in 2050? *Proc. Geol. Assoc.* 126, 14–17.
- Marquardt, D.W. (1963). An algorithm for least-squares estimation of nonlinear parameters. *J. Soc. Ind. Appl. Math.* 11, 431–441.
- Masek, J.G., Vermote, E.F., Saleous, N., Wolfe, R., Hall, F.G., Huemmrich, F., Gao, F., Kutler, J., and Lim, T.K. (2013). LEDAPS calibration, reflectance, atmospheric correction preprocessing code, version 2. Model Prod.
- Mattia, F., Le Toan, T., Picard, G., Posa, F.I., D'Alessio, A., Notarnicola, C., Gatti, A.M., Rinaldi, M., Satalino, G., and Pasquariello, G. (2003). Multitemporal C-band radar measurements on wheat fields. *Geosci. Remote Sens. IEEE Trans.* On 41, 1551–1560.
- Mérot, A. (2007). Analyse et modélisation du fonctionnement biophysique et décisionnel d'un système prairial irrigué-Application aux prairies plurispécifiques de Crau en vue de l'élaboration d'un Outil d'Aide à la Décision. Thèse, Ecole nationale supérieure agronomique de montpellier-AGRO M. France.
- Merot, A., Bergez, J.E., Wallach, D., and Duru, M. (2008a). Adaptation of a functional model of grassland to simulate the behaviour of irrigated grasslands under a Mediterranean climate: The Crau case. *Eur. J. Agron.* 29, 163–174.

- Merot, A., Wery, J., Isberie, C., and Charron, F. (2008b). Response of a plurispecific permanent grassland to border irrigation regulated by tensiometers. *Eur. J. Agron.* *28*, 8–18.
- Montzka, C., Moradkhani, H., Weihermüller, L., Franssen, H.-J.H., Canty, M., and Vereecken, H. (2011). Hydraulic parameter estimation by remotely-sensed top soil moisture observations with the particle filter. *J. Hydrol.* *399*, 410–421.
- North, P.R. (2002). Estimation of FAPAR, LAI, and vegetation fractional cover from ATSR-2 imagery. *Remote Sens. Environ.* *80*, 114–121.
- Notarnicola, C., Angiulli, M., and Posa, F. (2006). Use of radar and optical remotely sensed data for soil moisture retrieval over vegetated areas. *Geosci. Remote Sens. IEEE Trans.* On *44*, 925–935.
- Oh, Y. (2004). Quantitative retrieval of soil moisture content and surface roughness from multipolarized radar observations of bare soil surfaces. *Geosci. Remote Sens. IEEE Trans.* On *42*, 596–601.
- Oh, Y., and Kay, Y.C. (1998). Condition for precise measurement of soil surface roughness. *Geosci. Remote Sens. IEEE Trans.* On *36*, 691–695.
- Oh, Y., Sarabandi, K., and Ulaby, F.T. (1992). An empirical model and an inversion technique for radar scattering from bare soil surfaces. *Geosci. Remote Sens. IEEE Trans.* On *30*, 370–381.
- Oteng-Darko, P., Yeboah, S., Addy, S.N.T., Amponsah, S., and Danquah, E.O. (2013). Crop modeling: a tool for agricultural research—a review. *J Agric Res Dev* *2*, 1–6.
- Paloscia, S., Pampaloni, P., Pettinato, S., and Santi, E. (2008). A comparison of algorithms for retrieving soil moisture from ENVISAT/ASAR images. *Geosci. Remote Sens. IEEE Trans.* On *46*, 3274–3284.
- Paloscia, S., Pettinato, S., and Santi, E. (2012). Combining L and X band SAR data for estimating biomass and soil moisture of agricultural fields. *Eur. J. Remote Sens.* *45*.
- Paloscia, S., Pettinato, S., Santi, E., Notarnicola, C., Pasolli, L., and Reppucci, A. (2013). Soil moisture mapping using Sentinel-1 images: Algorithm and preliminary validation. *Remote Sens. Environ.* *134*, 234–248.
- Paris, J.F. (1986). The effect of leaf size on the microwave backscattering by corn. *Remote Sens. Environ.* *19*, 81–95.
- Paris Anguela, T., Zribi, M., Hasenauer, S., Habets, F., and Loumagne, C. (2008). 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* *12*, 1415–1424.
- Parry, M.L. (2007). Climate Change 2007: impacts, adaptation and vulnerability: contribution of Working Group II to the fourth assessment report of the Intergovernmental Panel on Climate Change (Cambridge University Press).

Bibliographie

- Patel, P., and Srivastava, H.S. (2013). Ground truth planning for synthetic aperture radar (SAR): addressing various challenges using statistical approach. *Int. J. Adv. Remote Sens. GIS Geogr.* *1*, 1–17.
- Payero, J.O., Neale, C.M.U., and Wright, J.L. (2004). Comparison of eleven vegetation indices for estimating plant height of alfalfa and grass. *Appl. Eng. Agric.* *20*, 385–393.
- Peake, W.H. (1959). Interaction of electromagnetic waves with some natural surfaces. *Antennas Propag. IRE Trans. On* *7*, 324–329.
- Picard, G., Le Toan, T., and Mattia, F. (2003). Understanding C-band radar backscatter from wheat canopy using a multiple-scattering coherent model. *Geosci. Remote Sens. IEEE Trans. On* *41*, 1583–1591.
- Pickett-Heaps, C.A., Canadell, J.G., Briggs, P.R., Gobron, N., Haverd, V., Paget, M.J., Pinty, B., and Raupach, M.R. (2014). Evaluation of six satellite-derived Fraction of Absorbed Photosynthetic Active Radiation (FAPAR) products across the Australian continent. *Remote Sens. Environ.* *140*, 241–256.
- Pogačar, T., and Kajfez-Bogataj, L. (2009). WOFOST: crop growth simulation model-1st part. *Acta Agric. Slov.* *93*, 231–243.
- Ponnurangam, G.G., and Rao, Y.S. (2011). Soil moisture mapping using ALOS PALSAR and ENVISAT ASAR data over India. *Synth. Aperture Radar APSAR 2011 3rd Int. Asia-Pac. Conf. On* *1–4*.
- Prakash, R., Singh, D., and Pathak, N.P. (2012). A fusion approach to retrieve soil moisture with SAR and optical data. *Sel. Top. Appl. Earth Obs. Remote Sens. IEEE J. Of* *5*, 196–206.
- Prévet, L., Champion, I., and 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 Sens. Environ.* *46*, 331–339.
- Prevot, L., Champion, I., and 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 Sens. Environ.* *46*, 331–339.
- Prévet, L., Chauki, H., Troufleau, D., Weiss, M., Baret, F., and Brisson, N. (2003). Assimilating optical and radar data into the STICS crop model for wheat. *Agronomie* *23*, 297–303.
- Quesney, A., Le Hégarat-Mascle, S., Taconet, O., Vidal-Madjar, D., Wigneron, J.P., Loumagne, C., and Normand, M. (2000). Estimation of watershed soil moisture index from ERS/SAR data. *Remote Sens. Environ.* *72*, 290–303.
- Rahman, H., and Dedieu, G. (1994). SMAC: a simplified method for the atmospheric correction of satellite measurements in the solar spectrum. *Int. J. Remote Sens.* *15*, 123–143.
- Rakotoarivony, L. (1995). Validation de modèles de diffusion électromagnétique: Comparaison entre simulations et mesures radar héliporté sur des surfaces agricoles de sol nu.

Bibliographie

- Ritchie, J.R., and Otter, S. (1985). Description and performance of CERES-Wheat: a user-oriented wheat yield model. ARS-U. S. Dep. Agric. Agric. Res. Serv. USA.
- Saastamoinen, J. (1972). Atmospheric correction for the troposphere and stratosphere in radio ranging satellites. *Use Artif. Satell. Geod.* 247–251.
- Said, S., Kothyari, U.C., and Arora, M.K. (2012). Vegetation effects on soil moisture estimation from ERS-2 SAR images. *Hydrol. Sci. J.* 57, 517–534.
- Santi, E., Paloscia, S., Pettinato, S., Notarnicola, C., Pasolli, L., and Pistocchi, A. (2013a). Comparison between SAR soil moisture estimates and hydrological model simulations over the Scrivia test site. *Remote Sens.* 5, 4961–4976.
- Santi, E., Paloscia, S., Pettinato, S., Notarnicola, C., Pasolli, L., and Pistocchi, A. (2013b). Comparison between SAR soil moisture estimates and hydrological model simulations over the Scrivia test site. *Remote Sens.* 5, 4961–4976.
- Schino, G., Borfecchia, F., De Cecco, L., Dibari, C., Iannetta, M., Martini, S., and Pedrotti, F. (2003). Satellite estimate of grass biomass in a mountainous range in central Italy. *Agrofor. Syst.* 59, 157–162.
- Schwerdt, M., Bräutigam, B., Bachmann, M., and Döring, B. (2008). TerraSAR-X calibration results. In *Synthetic Aperture Radar (EUSAR), 2008 7th European Conference on*, (Graf-Zeppelin-Haus, Friedrichshafen, Germany: VDE), pp. 1–4.
- Serrano, L., Ustin, S.L., Roberts, D.A., Gamon, J.A., and Penuelas, J. (2000). Deriving water content of chaparral vegetation from AVIRIS data. *Remote Sens. Environ.* 74, 570–581.
- Shi, J., Wang, J., Hsu, A.Y., O'Neill, P.E., and Engman, E.T. (1997). Estimation of bare surface soil moisture and surface roughness parameter using L-band SAR image data. *Geosci. Remote Sens. IEEE Trans. On* 35, 1254–1266.
- Sikdar, M., and Cumming, I. (2004). A modified empirical model for soil moisture estimation in vegetated areas using SAR data. In *Geoscience and Remote Sensing Symposium, 2004. IGARSS'04. Proceedings. 2004 IEEE International*, (Anchorage, AK: IEEE), pp. 803–806.
- Simoniello, T., Cuomo, V., Lanfredi, M., Lasaponara, R., and Macchiato, M. (2004). On the relevance of accurate correction and validation procedures in the analysis of AVHRR-NDVI time series for long-term monitoring. *J. Geophys. Res. Atmospheres* 1984–2012 109.
- Singh, D. (2005). A simplistic incidence angle approach to retrieve the soil moisture and surface roughness at X-band. *Geosci. Remote Sens. IEEE Trans. On* 43, 2606–2611.
- Sonobe, R., Tani, H., Wang, X., and Fukuda, M. (2008). Estimation of Soil Moisture for Bare Soil Fields Using ALOS/PALSAR HH Polarization Data. *Agric. Inf. Res.* 17, 171–177.
- SooBum Kim, Byungwook Kim, YoungKyun Kong, and Young-Soo Kim (2000). Radar backscattering measurements of rice crop using X-band scatterometer. *Geosci. Remote Sens. IEEE Trans. On* 38, 1467–1471.

- Soon-Koo Kweon, Ji-Hwan Hwang, and Yisok Oh (2012). COSMO SkyMed AO projects - soil moisture detection for vegetation fields based on a modified water-cloud model using COSMO-SkyMed SAR data. *Geosci. Remote Sens. Symp. IGARSS Munich Ger. 2012 IEEE Int.* 1204–1207.
- Srivastava, H.S., Patel, P., Manchanda, M.L., and Adiga, S. (2003). Use of multiincidence angle RADARSAT-1 SAR data to incorporate the effect of surface roughness in soil moisture estimation. *IEEE Trans. Geosci. Remote Sens.* *41*, 1638–1640.
- Srivastava, H.S., Patel, P., Prasad, S.N., Sharma, Y., Khan, B.A., Praveen, B., Prasad, K.C.A., Sharma, S., Vijayan, L., and Vijayan, V.S. (2008). Potential applications of multi-parametric synthetic aperture radar (SAR) data in wetland inventory: a case study of Keoladeo National Park (A World Heritage and Ramsar site), Bharatpur, India. *Proc. Taal* 1862–1879.
- Srivastava, H.S., Patel, P., Sharma, Y., and Navalgund, R.R. (2009). Large-area soil moisture estimation using multi-incidence-angle RADARSAT-1 SAR data. *Geosci. Remote Sens. IEEE Trans. On* *47*, 2528–2535.
- Srivastava, H.S., Patel, P., Sharma, K.P., Krishnamurthy, Y.V.N., and Dadhwala, V.K. (2011). A semi-empirical modelling approach to calculate two-way attenuation in radar backscatter from soil due to crop cover. *Curr. Sci.* *100*, 1871–1874.
- Taconet, O., Benallegue, M., Vidal-Madjar, D., Prevot, L., Dechambre, M., and Normand, M. (1994). Estimation of soil and crop parameters for wheat from airborne radar backscattering data in C and X bands. *Remote Sens. Environ.* *50*, 287–294.
- Thorp, K.R., Hunsaker, D.J., and French, A.N. (2010). Assimilating leaf area index estimates from remote sensing into the simulations of a cropping systems model. *Trans. ASAE Am. Soc. Agric. Eng.* *53*, 251.
- Todd, S.W., Hoffer, R.M., and Milchunas, D.G. (1998). Biomass estimation on grazed and ungrazed rangelands using spectral indices. *Int. J. Remote Sens.* *19*, 427–438.
- Torre, A., Calabrese, D., and Porfilio, M. (2011). COSMO-SkyMed: Image quality achievements. In *Recent Advances in Space Technologies (RAST)*, 2011 5th International Conference on, (Istanbul, Turkey: IEEE), pp. 861–864.
- Ulaby, F.T., Bush, T.F., and Batlivala, P.P. (1975). Radar response to vegetation II: 8-18 GHz band. *Antennas Propag. IEEE Trans. On* *23*, 608–618.
- Ulaby, F.T., Moore, R.K., and Fung, A.K. (1982). *Microwave Remote Sensing Active and Passive-Volume II: Radar Remote Sensing and Surface Scattering and Emission Theory*.
- Ulaby, F.T., Allen, C.T., Eger Iii, G., and Kanemasu, E. (1984). Relating the microwave backscattering coefficient to leaf area index. *Remote Sens. Environ.* *14*, 113–133.
- Ulaby, F.T., Moore, R.K., and Fung, A.K. (1986). *Microwave Remote Sensing: Active and Passive, vol. III, Volume Scattering and Emission Theory, Advanced Systems and Applications*. Inc Dedham Mass. USA Norwood Mass. Artech House 1797–1848.

Bibliographie

- Ulaby, F.T., Sarabandi, K., McDonald, K., Whitt, M., and Dobson, M.C. (1990). Michigan microwave canopy scattering model. *Int. J. Remote Sens.* *11*, 1223–1253.
- Vazifedoust, M., Van Dam, J.C., Bastiaanssen, W.G.M., and Feddes, R.A. (2009). Assimilation of satellite data into agrohydrological models to improve crop yield forecasts. *Int. J. Remote Sens.* *30*, 2523–2545.
- Vermote, E.F., El Saleous, N.Z., and Justice, C.O. (2002). Atmospheric correction of MODIS data in the visible to middle infrared: first results. *Remote Sens. Environ.* *83*, 97–111.
- Verstraeten, W.W., Veroustraete, F., van der Sande, C.J., Grootaers, I., and Feyen, J. (2006). Soil moisture retrieval using thermal inertia, determined with visible and thermal spaceborne data, validated for European forests. *Remote Sens. Environ.* *101*, 299–314.
- Wagner, W., Noll, J., Borgeaud, M., and Rott, H. (1999). Monitoring soil moisture over the Canadian prairies with the ERS scatterometer. *Geosci. Remote Sens. IEEE Trans. On* *37*, 206–216.
- Wang, S.G., Li, X., Han, X.J., and Jin, R. (2011). Estimation of surface soil moisture and roughness from multi-angular ASAR imagery in the Watershed Allied Telemetry Experimental Research (WATER). *Hydrol. Earth Syst. Sci.* *15*, 1415–1426.
- Weir, A.H., Bragg, P.L., Porter, J.R., and Rayner, J.H. (1984). A winter wheat crop simulation model without water or nutrient limitations. *J. Agric. Sci.* *102*, 371–382.
- Weiss, M., and Baret, F. (1999). Evaluation of canopy biophysical variable retrieval performances from the accumulation of large swath satellite data. *Remote Sens. Environ.* *70*, 293–306.
- Weiss, M., Baret, F., Smith, G.J., Jonckheere, I., and Coppin, P. (2004). Review of methods for in situ leaf area index (LAI) determination: Part II. Estimation of LAI, errors and sampling. *Agric. For. Meteorol.* *121*, 37–53.
- Wigneron, J.-P., Chanzy, A., Calvet, J.-C., and Bruguier, N. (1995). A simple algorithm to retrieve soil moisture and vegetation biomass using passive microwave measurements over crop fields. *Remote Sens. Environ.* *51*, 331–341.
- Wigneron, J.-P., Ferrazzoli, P., Olioso, A., Bertuzzi, P., and Chanzy, A. (1999). A simple approach to monitor crop biomass from C-band radar data. *Remote Sens. Environ.* *69*, 179–188.
- Wigneron, J.-P., Fouilhoux, M., Prévot, L., Chanzy, A., Olioso, A., Baghdadi, N., and King, C. (2002). Monitoring sunflower crop development from C-band radar observations. *Agron.-Sci. Prod. Veg. Environ.* *22*, 587–596.
- Wright, J. (1990). Irrigation water management considerations for sandy soils in Minnesota. Minn. Ext. Serv. Folders USA.
- Yang, Y., and Ling, P.P. (2004). Improved model inversion procedure for plant water status assessment under artificial lighting using PROSPECT+ SAIL. *Trans. ASAE* *47*, 1833–1840.

Bibliographie

- Yang, G., Shi, Y., Zhao, C., and Wang, J. (2012). Estimation of soil moisture from multi-polarized SAR data over wheat coverage areas. In Agro-Geoinformatics (Agro-Geoinformatics), 2012 First International Conference on, (Shanghai, China: IEEE), pp. 1–5.
- Yu, F., and Zhao, Y. (2011). A new semi-empirical model for soil moisture content retrieval by ASAR and TM data in vegetation-covered areas. *Sci. China Earth Sci.* *54*, 1955–1964.
- Zribi, M., and Dechambre, M. (2003a). A new empirical model to retrieve soil moisture and roughness from C-band radar data. *Remote Sens. Environ.* *84*, 42–52.
- Zribi, M., and Dechambre, M. (2003b). A new empirical model to retrieve soil moisture and roughness from C-band radar data. *Remote Sens. Environ.* *84*, 42–52.
- Zribi, M., Baghdadi, N., Holah, N., and Fafin, O. (2005). New methodology for soil surface moisture estimation and its application to ENVISAT-ASAR multi-incidence data inversion. *Remote Sens. Environ.* *96*, 485–496.
- Zribi, M., Saux-Picart, S., André, C., Descroix, L., Ottle, C., and Kallel, A. (2007). Soil moisture mapping based on ASAR/ENVISAT radar data over a Sahelian region. *Int. J. Remote Sens.* *28*, 3547–3565.
- Zribi, M., Chahbi, A., Shabou, M., Lili-Chabaane, Z., Duchemin, B., Baghdadi, N., Amri, R., and Chehbouni, A. (2011). Soil surface moisture estimation over a semi-arid region using ENVISAT ASAR radar data for soil evaporation evaluation. *Hydrol. Earth Syst. Sci.* *15*.