

DÉDICACE

Je dédie ce travail :

A la mémoire de mes grands-parents

Dadda, You Aicha, Ba Boujemaa, Maaziza, rien ne peut exprimer mes sentiments vers vous et rien ne peut décrire combien vous m'avez manqué. Vos soutiens, vos encouragements, vos conseils, vos sacrifices et toutes vos paroles vont toujours rester dans mon cœur.

A mes parents, à mon frère, à ma grande mère, à ma femme, à ma sœur, et à mes enfants.

Je vous remercie pour tous vos encouragements, vos conseils, vos efforts, vos sacrifices, vos soutiens, ainsi que toute aide que vous m'avez apporté pour l'accomplissement de cette thèse. Je vous souhaite toujours la bonne santé et la longévité.

Que Dieu vous protège.

A toute ma famille, Ouzemou, Tahri et Khelfaoui. A toutes les personnes qui m'ont supporté tout au long de mon parcours scolaire et universitaire.

REMERCIEMENT

À l'issue de la rédaction de cette thèse, je souhaite exprimer ici toute ma gratitude à celles et ceux qui, de près ou de loin, ont contribué à l'aboutissement de ce travail.

En premier lieu, je tiens à remercier profondément mon directeur de thèse, Mr. Abderrazak El Harti, Professeur à la Faculté des Sciences et Techniques de Béni Mellal (FSTBM), pour sa confiance en moi, son sérieux, son effort, ses conseils, ses remarques, ses encouragements, ainsi que sa disponibilité dont il a fait toujours preuve durant la thèse.

Je remercie également le CNRST (Centre National de la Recherche Scientifique et Techniques, Rabat) pour avoir financé mes recherches pour trois années.

Je tiens à exprimer ma reconnaissance à Monsieur El Mostafa Bachaoui, Professeur à la FST de Béni Mellal et notre Directeur d'Équipe. Je le remercie pour sa disponibilité, ses conseils, son soutien et l'aide qu'il m'a apporté durant toute la réalisation de cette thèse.

Je remercie aussi très sincèrement les responsables et les agents de SUTA/COSUMAR, pour m'avoir fourni les données dont on avait besoin, et également pour leurs accompagnements sur le terrain et leur encadrement appréciable dans tout ce qui est agronomique.

Je tiens à remercier tout particulièrement Messieurs Saaf Mohamed, Amdiaz Rachid, responsables à l'Office Régionale de la Mise en Valeur Agricole de Tadla, pour leurs soutiens constants, leurs encouragements et leurs conseils.

Mes remerciements les plus chaleureux à tous les membres de l'équipe ETS, c'est grâce à vous que cette thèse restera un beau et un bon souvenir. Alors un grand merci à vous tous : Rachid LHISSOU, Jaouad El HACHIMI, Zakaria ADIRI, Amine JELLOULI, Mohcine CHAKOURI, Najat KNOUZ, Hicham BOUZEKRAOUI, Zineb SAQARRA et Youssef LEBRINI.

Merci à toutes et à tous ceux avec qui j'ai travaillé, ou j'ai croisé en congrès ou ailleurs et qui se sont intéressés à mon travail. Vous m'avez beaucoup apporté.

Finalement, j'adresse un remerciement spécial et j'exprime ma profonde reconnaissance à ma famille, en particulier mes chers parents, ma femme, mon frère et ma sœur qui m'ont supporté et qui me supportent toujours. Que Dieu les récompense.

AVANT-PROPOS

FICHE DE THÈSE

Auteur de la Thèse	OUZEMOU Jamal-eddine
Email/site web	j.ouzemou@usms.ma
Intitulé de la Thèse	Apport de la Télédétection Optique et Radar pour le suivi et la cartographie des cultures : Cas du périmètre irrigué de TADLA
Directeur de Thèse	Pr. Abderrazak El Harti, PES, FST Béni Mellal
Lieu de réalisation du travail	Equipe de Télédétection et SIG appliqués aux Géosciences et à l'Environnement, FST- Béni Mellal, B.P. 523, MAROC.

LISTE DES PUBLICATIONS

ARTICLES & COMITE DE LECTURE :

[1] Jaouad El Hachimi, Abderrazak El Harti, **Jamal-Eddine Ouzemou**, Rachid Lhissou, Chakouri Mouhcine et Amine Jellouli. (2021). Assessment of the benefit of a single sentinel-2 satellite image to small crop parcels mapping. Geocarto International, 1-17.

[2] **Jamal-Eddine Ouzemou**, Abderrazak El Harti, Jaouad El Hachimi, Rachid Lhissou, Ali El Moujahid, Naima Bouch, Rabii El Ouazzani, El Mostafa Bachaoui, Abderrahmene El Ghmari. (2019). *Growth monitoring and mapping to assess and improve sugar beet status using Sentinel-2A and Landsat-8 satellite imagery. Remote Sensing Applications: Society and Environment. (Soumi)*

[3] **Ouzemou, J. E.**, El Harti, A., Lhissou, R., El Moujahid, A., Bouch, N., El Ouazzani, R., ... & El Ghmari, A. (2018). *Crop type mapping from pansharpened Landsat 8 NDVI data: A case of a highly fragmented and intensive agricultural system. Remote Sensing Applications: Society and Environment, 11, 94-103.* <https://doi.org/10.1016/j.rsase.2018.05.002>

[4] Abderrazak El Harti, Rachid Lhissou, Karem Chokmani, **Jamal-eddine Ouzemou**, Mohamed Hassouna, El Mostafa Bachaoui, Abderrahmene El Ghmari. 2016.

Spatiotemporal monitoring of soil salinization in irrigated Tadla Plain (Morocco) using satellite spectral indices. *International Journal of Applied Earth Observation and Geoinformation*, Volume 50, August 2016, Pages 64-73. doi: <http://dx.doi.org/10.1016/j.jag.2016.03.008>.

[5] **Jamal-eddine Ouzemou** ; Abderrazak El Harti ; Ali EL Moujahid ; Naima Bouch ; Rabii El Ouazzani ; Rachid Lhissou ; El Mostafa Bachaoui; **Mapping crop based on phenological characteristics using time-series NDVI of operational land imager data in Tadla irrigated perimeter, Morocco.** *Proc. SPIE 9637, Remote Sensing for Agriculture, Ecosystems, and Hydrology XVII*, 96372G (October 14, 2015); <http://doi:10.1117/12.2194466>.

COMMUNICATIONS :

[1] **Jamal-Eddine Ouzemou**, Abderrazak El Harti, Jaouad El Hachimi. **Synergetic Analysis of Radar and Optical Data for Early Sugar Beet Mapping.** *The 1st International Congress SUSTAINABLE AGRICULTURE: TOOLS AND INNOVATIONS «AgriNov2021»*, Faculty of Sciences and Technics- USMS, Beni Mellal, Morocco, on 27-30th October 2021.

[2] Jaouad El Hachimi, Abderrazak El Harti, **Jamal-Eddine Ouzemou**, Mohcine Chakouri. (2020), **Assessment of the benefit of a single sentinel-2 satellite image to small crop parcels mapping.** *5th Edition of Scientific English Day Webinar*

[3] Abderrazak El Harti, Jaouad El Hachimi, **Jamal-Eddine Ouzemou**, El Mostafa Bachaoui, Abderrahmene El Ghmari. 2017, **Evaluation of the potential of sentinel-2 data for mapping crops in Tadla Plain, and determination of the most favorable period for discrimination of different crops using a single sentinel-2 image.** *Sen2-Agri_3rd User Workshop Reports from local and voluntary demonstration sites (Case of Morocco)*. June 28 and 29, 2017 in Roma, Italy.

[4] Abderrazak El Harti, Rachid Lhissou, Karim Chokmani, **Jamal-eddine Ouzemou**, Mohammed Hassouna, El mostafa Bachaoui, Abderrahmène El Ghmari. 2017. **Spatiotemporal Monitoring of soil salinization in irrigated Tadla plain (Morocco) using satellite spectral indices.** *First International ASRO Geological Congress (ASRO-GC-2017)*, March 15-17, 2017. Faculty of Sciences El Jadida, Morocco.

[5] **Ouzemou Jamal-eddine**, Lhissou Rachid, Zidane Issameddine, Boulli Abdelali. 2017. ***Forest density characterization in the High Atlas Mountains of Beni Mellal using geomorphological and remote sensing data***. *First International ASRO Geological Congress (ASRO-GC-2017), March 15-17, 2017. Faculty of Sciences El Jadida, Morocco.*

[6] Abderrazak El Harti, Rachid Lhissou, Asma Dakir, Basma Naouil, **Jamal-eddine Ouzemou**, El mostafa Bachaoui, Abderrahmène El Ghmari, Mohammed Hassouna, Karem Chokmani. 2015. ***Détection de la dynamique de la salinisation des sols irrigués de la plaine du Tadla à l'aide des images Landsat TM / OLI***. *Séminaire international : Application de la Télédétection Spatiale en Modélisation hydrologique et à la Caractérisation des Sols, 11 Mai 2015, Faculté des Sciences et Techniques Béni Mellal, Maroc.*

[7] **Jamal-eddine Ouzemou** ; Abderrazak El Harti ; Ali EL Moujahid ; Naima Bouch ; Rabii El Ouazzani ; Rachid Lhissou; Jellouli Amine; Chakouri Mouhcine; Adiri Zakaria ; El Mostafa Bachaoui; ***La delimitation des parcelles agricoles par l'optimisation des paramètres de segmentation en utilisant les données GeoEye-1***. *ATGG Application des Technologies Géospatiales en Géosciences, Taza, Maroc 21 – 22 Octobre 2015.*

[8] **Jamal-eddine Ouzemou** ; Abderrazak El Harti ; Ali EL Moujahid ; Naima Bouch ; Rabii El Ouazzani ; Rachid Lhissou ; El Mostafa Bachaoui ; ***Mapping crop based on phenological characteristics using time-series NDVI of operational land imager data in Tadla irrigated perimeter, Morocco***. *SPIE Remote Sensing, Toulouse, France 21 - 24 September 2015.*

[9] Abderrazak El Harti, Rachid Lhissou, Karem Chokmani, Asma Dakir, Basma Naouil, **Jamal-eddine Ouzemou**, El Mostafa Bachaoui, Abderrahmene El Ghmari, Mohammed Hassouna. ***Detecting of soil salinization dynamics in rrigated Tadla Plain using Landsat TM/OLI imagery***. *SPIE Remote Sensing, Toulouse, France 21 - 24 September 2015.*

RÉSUMÉ

Apport de la Télédétection Optique et Radar pour le suivi et la cartographie des cultures : Cas du périmètre irrigué de TADLA

Les effets du réchauffement climatique des dernières décennies font de l'irrigation une pratique obligatoire pour l'agriculture dans les pays arides et semi-arides comme le Maroc. La localisation des cultures et leur cartographie à différents stades, sont des informations utiles pour la planification agricole, pour la gestion des ressources en eau d'irrigation et pour le suivi de la santé des cultures.

Les images de télédétection spatiale multispectrales sont souvent utilisées pour cartographier les cultures dans les systèmes agricoles extensifs à l'échelle mondiale et régionale. Cependant, la résolution spatiale et spectrale des capteurs multispectraux en orbites sont inadéquates pour cartographier des paysages agricoles fortement fragmentés et intensifs, tels que le périmètre irrigué de Tadla (PIT) dans le centre du Maroc.

La première partie de cette thèse vise à : (1) identifier et cartographier les principales cultures du PIT en utilisant une série temporelle d'indices de végétation;. Notre méthodologie est basée sur les données Landsat-8 OLI (Operational Land Imager) rééchantillonnées à 15 m. Les classificateurs SAM, RF et SVM ont été utilisés et comparés pour la cartographie des cultures pendant 10 périodes au cours de la saison agricole. Les méthodes RF, SVM et SAM ont classé les principales cultures avec des précisions globales de 89,26%, 85,27% et 57,17% respectivement, et un coefficient kappa de 85%, 80% et 43%, respectivement. Malgré la performance des séries de NDVI issues des données OLI, des confusions entre les différentes cultures sont observées.

La deuxième partie de cette thèse est consacrée au suivi de croissance et de développement de la betterave à sucre durant les campagnes agricoles 2013-2014 et 2015-2016. La première année agricole a été consacrée à l'étalonnage des seuils des classes de l'état de croissance de la betterave sucrière, tandis que la seconde a servi à valider et à ajuster les seuils fixés pendant la première année, afin d'améliorer la cartographie de l'état de croissance. Notre méthodologie est basée sur les images Landsat-8 et Sentinel-2A et leurs indices spectraux de végétation dérivés. Les classes d'état de santé obtenues ont été recalibrées et validées sur la base de la réalité du terrain. La surveillance des états de croissance a permis de cibler les interventions sur le terrain pour le traitement des différents anomalies de la culture.

A cause de la couverture nuageuse et les conditions climatiques affectant la disponibilité des données optiques, nous avons utilisé dans la troisième partie de cette thèse les données Radar Sentinel-1 en synergie avec les données optiques pour la cartographie précoce des parcelles de la betterave à sucre. La classification orientée objet est utilisée pour restituer les limites des parcelles agricoles et isoler précisément les champs de la betterave à sucre dans un état de croissance précoce.. Ainsi nous avons pu cartographier la betterave à sucre avec une précision globale de 97,62% et un Coefficient kappa de 0.95 au mois de décembre.

En guise de conclusion, la méthodologie développée a montré un grand intérêt sur la maîtrise du périmètre irrigué de Tadla en matière de localisation et le suivi des cultures, en particulier la betterave à sucre.

Mots-clés : Tadla, Cartographie de cultures, Betterave à sucre, Télédétection, Série temporelle, Suivi spatio-temporel, Landsat-8 OLI, Sentinel 2, Sentinel 1, Radar, Optique.

ABSTRACT

Contribution of Optical and Radar Remote Sensing for crop monitoring and mapping.

Case of the TADLA Irrigated Perimeter

The effects of global warming in recent decades have made irrigation a compulsory practice for agriculture in arid and semi-arid countries such as Morocco. Retrieving crops and their location, as well as their spatial extent, are useful information for agricultural planning and better management of irrigation water resources as well as for crop health monitoring, towards an increased food production and reduced water use. Multispectral remote sensing images with a spatial resolution of 30 m or greater are often used for mapping crops in extensive agricultural systems at global and regional scale. However, that spatial resolution is inadequate for mapping highly fragmented and intensive agricultural landscapes, such as the Tadla Irrigated Perimeter (TIP) in central Morocco.

The first part of the thesis aims to: (1) identify and map major crops in the TIP with improving the spatial resolution of producing maps from 30 m to 15 m; (2) retrieve the area of major cultivations; (3) compare machine learning classifiers namely, Support Vector Machine (SVM), Random Forest (RF) and Spectral Angle Mapper (SAM) as a distance-based classifier. Our methodology is based on the Landsat-8 OLI (Operational Land Imager) data pan-sharpened to 15 m. SAM, RF and SVM classifiers were used and compared for retrieving crops from a multitemporal dataset of the Normalized Difference Vegetation Index (NDVI) for 10 periods during the agricultural season. The RF, SVM and SAM have classified the major crops with overall accuracies of 89.26%, 85.27% and 57.17% respectively, and kappa coefficient of 85%, 80% and 43%, respectively, noting that sugar beet, tree crops and cereals are delineated accurately while alfalfa is not. This study showed a high performance by using time-series pan-sharpened OLI NDVI data coupled with machine learning classifiers for mapping different crops in irrigated, very fragmented and heterogeneous agricultural landscape.

This thesis aims secondly to develop an operational tool for spatiotemporal monitoring of the health status of sugar beets using free multispectral remote sensing data in the irrigated perimeter of Tadla (Morocco) during two agricultural years 2013-2014 and 2015-2016. Because traditional method of monitoring sugar beet based on random field surveys and census remains unsuitable and does not give the actual state of all parcels. Therefore, it is necessary to use more advanced methods to deal with this issue. The present work aims The first one was dedicated to calibrate the thresholds of the classes of the sugar beet growth status, while the second year was used to validate and adjust the thresholds fixed in the first year, in order to improve the growth status mapping. Our methodology is based on the Landsat-8 and Sentinel-2A images and their derived spectral vegetation indices. The health status classes obtained were recalibrated and validated based on the ground truth. This methodology allowed for the detection of the parcels in stress condition. The overall accuracy of NDVI, EVI and OSAVI was 94.29%, 87.5%, and 87.14%, respectively. Les résultats ont montré que ce suivi a contribué à améliorer l'encadrement des agriculteurs et les interventions ciblées sur le terrain, ce qui a permis de contribuer dans l'amélioration des rendements.

Due to cloud cover and weather conditions affecting the availability of optical data. All the recommendations of the first two parts focused on the use of radar data for mapping and spatio-temporel monitoring of crops. Consequently, radar and optical data were used in the last phase in synergy following an object-oriented classification approach to clearly delineate the boundaries of agricultural plots and to precisely isolate sugar beet plots in an early growth state. In order to achieve the results based on the assumptions predetermined in previous work, a long process was carried out to achieve a better segmentation at the start. Multi-resolution segmentation based on optimized parameters was applied to the multispectral images in addition to an aggregation of contour images. The Canny algorithm for edge detection was used. Indeed, all the precision parameters recorded good results at the end of December (Overall precision:97.62%; Kappa Coefficient:0.95) for the approach followed (Object-oriented classification of combined Optical/Radar data) compared to the results of results based on the pixel classification of optical data at the end of March (Overall precision:93.73%; Kappa Coefficient:0.87).

In conclusion, the developed methodology has shown a great interest on the control of the irrigated perimeter of Tadla in terms of location and monitoring of crops, especially sugar beet.

Keywords: Tadla, Crop Mapping, Sugar Beets, Remote Sensing, Time Series, Spatio-temporel Monitoring, Landsat-8 OLI, Sentinel 2, Sentinel 1, Radar, Optics.

TABLE DES MATIÈRES

1	INTRODUCTION.....	2
1.1	MISE EN CONTEXTE DE L'ETUDE	2
1.2	PROBLEMATIQUE DE L'ETUDE	2
1.3	OBJECTIFS DE L'ETUDE	3
1.4	CONTENU DU RAPPORT.....	4
2	REVUE DE LITTERATURE.....	7
2.1	TELEDETECTION APPLIQUEE EN AGRICULTURE	7
3	CARTOGRAPHIE DES TYPES DE CULTURES EN SE BASANT SUR LES CARACTERISTIQUES PHENOLOGIQUE ET LA SERIE TEMPORELLE DE NDVI : CAS D'UN SYSTÈME AGRICOLE TRES FRAGMENTE ET INTENSIF	12
3.1	INTRODUCTION.....	12
3.2	ZONE D'ETUDE	14
3.3	MATERIELS ET METHODES.....	16
3.3.1	<i>Données de terrain.....</i>	<i>16</i>
3.3.2	<i>Acquisition de données satellitaires</i>	<i>17</i>
3.3.3	<i>Méthodologie.....</i>	<i>18</i>
3.3.4	<i>Prétraitement des images satellitaires</i>	<i>21</i>
3.3.5	<i>Traitement des images satellitaires.....</i>	<i>27</i>
3.4	RESULTATS ET DISCUSSIONS.....	35
3.4.1	<i>Surface irriguées / non-irriguées.....</i>	<i>35</i>
3.4.2	<i>Courbes phénologiques des cultures.....</i>	<i>35</i>
3.5	CONCLUSION.....	42
4	EVALUER ET AMELIORER L'ETAT DE LA BETTERAVE SUCRIERE PAR LE SUIVI SPATIO-TEMPOREL A L'AIDE DES IMAGES SENTINEL-2 ET LANDSAT-8.....	46
4.1	INTRODUCTION.....	46
4.2	ZONE D'ETUDE	48
4.3	MATERIEL ET METHODES	49
4.3.1	<i>Données de terrain.....</i>	<i>49</i>
4.3.2	<i>Données images satellitaires</i>	<i>51</i>
4.3.3	<i>Méthodologie.....</i>	<i>52</i>
4.3.4	<i>Prétraitement des données images</i>	<i>54</i>
4.3.5	<i>Calcul d'indices de végétation VIs.....</i>	<i>55</i>

4.3.6	<i>Inter-calibration des VIs dérivés des données S-2A et OLI</i>	55
4.3.7	<i>Seuillage et validation des VIs</i>	57
4.4	RESULTATS ET DISCUSSIONS.....	60
4.4.1	<i>Suivi spatio-temporel de l'état de la betterave à sucre</i>	60
4.4.2	<i>Problèmes agricoles détectés</i>	70
4.5	CONCLUSION.....	72
5	ANALYSE SYNERGETIQUE DES DONNEES RADAR ET OPTIQUES POUR UNE CARTOGRAPHIE PRECOCE DE LA BETTERAVE A SUCRE	75
5.1	INTRODUCTION	75
5.2	ZONE D'ETUDE ET DONNEES DE TERRAIN	78
5.3	MATERIEL ET METHODES	79
5.3.1	<i>Données images</i>	79
5.3.2	<i>Méthodologie</i>	80
5.3.3	<i>Prétraitements et traitements des données S-1 et S-2</i>	81
5.3.4	<i>Les classifications par pixel (PXB) et Orienté-Objet (OO)</i>	82
5.3.5	<i>La segmentation</i>	84
5.3.6	<i>Parcelles non cultivées</i>	88
5.3.7	<i>La validation des résultats</i>	88
5.4	RESULTATS ET DISCUSSIONS.....	89
5.4.1	<i>La segmentation</i>	89
5.4.2	<i>Les classifications PXB et OO</i>	91
5.5	CONCLUSION.....	102
6	CONCLUSION GENERALE ET PERSPECTIVES	105
6.1	CONCLUSIONS.....	105
6.2	PERSPECTIVES.....	106
	BIBLIOGRAPHIE	107

LISTE DES TABLEAUX

Tableau 3.1	Les dates d'acquisition des images et leurs équivalents en ordre de jour de l'année	17
Tableau 3.2	Caractéristiques des capteurs OLI et TIRS du satellite Landsat 8	18
Tableau 3.3	Mesures de précision des classifications RF, SVM et SAM.	37
Tableau 4.1	Les périodes de semis de la betterave à sucre et les superficies de chaque période en ha et en pourcentage des deux campagnes agricoles 2013-2014 et 2015-2016.	51
Tableau 4.2	Les dates d'acquisition et les caractéristiques des images utilisées.	52
Tableau 4.3	Seuils de NDVI retenus après validation.	60
Tableau 5.1	Les dates d'acquisition des images S-1 et S-2	80
Tableau 5.2	Les polarisations, Ratios et Combinaisons utilisées.	82
Tableau 5.3	Les différentes classifications effectuées.	84
Tableau 5.4	Les résultats de la précision globale et coefficient kappa pour chaque approche utilisée.	95

LISTE DES FIGURES

Figure 3.1	Localisation de la zone d'étude à l'échelle nationale.....	15
Figure 3.2	Calendrier des dates de plantation et de récolte des principales cultures du TIP.....	16
Figure 3.3	Organigramme de la méthodologie utilisée.....	20
Figure 3.4	Les méthodes de rééchantillonnage.....	23
Figure 3.5	Illustration de la technique de Gram-Schmidt Pan Sharpening.....	24
Figure 3.6	Effets du pan-sharpening sur les données de NDVI.....	26
Figure 3.7	Illustration du procédé de création de la série chronologique de NDVI.....	28
Figure 3.8	Profils spectraux de NDVI pour les principaux types de cultures cultivées en 2014.....	30
Figure 3.9	Carte globale des types de cultures du PIT obtenue par la classification RF. (A) et (B) représentent les résultats des classificateurs RF, SVM et SAM.....	40
Figure 3.10	Comparaison des superficies de cultures obtenues par RF, SVM et celles fournies par l'ORMVAT.....	42
Figure 4.1	La zone d'étude. (a) Situation de la zone d'étude par rapport au territoire du Maroc ; (b) L'emplacement des parcelles de la betterave sucrière.....	49
Figure 4.2	Précipitations et températures annuelles enregistrées dans la zone d'étude des années agricoles 2013-2014 et 2015-2016.....	51
Figure 4.3	Durée de la surface foliaire d'une parcelle de betterave à sucre stressée et d'une parcelle de référence en bonne santé de la zone d'étude pendant la saison 2013-2014.....	53
Figure 4.4	Diagramme de processus global de cette étude.....	54
Figure 4.5	Inter-calibration de Landsat-8 et Sentinel-2A's VIs. (a) NDVI, (b) EVI et (c) OSAVI.....	57
Figure 4.6	L'état des cultures de betterave à sucre à l'aide des trois VIs dans les trois sites (A), (B) et (C) au cours de la saison 2015-2016.....	62
Figure 4.7	Analyse statistique de l'état de la betterave à sucre sur le terrain à l'aide des trois VIs. (a) Médiocre, (b) Moyen, (c) Bon, (d) Arraché et (e) précision globale.....	65
Figure 4.8	Localisation et photographies de quelques exemples de différentes classes d'état de betteraves à sucre au 26 juin 2016.....	67
Figure 4.9	Variation de la dynamique des différents états de la betterave à sucre à l'aide de NDVI. (a) Landsat-8 en 2013-2014 et (b) Sentinel-2A en 2015-2016.....	70
Figure 4.10	Photographies de différents problèmes détectés à l'aide de notre méthodologie.....	72
Figure 5.1	Localisation de la zone d'étude et des échantillons de calibration et de validation.....	79
Figure 5.2	Organigramme de la méthodologie utilisée.....	81
Figure 5.3	Illustration de l'agrégation de plusieurs images de contours issues de l'algorithme Canny et leur binarisation.....	86
Figure 5.4	Fonctionnement de la segmentation Multirésolution.....	88
Figure 5.5	Illustration des limites extraites de la segmentation Multi-résolution MRS.....	91

Figure 5.6 Les classifications SVM d'images S-1 et S-2 acquises en décembre par l'approche PXB et par OO pour le site Pivots_FBS.93

Figure 5.7 Les classifications SVM d'images S-1 et S-2 acquises en décembre par l'approche PXB et par OO pour le site Pivots_Zidouh.94

Figure 5.8 L'évolution des paramètres F1 score, Ri et Pi des approches de classifications utilisées. (A) Approche PXB, (B) Approche OO, (C) Evolution des paramètres F1 score, Ri et Pi pour chaque approche de classification utilisée en fonction du temps.....96

Figure 5.9 Comparaison de la distribution des parcelles de la betterave à sucre dans les deux zones de pivots étudiées.99

NOTATIONS, SYMBOLES ET ABRÉVIATIONS

σ°	:	Coefficients de rétrodiffusion
λ	:	longueur d'onde de la bande spectrale
Abs	:	Valeur absolue
AOF	:	Apply orbit file
ASAR	:	Advanced synthetic aperture radar
BBCH	:	Expression allemande : Bundesanstalt, Bundessortenamt und chemische Industrie
CART	:	Classification and regression trees
CDA	:	Centre de Développement Agricole
DT	:	Decision tree
DOS	:	Dark object subtraction
ESA	:	European space agency
ETM+	:	Enhanced thematic mapper plus
EVI	:	Enhanced vegetation index
FAO	:	Organisation des Nations unies pour l'alimentation et l'agriculture
FLAASH	:	Fast Line-of-sight Atmospheric Analysis of Hypercubes
GNDVI	:	Green normalized vegetation indice
GNSS	:	Global navigation satellite system
GPS	:	Global positioning system
GRD	:	Ground range detected
GS	:	Gram-schmidt
ha	:	Hectare
HIS	:	Hue-saturation-intensity
HPF	:	High pass filter
IW	:	Interferometric wide swath
kNN	:	K-Nearest Neighbour
LDCM	:	Landsat data continuity mission
MIR	:	Moyen infra-rouge
MODIS	:	Moderate resolution imaging spectroradiometer
MNT	:	Modèle Numérique du Terrain
MRS	:	Segmentation multi-résolution
MSI	:	Instrument multispectral
NDRE	:	Normalized difference red edge index
NDVI	:	Normalized Difference Vegetation index
NN	:	Neural networks
OA ou PG	:	Overall accuracy ou Précision globale

OLI	:	Operationnal land iamger
OO	:	Classification orientée objet
ORMVAT	:	Office Régional de la Mise en Valeur Agricole de Tadla
OSAVI	:	Optimized soil adjusted vegetation index
PIR	:	Proche infra-rouge
PIT	:	Périmètre Irrigué de tadla
PXB	:	Classification basée sur pixels
RADAR	:	Radio Detection And Ranging
R ² ou Rsq	:	Céofficient de détermination
RBF	:	Radial basis function
RF	:	Random forest
RMSE	:	Erreur quadratique moyenne
ROI	:	Regions of interest
S-1TBX	:	Sentinel-1toolbox
S-1	:	Sentinel-1
S-2	:	Sentinel-2
SAM	:	Spectral Angel Mapper
SAR	:	Synthetic Aperture Radar
SRTM	:	Shuttle Radar Topography Mission
SUTA	:	Sucrerie de Tadla
SVM	:	Support Vector Machine
SWIR	:	Short-wavelength infrared
USGS	:	United States Geological Survey
TIRS	:	Thermal InfraRed Sensor
TM	:	Thematic Mapper
TOA	:	Top of Atmosphère
VHR	:	Very High Resolution
VIS	:	Visible
VI _s	:	Vegetation Indexs
VNIR	:	Visible and Near Infrared
VV	:	Vertical Vertical
VH	:	Vertical Horizontal
W-PCA	:	Wavelet-Principal Component Analysis

1. INTRODUCTION

1 INTRODUCTION

1.1 Mise en contexte de l'étude

Les changements climatiques et la sécurité alimentaire sont des questions majeures qui touchent l'ensemble de la société mondiale.

Jusqu'à présent, toutes les études effectuées dans le domaine du climat ont prouvé que l'homme a un impact sur le système climatique. La poursuite de son activité industrielle accentuera de plus en plus l'effet négatif sur le globe terrestre et entraînera des difficultés au niveau de la répartition de la végétation naturelle et cultivée.

En raison du changement climatique extrême, on observe l'augmentation des conditions de stress hydrique dans un certain nombre de zones agricoles dans le monde. C'est la conséquence d'une confluence de facteurs : pression démographique, mauvaise gestion des ressources en eau (*Davis et coll., 2017*). Ce qui fait, le contrôle des ressources hydriques et des terres arables revêt une importance croissante (*Brown et coll., 2012*).

Selon l'Organisation des Nations Unies pour l'alimentation et l'agriculture (FAO), l'axe de recherche prioritaire actuellement dans tout le monde est l'augmentation de la production alimentaire, en raison de l'énorme croissance démographique qui va passer à 9 milliards en 2050. Cette croissance exige plus d'efforts pour produire davantage des produits alimentaires (agricoles), et ceci pour satisfaire les besoins en approvisionnement alimentaire (*Foley et al, 2011*).

1.2 Problématique de l'étude

La cartographie des cultures et la mise à jour de l'information spatiale permettent le suivi spatio-temporel des cultures, qui contribue à la planification et à la gestion des ressources en eau, à la prévision des rendements et à l'adaptation de l'agriculture aux changements climatiques. De plus, l'association de toutes les informations sur les cultures, fournit un système d'aide à la décision immédiate de haut niveau qui apporte une valeur exceptionnelle aux intervenants et aux producteurs agricoles.

Cependant, le suivi spatio-temporel et la cartographie des types de cultures par des méthodes conventionnelles telles que les recensements et les enquêtes sur le terrain restent coûteuses, laborieuses et sujettes à un certain nombre d'erreurs. Ainsi, il est inévitable de développer des techniques et des méthodologies efficaces pour la cartographie et le suivi spatio-temporel des cultures. En effet, il s'est avéré nécessaire d'adopter des technologies puissantes, rapides, synoptiques, fréquentes et moins chères pour remédier aux problématiques rencontrées avec les méthodes traditionnelles.

Parmi ces technologies, on parle de la télédétection spatiale. Cette technique a été utilisée comme un outil efficace pour la cartographie, la surveillance et la détermination des caractéristiques des cultures telles que le stress hydrique et l'influence des conditions environnementales sur ces dernières. Plusieurs études ont montré qu'il y a une bonne corrélation entre les indices de végétation dérivés des images satellitaires caractéristiques des cultures ([Tingting and Chuang 2010](#)).

1.3 Objectifs de l'étude

Cette recherche vise à étudier principalement l'utilité de la télédétection spatiale optique et radar pour la cartographie et le suivi spatio-temporel des cultures et en particulier la betterave à sucre. L'achèvement de ces objectifs a été effectué en s'appuyant sur plusieurs points:

- Dressage d'un diagnostic sur la possibilité de savoir les types de cultures en se basant sur les indices spectraux de végétation dérivés des données satellitaires optiques et open source;
- La caractérisation spectrale de chaque type de cultures étudié, l'évaluation et le choix du meilleur classificateur ;
- Développement d'une méthodologie pour surveiller l'état de croissance de la betterave à sucre et intervenir immédiatement pour améliorer l'état de croissance et le développement de cette culture et par conséquent, obtenir des récoltes satisfaisantes du point de vue rendement ;

- L'utilisation d'un ensemble de techniques pour instaurer une procédure permettant une cartographie précoce de la betterave à sucre à la base des données radar et optiques.

1.4 Contenu du rapport

Ce document est divisé en 5 parties principales :

Le contexte, la problématique et les objectifs du travail sont présentés dans la première partie. Une revue de littérature sur l'utilisation de la télédétection dans le domaine de l'agriculture est abordée dans la deuxième partie. Les trois dernières parties s'articulent sur trois axes de recherche et dont chaque axe est présenté par la méthodologie et les données utilisées en plus de la discussion des résultats.

Le premier axe (**partie 3**) de notre travail de thèse consiste à proposer des méthodologies visant à déterminer l'emplacement et estimer la superficie occupée par chaque type de culture d'hiver majeure étudié. Pour atteindre les résultats souhaités par ce travail, on a essayé dans un premier temps de distinguer les types de cultures en se basant sur les données du capteur OLI de Landsat-8 au début de la saison. Cependant, une seule image de ce type de capteur est insuffisante pour faire la distinction. Par conséquent, il s'est avéré nécessaire que la caractérisation de chaque type de culture par un profil spectral extrait d'une série temporelle d'indice de végétation est inévitable. Ces profils spectraux couvrent tous les stades phénologiques des cultures étudiées, c'est-à-dire, on a utilisé l'ensemble des images acquises depuis le début de la saison jusqu'à sa fin.

Le deuxième axe (**partie 4**) de recherche porte sur l'utilisation de la télédétection optique pour le suivi spatio-temporel et la surveillance de la culture de la betterave à sucre afin d'effectuer des interventions immédiates et au bon moment. Ces interventions, qui prendront la forme de traitements phytosanitaires, d'optimisation de l'irrigation, etc., contribueront à la bonne gestion de cette culture et donc à la réalisation des rendements escomptés.

Le troisième axe de recherche (**partie 5**) s'articule sur l'utilisation des données satellitaires optique et radar d'une manière synergique pour pouvoir identifier les parcelles de betteraves à sucre en tout début de saison agricole et dans un état de croissance encore précoce, ce qui nous permettra de réaliser un suivi spatio-temporel de cette culture.

Enfin, nous terminerons avec une conclusion générale en plus de quelques perspectives.

2. REVUE DE LITTERATURE

2 REVUE DE LITTERATURE

2.1 Télédétection appliquée en agriculture

A l'échelle mondiale, le suivi et l'étude des zones agricoles occupe une place sociale et économique très importante. En principe, l'état du sol et des cultures peut changer quotidiennement et de façon saisonnière. Les cibles agricoles varient également dans l'espace, avec des différences observées d'un champ à l'autre et à l'intérieur des champs individuels (McNairn et Brisco, 2004). Par conséquent, il est très important de développer des méthodes visant à surveiller l'état des cultures, améliorer leur gestion, ainsi que pouvoir faire une des prévision de rendements (González Sanpedro, 2008; FAO, 2017).

Durant plusieurs années, la classification et la surveillance des types de cultures s'est réalisée à l'aide des images satellitaires de source optique. Aujourd'hui, le progrès technologique a permis de combiner entre les données optiques et radar en vue de réaliser une cartographie détaillée des types de cultures. Ces données, opérant dans les parties spectrales du VIS, PIR et Hyperfréquences, fournissent des informations sur la distribution spatiale des cultures à des échelles locales et régionales (Orynbaikyzy et al., 2019). Ce champ d'application constitue un sujet important dans la recherche en télédétection, car ces techniques présentent l'avantage de réduire les coûts ainsi que couvrir de grandes zones (González Sanpedro, 2008; FAO, 2017).

En principe, la surveillance des cultures par télédétection est basée sur l'estimation des paramètres biophysiques et de leur évolution au fil du temps (Carfagna et Gallego, 2005; González Sanpedro, 2008; FAO, 2017). Ces paramètres agissent comme indicateurs de l'état des cultures tout au long de la saison de croissance, ce qui est fondamental en agriculture de précision (Qi et al., 2003; González Sanpedro, 2008; Liaghat et Balasundram, 2010; Shanmugapriya et al., 2019). La télédétection optique a été établie depuis longtemps pour les pratiques de gestion agricole telles que l'estimation et la prévision du rendement, la planification de l'irrigation, la détection et la surveillance de certaines maladies des plantes, etc. Cette tâche a été achevée en utilisant des images spatio-temporelles à haute résolution spatiale provenant des

capteurs spatiaux et aéroportés (Qi et al., 2003). Parmi les indices les plus répandus est celui de la végétation par différence normalisée (NDVI), utilisé pour l'étude de la végétation. Le rendement des cultures est fortement influencé par les types de sols, les intrants agricoles et les techniques de culture, ce qui peut donner lieu à des variabilités au sein des cultures. Le calcul de NDVI peut contribuer dans l'étude de cette variabilité (Carfagna et Gallego, 2005).

En outre, plusieurs études ont montré l'apport des données radar dans l'agriculture (Steele-Dunne et al., 2017; Chang-an et al., 2019). La capacité tout temps de la télédétection radar la rend plus appropriée que toutes les autres techniques de télédétection pour la surveillance constante des cultures (Sivasankar et al., 2018). Les progrès récents dans la résolution et la disponibilité des imageries satellitaires ont permis la collecte d'informations sur la variabilité des cultures (FAO, 2017). Ces données ont été largement utilisées dans l'étude des cultures (Bastiaanssen et al., 2000; Seelan et al., 2003; Hadria et al., 2009; Moran et al., 2012; Marais Sicre et al., 2016), l'identification des pratiques agricoles (Fieuzal et al., 2011; Marais Sicre et al., 2014, 2017), l'estimation des paramètres biophysiques (Duchemin et al., 2006, 2015; Claverie et al., 2012; Atzberger, 2013; Baup et al., 2016; Betbeder et al., 2016) et l'estimation des rendements (Soria-Ruiz et al., 2009; Fieuzal and Baup, 2016; Fieuzal et al., 2017; Marais Sicre et al., 2020). En littérature, plusieurs auteurs ont exploité les données optiques et radar en agriculture (Solberg, 2006; McNairn et al., 2007, 2009; Qiao et al., 2014). L'utilisation de ces deux types d'imagerie est devenue plus en plus nécessaire surtout pour la différenciation entre les types de cultures qui se rassemblent dans l'une de ces sources de données, ou dans les régions avec une couverture nuageuse fréquente. Cette opportunité a ouvert de nouvelles perspectives pour la télédétection appliquée à l'agriculture.

La majorité des études réalisées ont démontré l'avantage de l'utilisation de séries multi-temporelles d'images satellitaires optiques et radar. Cette combinaison a permis de réduire les lacunes temporelles (causées principalement par les nuages), et elle a donné la possibilité de surveiller le cycle de croissance des cultures (McNairn et al., 2009). Inglada et al. (2016) ont examiné l'impact des données radar sur les résultats de la classification, tout en fusionnant des séries multi-temporelles de onze scènes Landsat

avec neuf scènes Sentinel-1. L'analyse a mis en évidence des améliorations significatives de la précision, en montrant que les cartes de couverture terrestre dans les zones agricoles peuvent être générées au début de la saison de croissance avec une précision satisfaisante. [Shang et al. \(2008\)](#) ont démontré qu'une précision acceptable pouvait être atteinte dès le début de la saison de croissance, même si une seule image Landsat était complétée par deux images ASAR (*Advanced Synthetic Aperture Radar*) de polarisation VV/VH. [Zhou et al. \(2017\)](#) ont trouvé qu'en cas de classification du blé d'hiver, lorsqu'une image optique ne peut pas être utilisée en raison de la couverture nuageuse considérable, elle peut être remplacée par une image radar sans aucune influence défavorable sur la qualité de la classification.

De plus, [Hong et al. \(2014\)](#) ont déduit que la classification non supervisée est plus performante pour la différenciation des prairies et de la luzerne. Ils ont également souligné que la classification de la scène en plusieurs parties homogènes est très utile en utilisant les données radar. La classification non supervisée a été utilisée également par [Hill et al. \(2005\)](#) pour les graminées et les pâturages en Australie occidentale. Ce choix a été expliqué par les changements continus dans la structure et la composition des prairies, ce qui rend difficile de sélectionner de régions d'intérêts fiables. [Le Hegarat-Masclé et al. \(2000\)](#) ont démontré que l'utilisation des données Landsat et radar ERS a fourni la classification la plus robuste du blé, du maïs, de l'orge, etc. En outre, on note l'existence d'approches hybrides, où la classification initiale non supervisée est suivie d'une analyse et/ou interprétation des données ou d'une classification supervisée ([Thenkabail et al., 2005](#)).

Dans d'autres études, [Kurtz et al. \(2009\)](#) ont utilisé des images Landsat multi-temporelles afin de classer les types de couverture terrestre et l'intensité du pâturage. Les catégories de cette dernière ont été définies en fonction du pourcentage de sol nu et de la hauteur de l'herbe. L'analyse de corrélation entre le NDVI et la biomasse aérienne était significative. [Moreau et Toan \(2003\)](#) ont utilisé les données du radar pour quantifier la biomasse dans une zone humide andine dans le but d'optimiser la gestion du bétail. La sensibilité du signal correspondant à la variation de la biomasse était suffisamment élevée pour faciliter la cartographie de la biomasse de haute précision. A leur tour, [Folhes et al. 2009](#) ont exploité l'imagerie Landsat conjointement avec un

modèle d'évapotranspiration pour optimiser l'utilisation de l'eau dans une zone irriguée. Les résultats ont montré une meilleure prévisibilité de la consommation d'eau dans l'agriculture irriguée, et donc une meilleure gestion des ressources en eau dans ces zones.

Les classifications supervisées comme Random Forest (RF), Support Vector Machine (SVM), k-Nearest Neighbour (kNN), Neural Networks (NN) and Decision Tree (DT) ont été utilisées aussi en agriculture. A titre d'exemple, [Abdikan et al. \(2015\)](#) ont évalué la performance des approches de l'SVM, RF et kNN sur les données fusionnées (TerraSAR-X et RapidEye) et brutes (RapidEye) pour classer les champs de maïs et du coton. Les résultats obtenus ont montré que la précision de la classification a dépassé le seuil de 90%. Aujourd'hui, les satellites Sentinel et Landsat 8 fournissent des données en accès libre avec une très bonne résolution spatio-temporelle, qui sont très adaptées aux applications agricoles ([Kussul et al., 2016, 2018](#); [Lussem et al., 2016](#); [Mansaray et al., 2017](#); [Sonobe et al. 2017](#)). Alors, ces satellites ont constitué la base de la présente recherche à côté d'autres sources de données.

Au Maroc de multiples recherches ont été menées sur l'application de la télédétection l'agriculture de précision.

[Bouras et al., 2020](#) ont étudié les liens entre la production céréalière pluviale et la sécheresse agricole par le biais d'indices de télédétection et d'un système d'assimilation de données terrestres. [Acharki et al., 2020](#) ont montré l'utilité de l'utilisation combinée des données optiques et Radar pour l'amélioration qualitative de la classification des cultures dans un périmètre irrigué dans le nord marocain. D'autres études plus avancées ont été focalisées sur l'automatisation des traitements des images satellitaires pour le suivi des cultures ([Defourny et al., 2019](#)).

L'objectif principal de cette revue est de compléter ces efforts pour fournir un contexte et des connaissances complètes sur les applications des données et technologies de télédétection en agriculture, en se concentrant sur la cartographie et le suivi des cultures : cas de la betterave à sucre.

**3. CARTOGRAPHIE DES TYPES DE CULTURES EN SE
BASANT SUR LES CARACTERISTIQUES
PHENOLOGIQUES ET LA SERIE TEMPORELLE DE
NDVI : CAS D'UN SYSTEME AGRICOLE TRES
FRAGMENTE ET INTENSIF**

3 CARTOGRAPHIE DES TYPES DE CULTURES EN SE BASANT SUR LES CARACTERISTIQUES PHENOLOGIQUES ET LA SERIE TEMPORELLE DE NDVI : CAS D'UN SYSTÈME AGRICOLE TRES FRAGMENTE ET INTENSIF

3.1 Introduction

La réduction de l'utilisation de l'eau pour l'agriculture reste un défi majeur et mondial. Ces dernières années ont vu l'émergence de conditions de stress hydrique dans un certain nombre des zones agricoles les plus importantes de la planète, résultant d'une confluence de facteurs : pression démographique, mauvaise gestion des ressources en eau et changements climatiques extrêmes (Davis et al., 2017).

L'agriculture marocaine est confrontée à plusieurs défis, notamment, le fait que ce pays est dominé par un climat semi-aride à aride (Ait Kadi, 2004). Le Maroc est très exposé aux changements climatiques, ce qui se traduit par un climat plus chaud et plus sec. De 1961 à 2016, on a observé une augmentation du nombre total annuel de jours chauds et une diminution du nombre de jours froids à l'échelle nationale et locale. De plus, ce réchauffement s'accompagne d'une diminution des précipitations totales et d'une tendance positive du nombre maximum de jours secs consécutifs (Ait Kadi et Ziyad, 2018).

Le périmètre irrigué de Tadla (PIT) au centre du Maroc contribue à la production nationale de betteraves sucrières, céréales, olives, agrumes et grenades de 25 %, 30 %, 8 %, 14 % et 40 %, respectivement (ORMVAT, 2015). Afin d'assurer les besoins alimentaires futurs, le PIT ainsi que les autres périmètres irrigués marocains devraient améliorer leur méthode technique de prévision des rendements et de gestion des eaux d'irrigation ainsi que la performance agricole (Mancosu et al., 2015).

La cartographie des cultures et la mise à jour de l'information spatiale permettent le suivi spatio-temporel des cultures, qui contribue à la planification et à la gestion des ressources en eau, à la prévision des rendements et à l'adaptation de l'agriculture aux changements climatiques (FAO, 2003 ; Mancosu et al., 2015). De plus, l'association des

données sur les cultures, l'emplacement, le rendement, la superficie et d'autres données économiques ou logistiques pertinentes, comme le coût par tonne métrique et les coûts de transport, fournit un système d'aide à la décision de haut niveau qui apporte une valeur exceptionnelle aux intervenants et aux producteurs agricoles. Néanmoins, la cartographie des types de cultures par des méthodes conventionnelles telles que le recensement et les enquêtes sur le terrain restent coûteuses, laborieuses et sujettes à un certain nombre d'erreurs. Il est donc devenu nécessaire d'utiliser des méthodes efficaces, indirectes, moins coûteuses, plus rapides et synoptiques. En effet, la télédétection est largement utilisée pour la cartographie des cultures ([Conrad et al., 2010](#) ; [Zhong et al., 2014](#) ; [Ozdarici-Ok et al., 2015](#) ; [Garcia-Pedrero et al, 2015a, 2015 b](#) ; [Pelletier et al, 2016](#) ; [Basukala et al., 2017](#)). La dérivation des paramètres agricoles à partir de la télédétection en fonction des stades phénologiques est utilisée pour de multiples applications en agriculture, telle que le suivi de la croissance des cultures ([Duarte et al., 2018](#)), la cartographie des types de cultures ([Ouzemou et al., 2015](#) ; [Azar et al., 2016a, 2016 b](#)), ainsi que les prévisions des superficies et des rendements agricoles ([Gumma et al., 2011](#)). En outre, le suivi spatio-temporel des parcelles à différentes échelles permet d'enregistrer la rotation des cultures et la productivité des sols ([Löw et al., 2013](#)).

Des capteurs à résolution spatiale modérée comme MODIS ont été utilisés en raison de leur résolution temporelle élevée et sa large fauchée ([Shahriar Pervez et al., 2014](#)). L'échelle régionale, des capteurs à haute résolution spatiale tels que TM et ETM+ de Landsat (30 m) ont été utilisés pour différencier avec précision les parcelles agricoles ([Zheng et al., 2015](#)). Cependant, cette résolution spatiale est insuffisante pour cartographier des parcelles très fragmentées et sous-dimensionnées, comme dans la présente recherche, où les parcelles de 5 ha ou moins représentent la grande majorité. Dans ce cas, la résolution de 30 m peut entraîner de nombreux pixels mixtes et une faible précision. Une résolution spatiale supérieure à 30 m est nécessaire afin d'éviter une incertitude importante dans l'estimation de la superficie des cultures et d'éviter la fusion des limites des parcelles agricoles. L'utilisation d'une très haute résolution (VHR, 1 m ou moins) permet d'analyser ces modèles agricoles complexes. Cependant, cette résolution plus élevée représente un défi pour les approches d'exploitation et de

diffusion des données disponibles (Garcia-Pedrero et al., 2015 a, 2015 b). En outre, il y a des contraintes de coût pour un grand nombre de données ainsi que la faible résolution temporelle des images VHR. D'une résolution spatiale (30 m), radiométrique et temporelle élevée, la libre disponibilité des données OLI (Operational Land Imager) collectées par le satellite Landsat 8 a créé une grande opportunité pour les responsables agricoles en termes de suivi des cultures et d'estimation de leurs superficies et rendements. À cet égard, la présente étude suggère une approche impliquant l'utilisation de données OLI NDVI à échelle réduite et de séries chronologiques couplées à un classificateur de machines d'apprentissage pour cartographier les différentes cultures dans des paysages agricoles irrigués, très fragmentés, hétérogènes et de petites tailles. L'approche consiste à utiliser l'algorithme de Gram-Schmidt Pan-sharpening pour réduire l'échelle de l'ensemble des données multispectrales de 30 m à 15 m en utilisant les images panchromatiques avec une résolution spatiale de 15 m. Par la suite, une série chronologique de l'indice NDVI dérivée des données ré-échantillonnées à 15 m a été utilisée pendant la campagne agricole 2013-2014 pour identifier et cartographier les cultures dans le PIT.

3.2 Zone d'étude

Le PIT a été choisi comme zone d'étude en raison du besoin accru d'une meilleure gestion de l'eau et d'une rotation optimale des cultures. En outre, le PIT est un système d'agriculture intensive et les producteurs ont besoin d'un système d'aide à la décision de haut niveau pour le suivi agricole. Le PIT fait partie de la plaine agricole de Tadla. Il est situé dans la région de Beni Mellal-Khenifra (**Figure 3.1**). La plaine de Tadla située au centre du Maroc, est traversée par le fleuve Oum Er Rabia. Ce dernier divise le PIT en deux zones irriguées : la zone de Beni Amir (36 000 ha) située sur la rive nord du fleuve et la zone de Beni Moussa (69 500 ha) sur la rive sud. Le PIT est alimenté en eau par les deux barrages Bin El Ouidane sur l'Oued El Abid (1500 millions de m³) et Ahmed Elhansali sur Oued Oum Er Rabia (740 millions de m³), les aquifères de Beni Amir et Beni Moussa et les eaux souterraines confinées de l'Eocène et de Turonian. Cette quantité d'eau est source de diversité des cultures dans le PIT, notamment les agrumes,

les olives, la grenade, les céréales (blé et orge), la luzerne et la betterave sucrière... (A. Hammani et al, 2006 ; Karrou et al., 2011).

La taille des parcelles est généralement très petite et 86 % des parcelles ont une superficie inférieure à 5 ha ; seulement 5 % des parcelles ont une superficie supérieure à 10 ha. Avec une altitude moyenne de 400-700 m, le PIT connaît un climat semi-aride à aride avec des températures extrêmes allant de - 6 °C en janvier à 46 °C en août enregistrées au cours des 40 dernières années (Lhissou et al., 2014). La pluviométrie annuelle moyenne est de 280 mm avec une très grande variabilité d'une année sur l'autre (El Harti et al., 2016).

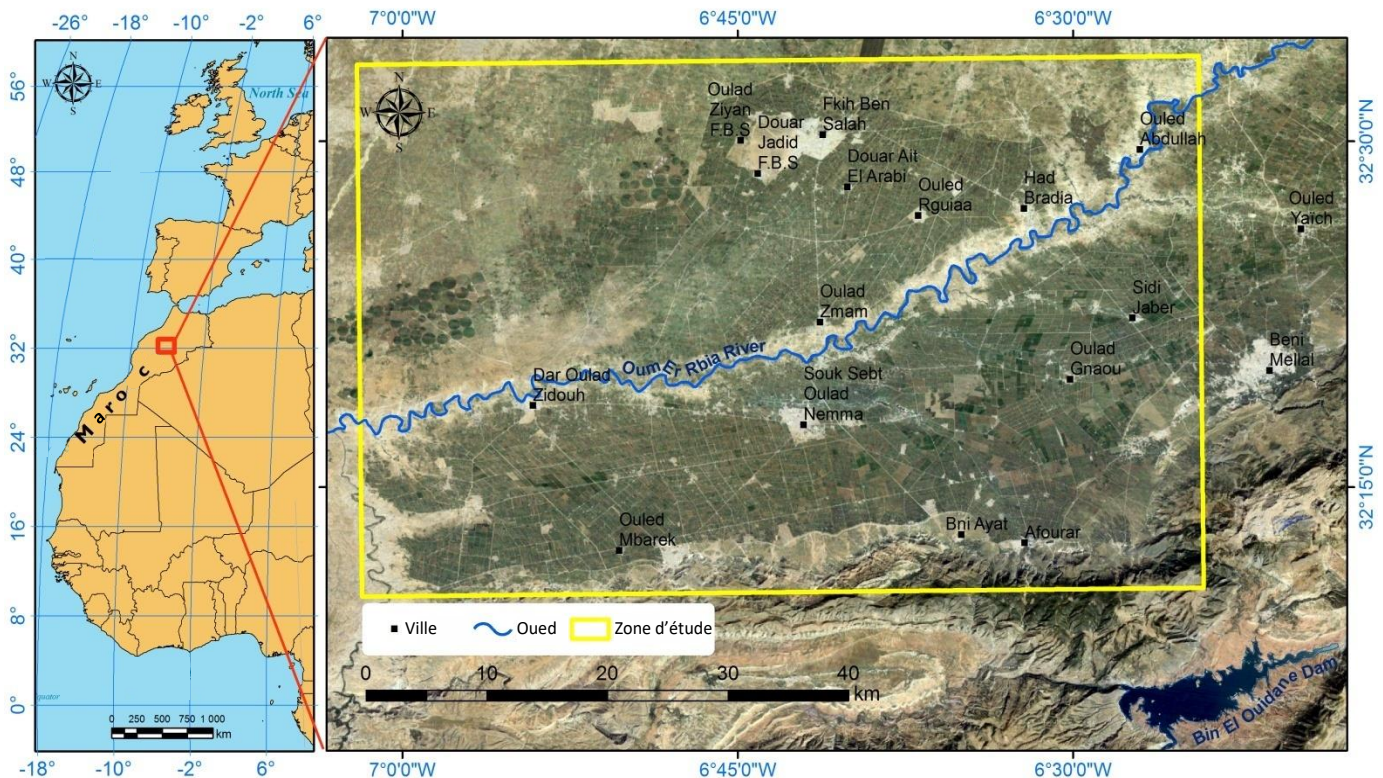


Figure 3.1 Localisation de la zone d'étude à l'échelle nationale.

3.3 Matériels et méthodes

3.3.1 Données de terrain

Des missions de terrain ont été effectuées pendant la période de post-émergence jusqu'aux stades phénologiques développés (de février à avril 2014) pour localiser les régions d'intérêt (ROI) qui ont été utilisées pour classifier nos images et évaluer la précision des cartes produites. Les ROI sont sélectionnés de manière à couvrir les principaux vergers et les grandes cultures de printemps de le PIT. Les stades habituels de croissance et de développement de ces cultures sont présentés à la figure 2. Les ROI ont été localisés dans une étude de terrain par un système global de navigation par satellite (GNSS) et une ortho-photo de 4 m de résolution spatiale. Nous avons localisé 1080 échantillons (parcelles) de différentes cultures. Parmi ces parcelles, 432 (40%) sont utilisées pour l'étalonnage et 648 (60%) pour la validation des résultats. Le nombre élevé d'échantillons est utilisé pour construire une base de données spectrale robuste. Ceci permettra de parvenir à des classifications efficaces même dans un très grand site d'étude.




Figure 3.2 Calendrier des dates de plantation et de récolte des principales cultures du TIP

Ce graphique (**Figure 3.2**) est établi à la base des données provenant de la base de données du Code BBCH, qui est une échelle destinée à identifier les stades de développement phénologique des plantes.

3.3.2 Acquisition de données satellitaires

Ce travail a été effectué sur la base d'images satellitaires temporelles du capteur OLI de Landsat 8. En tout, nous avons acquis un ensemble de 10 images de la zone d'étude sur la période d'Octobre 2013 à Juin 2014 en raison des couvertures nuageuses en hiver. Ceci nous donne au moins une image par mois sur l'ensemble de la campagne agricole. Les dix images de notre série temporelle ont donc été respectivement acquises aux dates consignées dans le **Tableau 3.1**.

OLI est l'un des deux capteurs du satellite Landsat 8/LDCM (Landsat Data Continuity Mission) lancé le 11 Février 2013. Ce capteur acquiert les images dans neuf bandes spectrales de courtes longueurs d'ondes. Ces bandes allant du visible jusqu'au moyen infrarouge, en plus de deux nouvelles bandes par rapport aux autres capteurs du programme Landsat : la bande des Aérosols et celle du Cirrus. La résolution spatiale de ce capteur varie de 15m pour la bande panchromatique à 30m (bandes multispectrales) et les produits sont délivrés avec une résolution radiométrique de 16 bits. Landsat 8 a un cycle temporel de 16 jours et se trouve à une altitude de 705km sur une orbite héliosynchrone. Il porte également un autre capteur TIRS (Thermal InfraRed Sensor) qui acquiert les données dans 2 bandes de l'infrarouge thermique (**Tableau 3.2**).

Tableau 3.1 Les dates d'acquisition des images et leurs équivalents en ordre de jour de l'année

Numéro de l'image	Dates d'Acquisitions	Jour de l'année
1	05 Octobre 2013	278
2	06 Novembre 2013	310
3	08 Décembre 2013	342
4	24 Décembre 2013	358
5	25 Janvier 2014	25
6	26 Février 2014	57
7	30 Mars 2014	89
8	15 Avril 2014	105
9	17 Mai 2014	137
10	05 Juin 2014	153

Tableau 3.2 Caractéristiques des capteurs OLI et TIRS du satellite Landsat 8

	Bandes spectrales	Longueurs d'onde (μm)	Résolution spatiale(m)
OLI	Bande 1 : Aérosols	0,43 - 0,45	30
	Bande 2 : Bleu	0,45 - 0,51	30
	Bande 3 : Vert	0,53 - 0,59	30
	Bande 4 : Rouge	0,64 - 0,67	30
	Bande 5 : Proche Infrarouge	0,85 - 0,88	30
	Bande 6 : Infrarouge moyen 1	1,57 - 1,65	30
	Bande 7 : Infrarouge moyen 2	2,11 - 2,29	30
	Bande 8 : Panchromatique	0,50 - 0,68	15
	Bande 9 : Cirrus	1,36 - 1,38	30
TIRS	Bande 10 : Infrarouge thermique (TIRS) 1	10,60 - 11,19	100m (30 après ré-échantillonnage)
	Bande 11 : Infrarouge thermique (TIRS) 2	11,50 - 12,51	100m (30 après ré-échantillonnage)

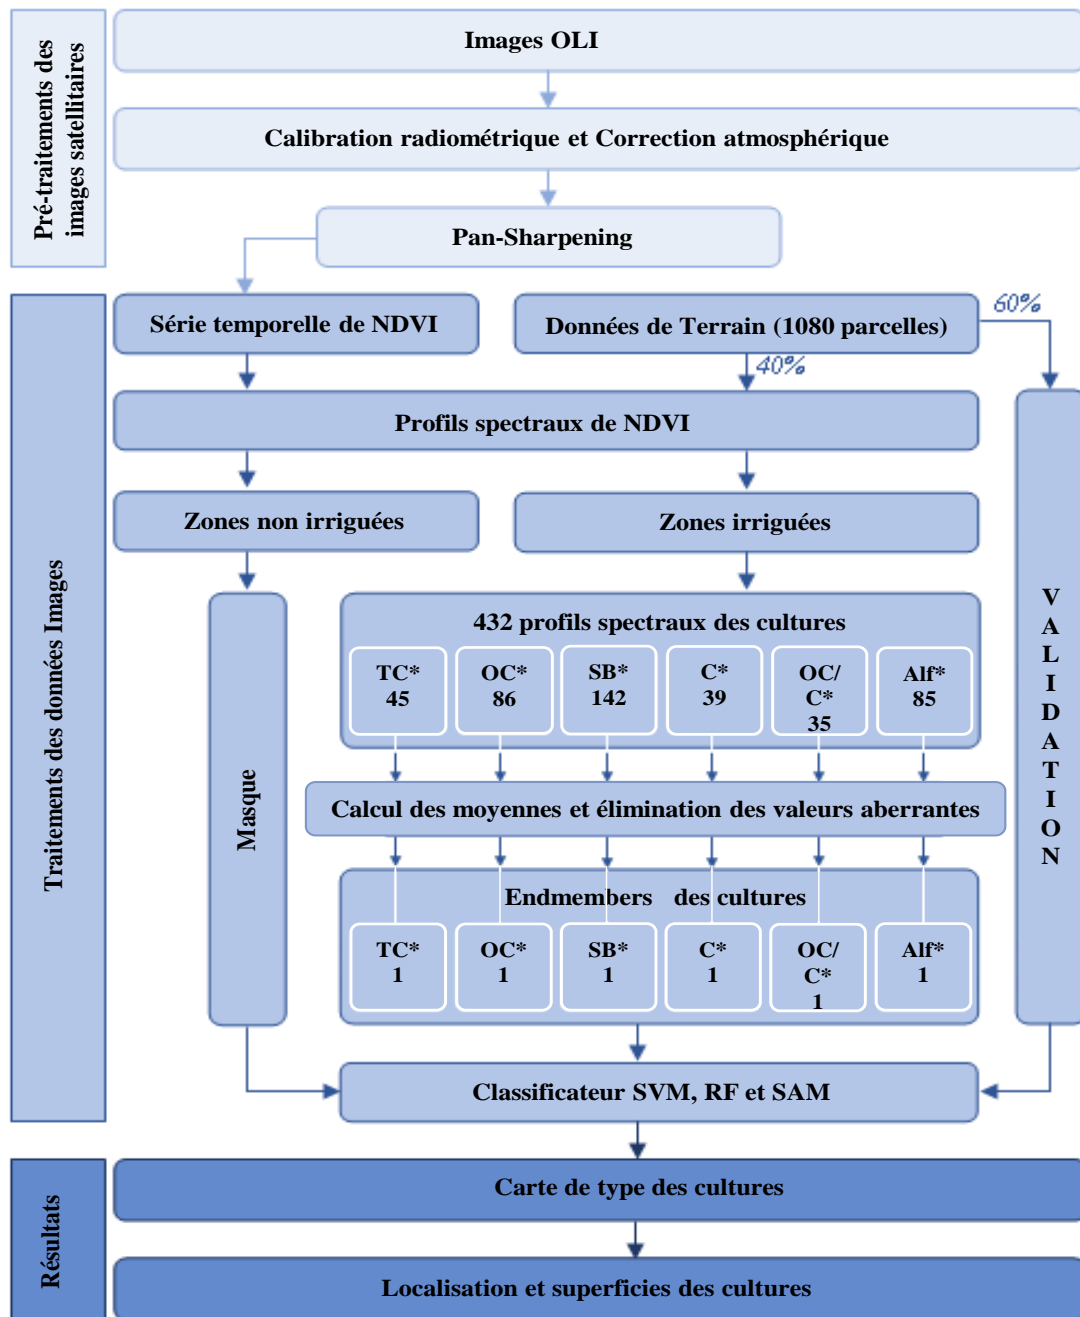
(Source: U.S. Department of the interior/ U.S. Geological Survey)

3.3.3 Méthodologie

La méthodologie du travail est résumée dans la **figure 3.3**. Premièrement, les images OLI sont étalonnées radiométriquement et corrigées des effets atmosphériques. Ensuite, elles ont été améliorées à une résolution spatiale de 15 m. L'indice NDVI est calculé pour chaque image afin de créer une série chronologique couvrant l'ensemble de l'année agricole. Les courbes spectrales ou profils spectraux (endmembers) de chaque culture ont été extraites des séries chronologiques de NDVI à la base de données de terrain géoréférencées.

Afin d'optimiser les résultats et le temps d'exécution de la méthode proposée, nous avons masqué les zones qui n'ont montré aucun intérêt pour cette étude, précisément les terrains non irrigués en utilisant leurs courbes temporelles de NDVI.

Comme nous l'avons mentionné dans la **section 3.3.1**, nous avons utilisé 432 parcelles de formation pour extraire les profils spectraux des cultures comme étape d'étalonnage. Le nombre de parcelles de formation pour les cultures arboricoles, les autres cultures, la betterave sucrière, les céréales, les autres cultures suivies par les céréales et la luzerne est respectivement de 45, 86, 142, 39, 35 et 85,. Cela a permis d'avoir des dizaines de courbes pour chaque culture. Cependant, le calcul d'une centaine de courbes par un algorithme de classification génère deux types de problèmes. Tout d'abord, la classification d'un trop grand nombre d'endmembers est trop longue et nécessite une machine puissante pour réussir le calcul, en particulier pour la classification SVM où la machine peut même planter. Deuxièmement, si jamais la classification est réussie, il est nécessaire de fusionner les classes de plusieurs endmembers d'une même culture en une seule classe, ce qui est une tâche longue et difficile et peut être une source d'erreurs. Afin d'éviter ces problèmes, nous avons utilisé la moyenne des endmembers de chaque culture tout en éliminant plusieurs courbes aberrantes dans la même classe. Par la suite, trois méthodes de classification ont été effectuées pour cartographier les types de cultures et calculer leurs surfaces (**Figure 3.3**).



* **TC**: Arboricultures, **OC**: Autres cultures, **SB**: Betterave à sucre, **C**: Céréales, **Alf**: Luzerne, **OC/C**: Céréales précédées par d'autres cultures.

Figure 3.3 Organigramme de la méthodologie utilisée.

3.3.4 Prétraitement des images satellitaires

3.3.4.1 Calibration radiométrique et correction atmosphérique

Avant de pouvoir exploiter les données brutes acquises, celles-ci doivent être prétraitées en passant par les étapes de calibrations radiométriques et de corrections atmosphériques. Ces dernières sont indispensables pour éliminer les différentes sources d'erreurs notamment les erreurs dues aux irrégularités du capteur et aux effets atmosphériques tels que la diffusion et l'absorption ([Song et al., 2001](#) ; [Du et al., 2002](#)). Ainsi, nous pourrions transformer nos données brutes (valeurs numériques) en valeurs de réflectance réelles au sol effectivement mesurées par le capteur au moment de l'acquisition des images et obtenir donc des données significatives. Les données brutes ou valeurs numériques reflétées par chaque pixel sont transformées en valeurs de radiance puis de réflectance apparente ou au sommet de l'atmosphère (TOA : Top of Atmosphere) en exploitant les valeurs du gain et du biais (offset), de l'éclairement solaire et son élévation et le temps d'acquisition de l'image présentes dans les métadonnées de l'image.

Les dix images de la série temporelle provenant des calibrations radiométriques ne reflètent pour le moment que des valeurs de réflectance apparente, toujours affectées par les erreurs liées aux effets atmosphériques notamment la diffusion. A cette étape, on a utilisé un bon outil de correction atmosphérique. Dark Object Subtraction (DOS) développée par [Chavez \(1988\)](#) a été utilisée pour éliminer les effets atmosphériques et obtenir la réflectance au sol en raison de sa simplicité et de ses résultats satisfaisants dans l'élimination des effets atmosphériques ([Ouaidrari et Vermote, 1999](#) ; [Song et al, 2001](#) ; [Zhang et al, 2010](#) ; [Vanonckelen et al, 2013](#)). L'outil Dark Subtraction élimine les effets de la diffusion atmosphérique en soustrayant de chaque bande de l'image, la valeur du pixel le plus sombre. Cette valeur peut différer selon les 3 méthodes proposées par l'outil :

- *Band minimum subtraction* : cette méthode prend automatiquement la valeur minimale de chaque bande spectrale pour la soustraction ;
- *Region of Interest subtraction* : cette valeur est une moyenne basée sur une région d'intérêt pour chaque bande spectrale ;

- *User Value subtraction* : une valeur arbitraire à spécifier par l'utilisateur.

3.3.4.2 Le pan-sharpening des images multispectrales de 30m vers 15m de résolution spatiale

En ce qui concerne la petite taille des parcelles (0-5 ha), il était nécessaire d'améliorer la résolution spatiale des données d'image afin d'augmenter la précision des résultats. Les images multispectrales d'une résolution spatiale de 30 m sont fusionnées avec leurs images panchromatiques respectives d'une résolution spatiale de 15 m à l'aide de l'algorithme Gram-Schmidt de pan-sharpening ([Laben et Brower, 2000](#)).

Le Pan Sharpening ou resolution merge, image integration, ou encore multi-sensor data fusion ([Vijayaraj et al, 2006](#) ; [Kumar et al, 2009](#)) est un processus qui consiste à fusionner une image panchromatique à haute résolution spatiale avec les bandes d'une image multispectrale à faible résolution spatiale afin de créer une nouvelle image à haute résolution spatiale et qui préserve l'information spectrale.

Grace à cette technique, on obtient une nouvelle image multispectrale avec la résolution spatiale de l'image panchromatique.

Plusieurs algorithmes ont été développés pour cette technique de fusion d'images à savoir l'algorithme de Gram-Schmidt (GS) que nous utiliserons pour rehausser la résolution de nos images, Ehler, HIS (hue-saturation-intensity), High pass filter (HPF), W-PCA(Wavelet-Principal Component Analysis) entre autres.

Dans cette panoplie d'algorithmes, le Gram-Schmidt Pan Sharpening a été la méthode de fusion adoptée tout simplement parce que c'est l'un des algorithmes les plus répandus et que c'est une méthode largement utilisée ([T.Maurer, 2013](#)). Certes d'après les études faites à ce sujet ([C. Padwick et al, 2010](#) ; [Yuhendra et al, 2012](#)), d'autres algorithmes sont plus précis, mais celui-ci n'a jamais été mal classé en termes de performances dans ces évaluations. Il convient donc à notre travail.

L'algorithme de Gram-Schmidt fusionne les images en simulant tout d'abord une bande panchromatique à partir des bandes multispectrales à basse résolution spatiale. La transformation de Gram Schmidt est alors effectuée sur la bande panchromatique simulée et les bandes multispectrales, en utilisant la bande panchromatique simulée

comme la première bande. L'image panchromatique à haute résolution spatiale est échangée contre cette première bande et la transformation inverse de Gram Schmidt est enfin appliquée pour former les bandes spectrales de l'image fusionnée.

En général, les algorithmes de Pan Sharpening font intervenir des étapes de :

- *Prétraitement* : pour s'assurer des corrections géométriques et projeter les images panchromatique et multispectrales dans le même système s'ils proviennent de capteurs différents, avant leur fusion.
- *Rééchantillonnage* : les pixels de l'image multispectrale sont rééchantillonnés pour avoir la même résolution que ceux de l'image panchromatique.

Cette étape de rééchantillonnage peut se faire avec trois procédés différents (**Figure 3.4**):

- Le plus proche voisin (nearest neighbour) : c'est une technique de rééchantillonnage qui consiste à assigner à chaque nouveau pixel dans l'image de sortie, la valeur du pixel le plus près dans l'image d'entrée ;
- Interpolation bilinéaire (bilinear interpolation) : cette technique de rééchantillonnage calcule la valeur de chaque nouveau pixel en se basant sur la moyenne pondérée des valeurs des 4 pixels les plus proches (horizontalement comme verticalement) l'entourant dans l'image d'origine ;
- Convolution cubique (cubic convolution) : La valeur de chaque nouveau pixel est une moyenne pondérée des valeurs des 16 pixels les plus proches l'entourant dans l'image d'origine.




Figure 3.4 Les méthodes de rééchantillonnage.

De ces trois méthodes, certes l'interpolation bilinéaire et la convolution cubique résultent de nouvelles valeurs de pixels contrairement au plus proche voisin, mais ces techniques produisent des images plus douces ([Ressources naturelles Canada](#)). Ils donnent donc de meilleurs résultats. Après plusieurs tests, la méthode convolution cubique a été la méthode de rééchantillonnage utilisée pour la technique de Pan Sharpening.

Ainsi en appliquant l'algorithme de Gram-Schmidt avec la convolution cubique comme méthode de rééchantillonnage, à nos images multispectrales de 30m et panchromatiques à 15m, nous avons pu obtenir une nouvelle série chronologique de dix images multispectrales de résolution spatiale de 15m. La **figure 3.5** ci-dessous montre une illustration des résultats du procédé utilisé.




Figure 3.5 Illustration de la technique de Gram-Schmidt Pan Sharpening

La méthode utilisée a permis une bonne conservation de l'information spectrale de l'image à une résolution spatiale de 15 m comme le montre la **figure 3.6** en comparant les données NDVI normales et les données NDVI ré-échantillonnées.

Comme le montre la **figure 3.6**, **(A)** et **(A')** montrent un pixel P1 à l'extrémité d'une petite parcelle végétative, respectivement en taille de pixel normale et en taille de pixel ré-échantillonné. Cette dernière permet une meilleure délimitation de la zone de végétation. **(B)** et **(B')** montrent un pixel P2 strictement à l'intérieur d'une parcelle végétative de taille de pixel normale et un pixel ré-échantillonné. De même, des

données affinées permettent d'établir une bonne distinction entre le sol nu, la végétation et les routes. En outre, **(A'')** et **(B'')** montrent l'inflexion de la réflectance spectrale pour les 4 sous-pixels ré-échantillonnés par rapport à leur pixel racine (30 m), respectivement pour P1 et P2.

En ce qui concerne la série chronologique des valeurs NDVI, l'inflexion entre les sous-pixels rééchantillonnés et leur pixel racine est montrée sur la **figure 3.6 (A''' et B''')** respectivement pour P1 et P2,. Les courbes de réflectance spectrale et les valeurs NDVI temporelles de P1 montrent une légère inflexion entre le pixel racine de 30 m et ses sous-pixels de 15 m, ce qui est normal en raison du mélange spatial d'un pixel situé à la limite de la parcelle de végétation près du sol nu mais sans dégrader la qualité NDVI. Par contre, il n'y a pas d'inflexion significative entre les données spectrales de racine et les données ré-échantillonnées au pixel P2 (**figure 3.6 B'' et B'''**), qui est purement végétation car il est situé au centre de la parcelle de culture. Tous ces points démontrent que les images de 15 m ré-échantillonnées n'ont pas été contaminées pendant le processus de ré-échantillonnage et que ce dernier n'a pas modifié la qualité spectrale des données de NDVI, mais, au contraire, il a amélioré la délimitation des parcelles de cultures en permettant de lisser davantage les routes et les limites des parcelles comme le montrent les **figures 3.6 (A' et B')**. C'est très important pour accroître la précision de l'estimation des superficies cultivées, l'un des principaux objectifs de la présente étude.

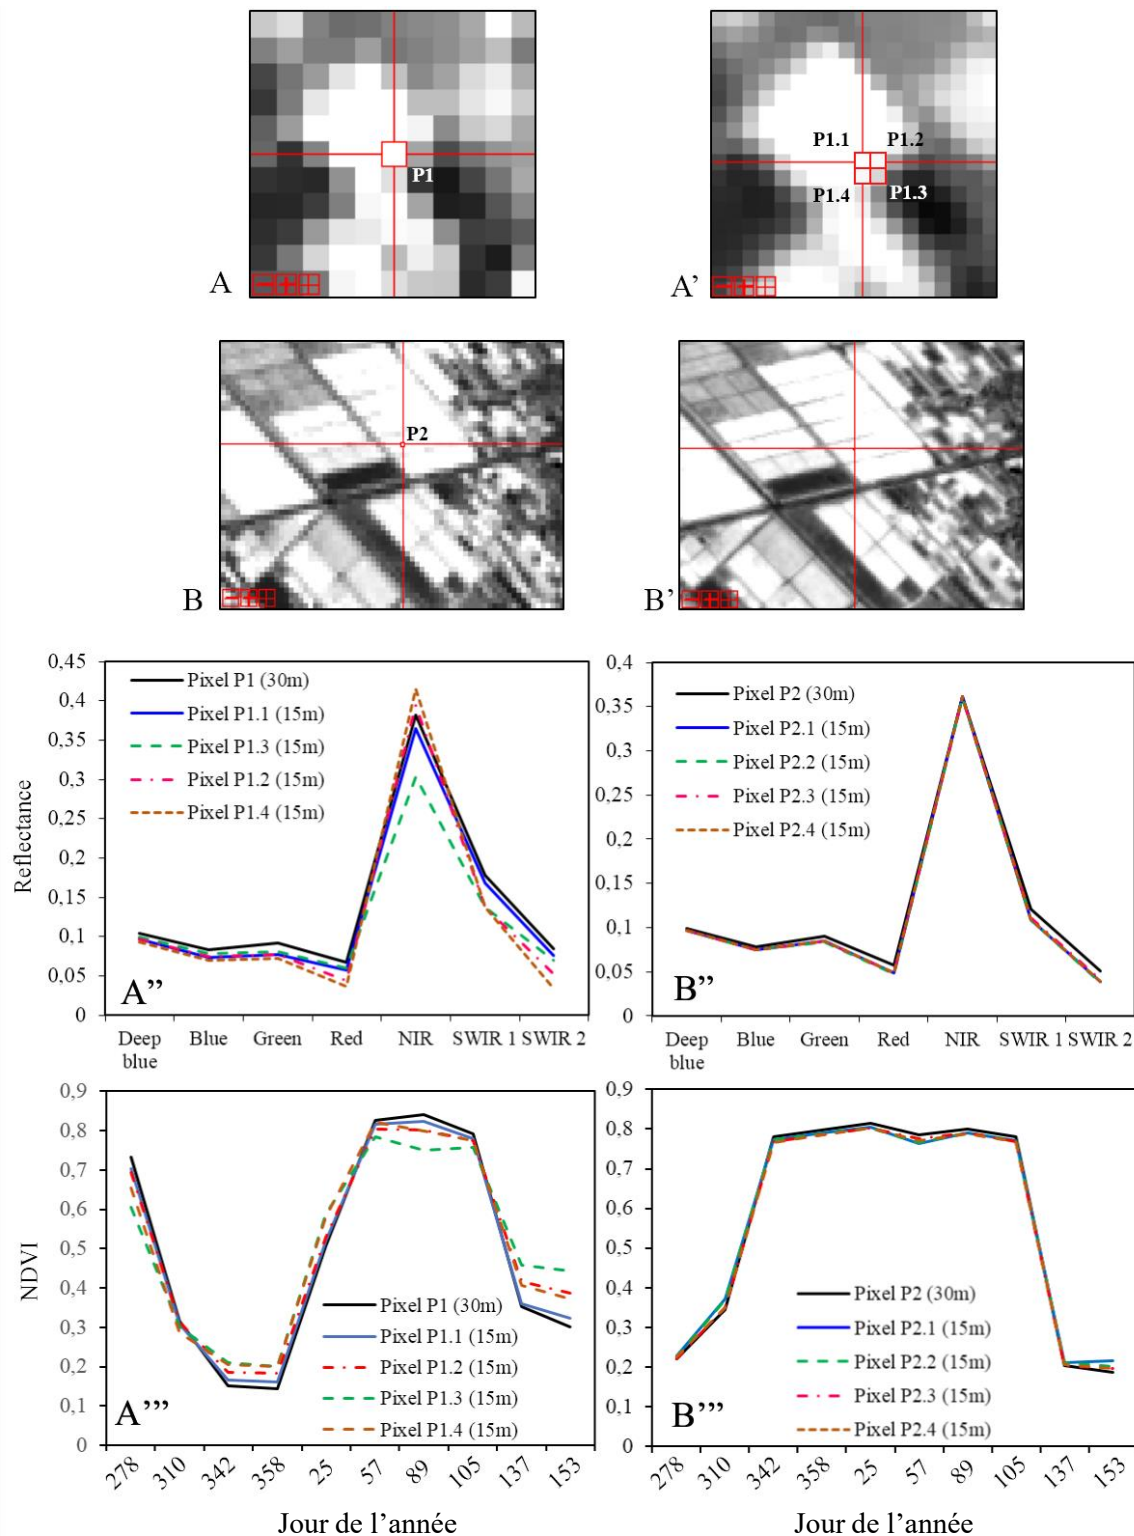


Figure 3.6 Effets du pan-sharpening sur les données de NDVI.

3.3.5 Traitement des images satellitaires

3.3.5.1 Calcul de NDVI (Indices de végétation par différence normalisée) et profils spectraux

a) Calcul de NDVI

A ce niveau, toutes nos données sont prêtes à être exploitées. Nous pouvons donc commencer à extraire l'information qui nous intéresse de nos images chronologiques à savoir le calcul des indices de végétation par différence normalisée (NDVI). Le NDVI est un indice de végétation comme son nom l'indique parmi tant d'autres, notamment le GNDVI (Green Normalized Vegetation Indice), le NDRE (Normalized Difference Red Edge Index),...etc.

Le NDVI qui est l'indice de végétation le plus connu et le plus utilisé (Rouse and Haas, 1973 ; Tucker, 1979) est un indicateur qui décrit la verdure, la densité relative et la santé de la végétation pour chaque pixel d'une image satellite. Il est calculé par la formule suivante (**Equation 3.1**) :

$$NDVI = \frac{PIR - R}{PIR + R} \quad \text{(Equation 3.1)}$$

Avec :

PIR : La valeur du pixel dans la bande du proche infrarouge

R : La valeur du pixel dans la bande du rouge.

Cet indice varie entre -1 et 1. Les valeurs négatives correspondent généralement à l'eau, la neige ou encore aux nuages. Les valeurs très faibles entre 0 et 0,1 peuvent caractériser les roches, le sol ou le sable. Celles comprises entre 0,2 et 0,5 reflètent la plupart du temps de la végétation clairsemée, des arbustes, de la prairie ou des cultures sénescentes contrairement aux valeurs élevées entre 0,5 et 1 qui montrent des zones de végétations denses ou des cultures à leur stade de croissance de pointe.

L'utilité du NDVI se traduit dans la surveillance de la végétation où il aide à la détection des zones où la végétation est en plein essor et celle des zones où elle est en

régression ceci pouvant s'expliquer par les conséquences des activités humaines telles que déforestation, feux entre autres. Il permet également le suivi de la santé de la végétation notamment dans la détermination des zones où celle-ci subit un stress. Et particulièrement grâce à cet indice, on peut détecter les changements de stade phénologique des plantes et c'est ce qui nous intéresse dans ce travail dans la mesure où nous allons nous baser sur ces stades pour différencier les cultures du périmètre irrigué. Ainsi, les valeurs de NDVI peuvent être moyennées à travers le temps pour réaliser une étude temporelle comme celle que nous allons faire en combinant les valeurs de NDVI depuis la première image de notre série chronologique jusqu'à la dernière pour les regrouper dans une seule image.

Par ce principe, la série chronologique de NDVI sera donc créée et le procédé est illustré par la **figure 3.7** ci-dessous :




Figure 3.7 Illustration du procédé de création de la série chronologique de NDVI.

b) Extraction des profils spectraux de NDVI des cultures

La série chronologique de NDVI étant créée par le regroupement des valeurs de NDVI de toutes nos images, on peut dès lors commencer notre analyse afin de déterminer les signatures types des différentes cultures que nous voulons classifier en l'occurrence : la betterave sucrière, la luzerne, les céréales (où l'on a distingué un autre

type précédé par d'autres activités agricoles) et tout ce qui est arboriculture notamment agrumes, grenadiers, olives entre autres.

Cette analyse qui au final nous permettra de déterminer les profils spectraux correspondants à chaque culture, n'est rien de plus qu'une étape de collection d'informations sur la réalité du terrain. Il s'agit donc de relever sur le terrain, les emplacements des différentes cultures à classer dans la série temporelle créée et d'en extraire les signatures types une fois au bureau grâce aux coordonnées relevées.

Ainsi, les graphiques de la **figure 3.8** ci-après présentent chacun les profils types de NDVI des cultures que nous avons obtenus sur la base de la série chronologique créée.

Une série chronologique était créée par la combinaison en une seule image des valeurs de NDVI depuis la première image de la campagne agricole jusqu'à la dernière. Cette dernière a servi à déterminer les stades phénologiques critiques de chaque culture et d'extraire leurs profils spectraux typiques (**Figure 3.8**).

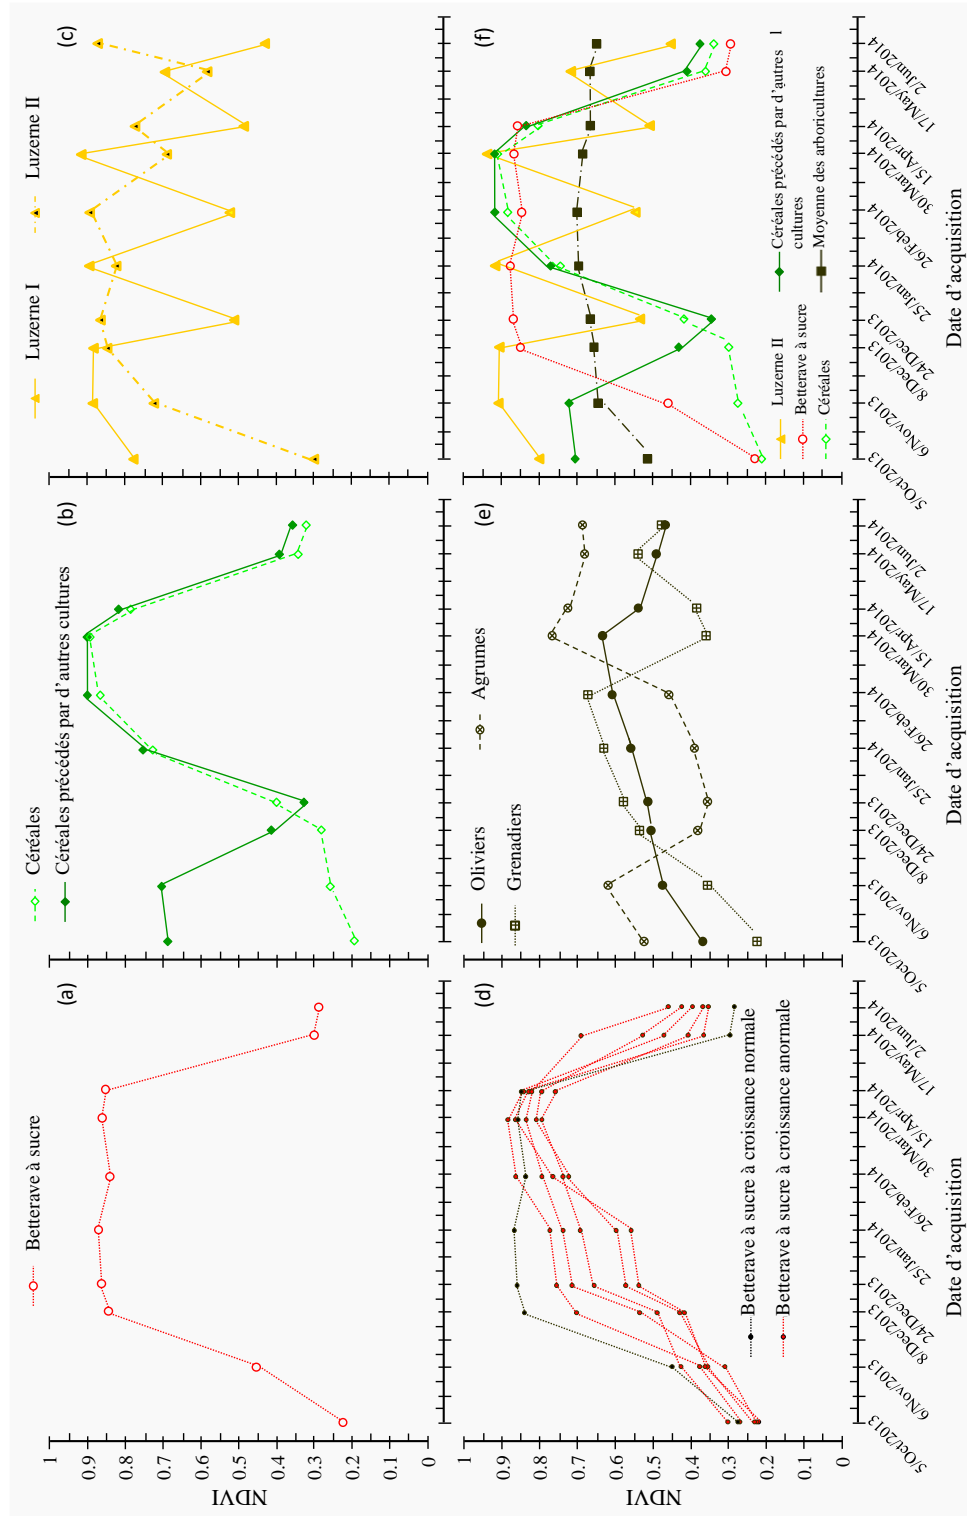


Figure 3.8 Profils spectraux de NDVI pour les principaux types de cultures cultivées en 2014

Sur ces graphes on peut s'apercevoir de l'évolution des valeurs de NDVI des différentes cultures en fonction des dates d'acquisition des images de la série. Et sur le **graphe (f)**, nous constatons que la distinction entre les cultures est nette. Nous pouvons facilement différencier le profil presque stagnant des cultures arboricoles, du profil en zigzag de la luzerne, de même que des profils de la betterave et des deux types de céréales : non précédées et précédées par d'autres cultures.

3.3.5.2 Les classifications RF, SVM et SAM

À la suite de la détermination et de l'extraction des signatures spectrales relatives à chaque type de culture, l'objectif spécifique de cette étape est d'arriver à classifier les cultures. Trois algorithmes de classification ont été adoptés pour l'étude à savoir : Random Forest (RF), Support Vector Machine(SVM) et Spectral Angel Mapper (SAM). En constituant nos régions d'intérêt à partir des profils spectraux de NDVI identifiés plus haut (**Figure 3.8**), nous allons pouvoir localiser les cultures qui nous intéressent dans le périmètre irrigué.

a) Classification RF

RF ([Breiman, 2001](#)) est un ensemble d'arbres de classification basé sur les classificateurs d'arbre de décision CART (Classification And Regression Trees) ([Breiman et al., 1984](#)). Chaque arbre contribue avec un seul vote pour l'affectation de la classe la plus fréquente aux données d'entrée. L'un des plus grands atouts de la RF, outre sa grande précision et sa robustesse face aux valeurs aberrantes et au bruit, est le calcul de différents indicateurs de diagnostic interne ([Breiman, 2001](#)). L'algorithme utilise son estimation d'erreur interne et chaque arbre est construit en effectuant un algorithme d'apprentissage individuel qui divise la variable d'entrée. En fait, RF construit un certain nombre d'arbres de décision, en utilisant un sous-ensemble aléatoire d'environ 2/3 de l'ensemble de données pour l'apprentissage de l'algorithme d'apprentissage interne, tout en conservant le tiers restant pour l'estimation des erreurs du processus d'apprentissage ([Nitze et al. 2015](#); [Pelletier et al., 2016](#))

b) Classification SVM

SVM est une méthode mathématique permettant de résoudre les problèmes de classification de données complexes et hétérogènes. C'est une méthode statistique, non

paramétrique et supervisée (Pal et Mather, 2005). La force de cette classification réside dans sa capacité à généraliser à partir de petites données relatives à des régions d'intérêt pour l'analyse d'images par pixels (Shao et Lunetta, 2012; Hao et al., 2015) et pour l'analyse d'images par objets (Teodoro et Araujo, 2016). Cette méthode de classification est largement utilisée en télédétection pour la cartographie des types de cultures (Devadas et al., 2012; Zheng et al., 2015).

SVM repose essentiellement sur une adaptation d'un hyperplan séparateur, qui offre une meilleure séparation entre les classes dans un espace multidimensionnel. Cet hyperplan est le domaine de décision sur lequel la séparation optimale des classes sera effectuée. Les vecteurs de support sont définis par les données situées en marge de l'hyperplan. La distance entre les classes séparées par l'hyperplan est appelée marge. L'algorithme SVM utilise une fonction du noyau (Kernel), qui projette les données initiales dans un nouvel espace de fonctions de dimension supérieure afin de rendre les données séparables linéairement (Bruzzone et Carlin, 2006; Waske et al., 2009; Volpi et al., 2013). En général, plus la marge est grande, plus l'erreur de classification est faible.

Dans notre étude, nous avons utilisé une classification SVM non linéaire avec le noyau de base radial (kernel RBF), qui est largement utilisé et donne de meilleurs résultats par rapport aux autres noyaux (linéaire, polynomial ou gaussien) dans la cartographie des types de cultures (Löw et al. ., 2013) et dans d'autres applications (Huang et al., 2002, 2008; Joachims, 1998). L'équation SVM pour la classification de deux classes d'information est donnée comme suit (Brandt et Mather, 2009):

$$f(x) = \text{sign}(\sum_i^N \alpha_i y_i \cdot K(x, x_i) + b) \quad \text{(Equation 3.2)}$$

Où x_i représente un vecteur de support pour le cas d'apprentissage i , y_i est le libellé de la classe d'informations, $K(x, x_i)$ est la fonction du noyau, b est la constante d'interception, N est le nombre de vecteurs de support et α_i sont des constantes déterminées par maximisation. Le noyau utilisé est alors le suivant (Hsu et al., 2010):

$$k(x_i, y_i) = \exp(-g \|x_i - x_j\|^2), g > 0 \quad \text{(Equation 3.3)}$$

Où g est le terme gamma dans le noyau RBF, qui doit être prédéfini par l'utilisateur en tant qu'entrée. De plus, le paramètre de pénalité C de l'algorithme SVM doit également être prédéfini. L'augmentation de la valeur de C augmente le coût des points anormalement classés et conduit à la création d'un modèle SVM plus précis. Ainsi, la valeur sélectionnée est élevée et égale à 100. En ce qui concerne la valeur g , l'inverse du nombre de bandes est un choix raisonnable mais non parfait, car la valeur gamma contrôle la transformation des données d'entrée en un espace de grande dimension. (Exelis Visual Information Solutions, 2016). En conséquence, plusieurs valeurs proches de l'inverse du nombre de bandes d'images d'entrée ont été testées et validées par recoupement (Cross-Validation) à l'aide du logiciel SAGA GIS. La valeur qui a donné les meilleurs résultats a été utilisée pour la cartographie des types de cultures.

c) Classification SAM

Le classifieur SAM mesure la similarité spectrale entre deux spectres (Kruse et al., 1993; Girouard et al., 2004; Zhang et Li, 2014). Il est physiquement conçu pour convertir les valeurs de pixels de différentes bandes en un vecteur. La classification est effectuée en calculant et en comparant l'angle entre les spectres de référence et les spectres inconnus dans un espace dont la dimensionnalité est égale au nombre de bandes utilisées (Kruse et al., 1993; Rowan et Mars, 2003; Li et al., 2012). Les petits angles entre les deux spectres indiquent une forte similitude.

SAM est l'une des mesures de similarité spectrale les plus populaires et les plus largement utilisées dans les applications de télédétection (Crósta et al., 1998; Chein, 2000; Dennison et al., 2004; Wang et al., 2009; Cho et al., 2010; Ghiyamat et al., 2013). SAM comme indiqué dans l'équation 3.4, mesure la similarité spectrale en détectant l'angle θ existant entre une signature spectrale inconnue β des pixels de l'image à n bandes et une signature spectrale de référence α (Keshava, 2004).

$$\theta(\alpha, \beta) = \arccos\left(\frac{\langle \alpha, \beta \rangle}{\|\alpha\| \|\beta\|}\right) = \arccos\left(\frac{\sum_{i=0}^{n-1} \alpha_i \beta_i}{\sqrt{\sum_{i=0}^{n-1} \alpha_i^2} \sqrt{\sum_{i=0}^{n-1} \beta_i^2}}\right) \quad \text{(Equation 3.4)}$$

Où α_i et β_i représentent la valeur de réflectance de α et β , respectivement.

Les deux algorithmes de classification SVM et SAM ont été calculés à l'aide du logiciel SAGA GIS, tandis que la classification RF a été calculée par le logiciel EnMAPBox afin de cartographier le type de culture du PIT en classant les images empilées de la série temporelle de NDVI.

3.3.5.1 Masque des terrains non-irrigué

Une classification directe des cultures après la correction et le traitement des images ne va jamais donner des résultats précis. En effet, il demeure quelques éléments à éliminer sur cette classification, notamment les cultures non-irriguées, le sol nu, les nuages isolés, le bâti, l'eau et les régions montagneuses entre autres. D'abord, on a séparé la plaine et la montagne en s'appuyant sur le modèle numérique de terrain (MNT) de la zone d'étude. Ensuite, les nuages ont été éliminés en ressortant leurs emplacements par la création d'un fichier de forme en traitant l'image du produit (Qualité) délivré par l'USGS. Puis, on a séparé les zones de cultures des zones non cultivées en se basant sur le changement du taux de chlorophylle durant la campagne agricole ([Baojuan Zheng et al., 2015](#)). On a détecté et maîtrisé ce changement facilement en utilisant la série chronologique des données NDVI. Ceci nous a permis d'isoler la végétation de ce qu'est non-végétation (Bâti, eau, sol nu...).

Enfin, on a éliminé les cultures non-irriguées à la base des caractéristiques phénologiques et les différentes réponses spectrales-temporelle présentées par les deux catégories de cultures ([Brian D. Wardlow et al., 2007](#)). Les cultures non-irriguées ont toujours un cycle de croissance plus court que les cultures irriguées, en plus, les valeurs maximales de NDVI pendant la période végétative sont plus élevées chez les cultures irriguées. A ce niveau, on a pu garder les composantes qui nous intéressent en appliquant le masque obtenu par l'utilisation de la série chronologique des données de NDVI, le MNT et l'image de qualité du capteur OLI de notre zone d'étude.

3.4 Résultats et discussions

3.4.1 Surface irriguées / non-irriguées

Bien que l'identification des cultures pour une bonne gestion de l'eau soit l'objet de cette recherche, on a essayé de répondre aux questions liées à l'emplacement des types de cultures à l'aide de la télédétection dans le périmètre irrigué du Tadla, qui est choisi comme un site de référence typique au Maroc. Les terres cultivables irriguées, représentaient environ 58,76% de la superficie totale de la zone d'étude en fonction du résultat des superficies irriguées/non-irriguées dérivé de la série temporelle des données NDVI d'OLI. Le résultat a montré que la classe des surfaces irriguées est fortement compatible avec la couverture terrestre réelle du périmètre irrigué de Tadla. L'étendue des surfaces irriguées soit en grande hydraulique, en moyenne hydraulique ou en pompage des deux rives de Beni Amir et Beni Moussa était parfaitement cartographiée. Les nuages, le bâti, les sols nus, les céréales non irrigués, les herbes, les zones de forêt (zone montagneuse) et les corps d'eaux ont été également cartographiés pour qu'ils soient éliminés de la carte finale des types de cultures. La similitude de la réponse spectrale entre l'arboriculture et les arbres de clôture a posé une difficulté au niveau de la discrimination entre les deux classes dans le but d'éliminer la deuxième.

3.4.2 Courbes phénologiques des cultures

Les cultures principales du PIT sont la betterave à sucre (SB), la luzerne (Alf), les céréales (C), les autres cultures suivies par les céréales (OC / C) et les arbres fruitiers (TC), y compris les agrumes, les grenadiers et les oliviers (ORMVAT, 2015). Les courbes spectrales NDVI de ces cultures diffèrent considérablement. Ils ont été utilisés pour identifier les changements et les stades phénologiques du cycle de croissance des cultures (**Figure 3.8.f**). Les variations de courbe pour le même type de culture ont été observées (**Figure 3.8.d**). Ces variations sont liées aux facteurs de production, à savoir la date de plantation, le type de sol, la qualité des semences et les pratiques agricoles (irrigation, désherbage et fertilisation). La betterave à sucre peut être plantée de mi-septembre vers le début de mi-décembre et récoltée de mi-avril à mi-juin. Cela se reflète

dans les courbes spectrales NDVI des betteraves à sucre, qui commencent à augmenter d'octobre à décembre. Ensuite, il reste presque constant et élevé jusqu'à la mi-avril. Ensuite, il montre une diminution nette liée à la période de récolte (**Figure 3.8.a**). Le blé et l'orge sont regroupés et classés dans un seul groupe (céréales) en raison de leur ressemblance phonologique; leur exploitation commence du début novembre au début décembre et elle est récoltée à la mi-mai et au plus tard au début de juin. De plus, nous avons distingué les céréales semées sur un sol nu et les céréales précédées par une autre culture en se basant sur leur profil spectral de NDVI. Le second type de céréale montre une augmentation de l'indice NDVI à la mi-décembre et une baisse en février, contrairement aux céréales précédées d'un sol nu. Après cela, les deux types commencent à diminuer en mars (**Figure 3.8.b**). La luzerne est une culture fourragère en raison de ses hautes performances, de sa longue durée de vie (3 à 4 ans) et de sa capacité de repousse. Elle est généralement semée d'octobre à février. En effet, les valeurs NDVI de cette culture montrent un changement soudain qui se reproduit tout au long de son cycle de croissance en raison de l'alternance entre la récolte et la repousse. La **figure 3.8.c** montre l'évolution de la luzerne au cours de la première année (Alfalfa I) et après un an de croissance (Alfalfa II). Les agrumes, les grenadiers et les oliviers sont combinés en une seule classe de cultures (Arbres). Les valeurs de NDVI de cette classe sont toujours supérieures à 0,3 (**Figure 3.8.e**), ce qui est dû au taux de chlorophylle presque durable dans ces cultures. Les légères diminutions des valeurs de NDVI des cultures arboricoles (**Figure 3.8.e**) sont dues à la perte de feuilles (par exemple, les grenadiers) ou à des pratiques agricoles (par exemple, la taille des agrumes). Les oliviers conservent à peu près le même taux de croissance et de verdure avec de très légères modifications de leurs valeurs de NDVI, ce qui se traduit par une durabilité élevée en termes de taux de chlorophylle (**Figure 3.8.e**).

Les classificateurs RF, SVM et SAM ont été utilisés pour classer les séries chronologiques de données NDVI et établir l'inventaire de la carte de cultures du PIT de la saison agricole 2014. Les cartes produites ont été évaluées en calculant la précision globale (OA) et le coefficient kappa pour chaque classification.

Tableau 3.3 Mesures de précision des classifications RF, SVM et SAM.

	Précision du producteur (PA) (%)			Précision de l'utilisateur (UA) (%)		
	RF	SVM	SAM	RF	SVM	SAM
TC ^a	87.15	91.10	51.43	99.55	96.37	90.48
OC ^a	95.45	86.26	0.09	76.13	69.84	0.04
SB ^a	94.61	88.82	93.57	85.51	77.33	94.35
C ^a	91.34	99.27	99.22	89.64	71.65	74.41
Alf ^a	78.66	45.00	33.56	81.69	68.00	19.10
OC/C ^a	99.34	78.19	76.09	79.36	98.47	96.09
Précision globale (OA) (%)				89.26	85.27	55.06
Coefficient Kappa				0.85	0.80	0.44

^a **TC**: Arboricultures ; **OC**: Autres Cultures ; **SB**: Betterave à sucre ; **C**: Céréales ; **Alf**: Luzerne ; **OC/C**: Céréales précédées par d'autres cultures.

Les mesures de précision RF, SVM et SAM sont illustrées dans le **tableau 3.3**. Les valeurs OA de RF, SVM et SAM sont respectivement de 89,26%, 85,27% et 57,17%, tandis que le coefficient kappa est de 85%, 80% et 44%. Ainsi, les coefficients OA et kappa de la SVM sont respectivement 28% et 37% plus élevés que ceux de la SAM, alors que RF surperforme légèrement la SVM de 4% et 5% des coefficients OA et kappa, respectivement. En ce qui concerne la classification RF et SVM, les erreurs observées sont généralement dues à la similarité des courbes phénologiques décrivant chaque classe de culture. La luzerne affichait la précision la plus faible (précision du producteur de 78,66%, 45% et 33,56% et précision de l'utilisateur de 81,69%, 68% et 19,1%, respectivement pour RF, SVM et SAM). RF et SVM ont montré les mêmes confusions mais toujours avec un avantage de RF. Pour les deux classifications, plusieurs pixels de la luzerne ont été classés à tort dans les cultures d'arbres. Cette confusion est due à la ressemblance entre les courbes phénologiques de la luzerne et l'évolution des agrumes. De plus, les pixels les plus confus de la betterave à sucre ont été classés à tort dans la classe de la luzerne, car ils sont phénologiquement similaires à la betterave à sucre arrachée après le mi-juin et qui se caractérisent parfois par une légère oscillation des valeurs de NDVI provoquée par des maladies ou un stress hydrique. La classe des autres cultures était la classe la plus confuse avec la luzerne et les arbres. D'une part, cette confusion est liée à la diversité des espèces au sein de la

classe des autres cultures dans la zone d'étude. Cette classe comprend plusieurs cultures de légumes (principalement des oignons, des aubergines, des tomates, des pommes de terre, des carottes, des navets, des haricots, du sésame, du nioka, du maïs, des melons et des pastèques) d'une superficie annuelle de 7 000 ha dans la zone d'étude. D'autre part, cela est dû à la grande variabilité des courbes phénologiques due aux différentes pratiques agricoles de la luzerne (par exemple, la variation des temps de coupe d'une parcelle à l'autre) et à la légère oscillation des agrumes. Nous notons que la RF a légèrement surperformé la SVM, en particulier pour la classe de la luzerne, où la RF était moins confuse que la SVM. Seules les catégories de céréales et d'arbres pour lesquels SVM présentait moins d'erreurs d'omission que la RF (PA plus élevé, **tableau 3.3**).

Les différences entre les deux classificateurs peuvent également provenir des types de cultures. La question de la confusion de la luzerne est en accord avec les résultats de [Zheng et al. \(2015\)](#) indiquant que les courbes spectrales variées de la luzerne rendent difficile l'identification des vecteurs de support entre la luzerne et d'autres cultures en utilisant la SVM sur des terres irriguées en Arizona central. La difficulté de cartographier la luzerne est confirmée également par la recherche de [Lounousse et al., \(2015\)](#) qui ont utilisé l'approche PNN (Probabilistic Neural Network) qui n'arrive pas à classer la luzerne. Pour une meilleure séparation par SVM, le nombre d'échantillons d'apprentissage de la luzerne et des autres cultures doit être augmenté ou sous-groupé afin d'améliorer la capacité du classificateur à identifier les vecteurs de support de séparation optimaux et, partant, d'accroître la précision de la classification SVM.

De nombreuses études ont comparé la précision de la RF et la SVM en montrant des performances comparables entre les deux classificateurs en utilisant différentes données de télédétection pour la cartographie des terres cultivées ([Löv et al., 2013](#); [Ozdarici-Ok et al., 2015](#); [Basukala et al., 2017](#)) avec une légère surperformance de la RF en précision globale ([Pelletier et al., 2016](#)). Pour le classifieur SAM, l'angle a été étendu à 0,2 rad pour minimiser les pixels non classifiés. Les classes de cultures de SAM étaient plus confuses que celles de SVM et RF, mais avec le même type de confusion. Cependant, les cultures arboricoles, en particulier les oliviers, ont été classées à tort dans les autres cultures (7125 pixels classifiés mal pour SAM contre

seulement 1204 et 973 pixels mal classifiés pour RF et SVM respectivement) (**Figure 3.9.B**), en raison de la grande diversité des espèces de la catégorie des autres cultures, ce qui augmente la fréquence des courbes ressemblant à celles des arbres. En outre, la régularité des courbes phénologiques d'olivier ainsi que l'angle de similarité plus large des mesures SAM ne peuvent que favoriser cette confusion. De plus, la classe des autres cultures a perdu la plupart de ses pixels (un exemple des 2734 pixels non classés est montré dans la **figure 3.9.A**), qui ne sont pas classés en raison de la grande variabilité des courbes phonologiques représentant cette classe. En raison du grand angle de mesure de la similarité du classifieur SAM et de la ressemblance de la forme de la luzerne I et des courbes phénologiques des arbres, 623 pixels de luzerne I sont classés à tort dans les cultures d'arbres, en particulier les agrumes. Toutes ces raisons expliquent la faible précision des classes de luzerne et des autres cultures. Afin de comparer les deux méthodes de classification en dehors des parcelles d'apprentissage et de validation, nous avons utilisé une image Quickbird à très haute résolution spatiale de Google Earth (0,65 m). La comparaison selon l'image Google Earth a montré la proximité de SVM et RF, ainsi que leur surperformance par rapport à SAM, en permettant une bonne discrimination des cultures, en particulier des arbres clairement détectables sur l'image Google Earth et classés incorrectement par le classifieur SAM (**Figure 3.9.B**).

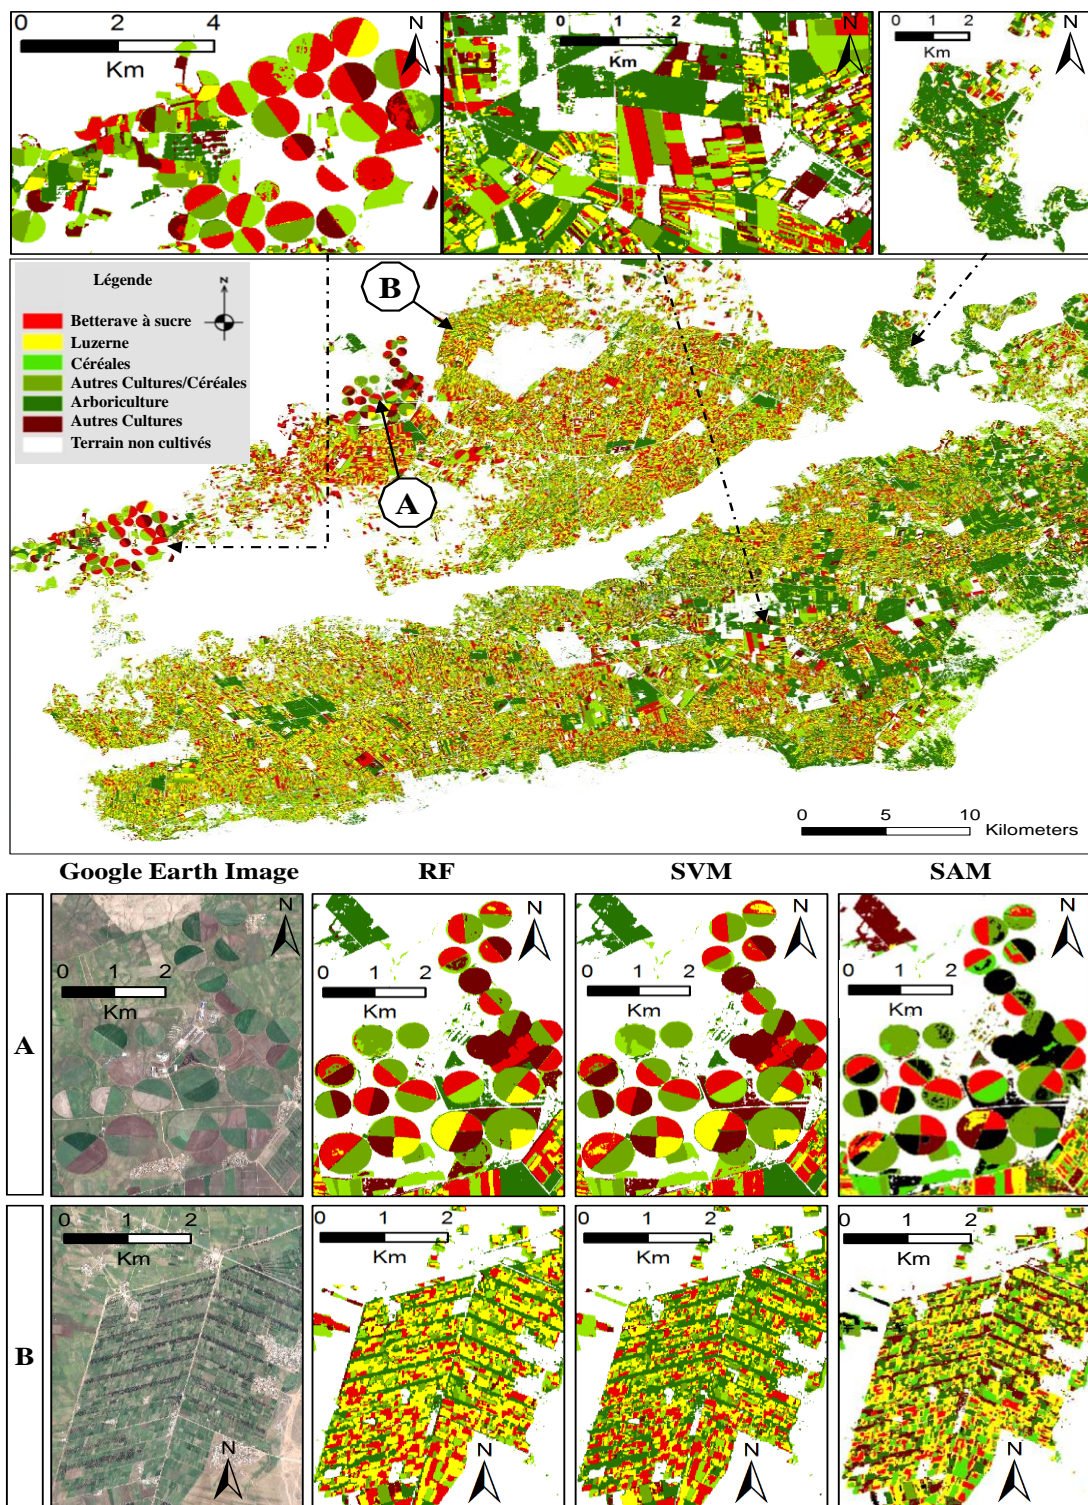


Figure 3.9 Carte globale des types de cultures du PIT obtenue par la classification RF. (A) et (B) représentent les résultats des classificateurs RF, SVM et SAM.

De plus, RF et SVM ont permis une bonne délimitation des parcelles, tandis que SAM n'a pas fréquemment classé l'ensemble de la parcelle agricole. Notons également que les pixels non classifiés sont très abondants dans la carte SAM et inexistantes dans la carte de RF et de SVM, même si les mesures de l'angle de similarité, de SAM était suffisamment étendue (**figure 3.9.A**). En conséquence, nous avons utilisé la carte des types de culture de SVM et du classificateur RF afin de récupérer les superficies des cultures (**figure 3.9**).

Les classificateurs basés sur la distance (SAM) ont confirmé leur sous-performance par rapport aux algorithmes d'apprentissage automatique (RF et SVM). Cela est probablement dû au manque de capacités de SAM dans la prise en compte de la variance intra-classe dans les règles de décision de classification ([Azar et al., 2016a, 2016b](#)).

Enfin, les zones de culture dérivées des classifications RF et SVM sont comparées à celles obtenues lors des enquêtes sur le terrain de l'ORMVAT (**figure 3.10**). La betterave à sucre, les céréales et la luzerne ont montré une légère différence entre les superficies fournies par l'ORMVAT et celles obtenues par RF et SVM. Cela peut être principalement lié au problème de mélange spectral de pixels recouvrant les bords des parcelles, en plus du problème de confusion de la luzerne évoqué précédemment. En outre, la superficie des cultures arboricoles montre une surestimation de RF et de SVM (**figure 3.10**), en raison de l'absence de statistiques officielles sur la superficie des grenadiers. Il est essentiel d'indiquer que cet arbre fruitier occupe une grande surface dans le PIT.

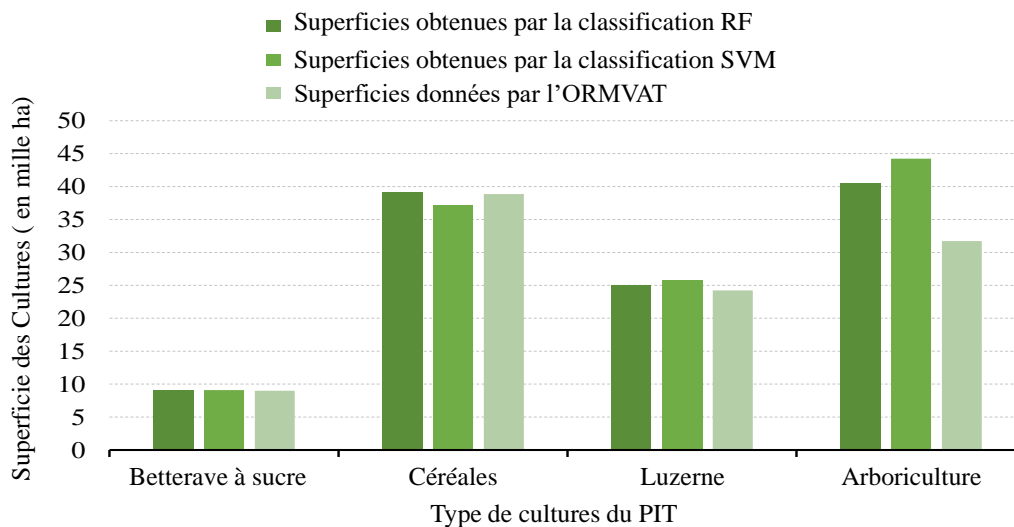


Figure 3.10 Comparaison des superficies de cultures obtenues par RF, SVM et celles fournies par l'ORMVAT.

3.5 Conclusion

L'identification et la cartographie des cultures irriguées est une étape très importante pour la gestion de l'agriculture et le contrôle de la sécurité alimentaire vers une production alimentaire accrue et une réduction de la consommation d'eau. Il ne fait aucun doute que les techniques de cartographie et de surveillance des cultures traditionnelles sont laborieuses, longues et coûteuses. Les données image Landsat-8 ont démontré leur utilité pour la cartographie des cultures et l'estimation de leurs superficies, ce qui est dû à sa haute résolution spatiale, à sa haute résolution temporelle et à sa grande couverture. Les résultats de la présente étude ont montré que les images panchromatiques de Landsat 8 OLI de 15 m sont un outil très important pour recenser les cultures et leurs superficies dans des paysages agricoles très fragmentés et sous-dimensionnés, ce qui est le cas dans la majorité des pays africains tels que le Maroc. Malgré la petite taille des parcelles, la diversité des cultures et les changements de pratiques agricoles d'une parcelle à l'autre, l'utilisation des séries chronologiques de NDVI dérivées de données OLI rééchantillonnées, a permis, avec un coût raisonnable, de cartographier avec précision les cultures irriguées du PIT. En outre, l'utilisation de données OLI rééchantillonnées à 15 m a amélioré l'estimation des superficies cultivées et

le lissage des bords des parcelles, permettant ainsi une meilleure isolation de celles-ci. Une telle approche permettra de réaliser des inventaires annuels de cultures à très haute résolution spatiale dans des systèmes agricoles irrigués, très fragmentés, hétérogènes et intensifs.

En ce qui concerne les limitations rencontrées lors de la cartographie des cultures dans notre étude, nous notons la grande diversité d'espèces dans le PIT et beaucoup d'entre elles, comme les légumes, les fruits et d'autres combinaisons de cultures, sont regroupées dans la catégorie des autres cultures. Nous notons qu'il n'est pas évident d'apporter des informations spatiales sur les autres cultures et que les courbes phénologiques de certaines d'entre elles sont similaires à celles de la luzerne et des arbres. De plus, il n'est pas évident d'avoir beaucoup d'images, car certaines acquisitions de Landsat 8 au printemps pourraient être affectées par les nuages. Ces difficultés doivent être prises en compte dans les travaux futurs en densifiant les échantillons de luzerne et d'autres classes de cultures ou en essayant de les subdiviser.

La validation des résultats de la classification par la réalité de terrain a montré que les classificateurs RF et SVM sont plus efficaces que le classificateur SAM dans la discrimination des cultures sur la base des profils spectraux NDVI. Cela confirme que les classificateurs d'apprentissage machine (Machine learning) sont plus appropriés que les classificateurs basés sur la distance pour classifier diverses courbes spectrales de NDVI de cultures dans un système de parcelles hétérogènes et sous-dimensionnées (micro-parcelles). Néanmoins, l'approche utilisant RF et SVM doit être testée et évaluée pour d'autres paysages agricoles avec un autre type de culture. Les profils phénologiques de NDVI générés dans notre étude ne sont valables que dans une région agronomiquement similaire, c'est-à-dire qui présente des caractéristiques similaires en termes de climat, de sol et de conditions agrotechniques. Ainsi, les profils phénologiques de NDVI doivent être adaptés lorsqu'ils sont appliqués à d'autres agro-régions.

Comme recommandation pour les travaux futurs, il est possible d'améliorer la précision des résultats en utilisant les nouveaux systèmes à haute résolution spatiale, spectrale et temporelle, tels que Sentinel-2. L'utilisation de ces systèmes, autonomes ou

en synergie avec des systèmes radar tels que Sentinel-1 atténuera la confusion des cultures instables ou à cycle court telles que la luzerne et assurera un meilleur suivi phénologique des cultures pendant la période nuageuse dans les régions arides et semi-arides.

**4. EVALUATION ET AMELIORATION DE L'ETAT DE LA
BETTERAVE A SUCRE PAR LE SUIVI SPATIO-
TEMPOREL A L'AIDE DES IMAGES SENTINEL-2 ET
LANDSAT-8**

4 EVALUER ET AMELIORER L'ETAT DE LA BETTERAVE SUCRIERE PAR LE SUIVI SPATIO-TEMPOREL A L'AIDE DES IMAGES SENTINEL-2 ET LANDSAT-8

4.1 Introduction

Vu l'importance socio-économique de la betterave à sucre (*Beta vulgaris*), les chercheurs tentent partout dans le monde à améliorer son économie. Ce qui fait de l'amélioration de sa rentabilité un objectif majeur de la recherche scientifique, et ceci par le développement de nouvelles méthodologies qui servent à gérer cette culture et à augmenter son rendement (Cooke and Scott 2012; Lamine et al. 2009). Un bon rendement est obtenu par la surveillance de l'état de développement des cultures durant toute la période de croissance (Asseng et al. 2000; Clevers 1997; Hansen and Schjoerring 2003). C'est pourquoi le suivi spatio-temporel des cultures était dans le temps la méthode la plus utilisée pour améliorer la productivité. Dans les pays développés, l'agriculture de précision est la tendance. Elle consiste à utiliser les informations des technologies spatialisées permettant de mesurer les caractéristiques biophysiques des cultures (la concentration de chlorophylle, ...) dans le but de suivre, d'identifier et de localiser les anomalies dans les cultures afin de mettre en place une gestion optimale à l'échelle des variations intra-parcellaires (Berni et al. 2009; Daumard 2010; Pinter Jr et al. 2003). Ces informations permettent également aux compagnies d'assurance et aux agences gouvernementales d'anticiper les impacts du changement climatique sur la production agricole, d'atténuer ces impacts, de se préparer et de mieux coordonner leurs actions en cas de perte de rendement (Borgogno-Mondino et al. 2019 ; Hill et al. 2019).

Au Maroc et plus précisément au périmètre irrigué de Tadla, la méthode conventionnelle du suivi et du contrôle de la betterave sucrière est encore utilisée. Elle est sous forme d'enquêtes de terrain aléatoires qui sont coûteuses et consomment du temps. Les membres du staff agronomique de la sucrerie de Tadla (SUTA) chargés de la surveillance du développement de la betterave à sucre ne peuvent pas vérifier toutes les parcelles de leur zone d'action. C'est pourquoi, ils effectuent des missions de terrain

et choisissent des parcelles aléatoires pour le suivi et le contrôle de l'état de croissance de cette culture. Parfois, il arrive que les parcelles visitées soient en bon état. Cependant, la réalité c'est qu'il y a une superficie très importante qui connaît des difficultés. Cette méthode ne donne pas une vision véritable et globale sur ce qui se trouve dans la réalité. Ce qui fait de l'émergence de l'agriculture de précision au périmètre irrigué de Tadla un impératif pour la surveillance de cette culture. A cause des superficies énormes occupées par la betterave sucrière, le recours à la télédétection est nécessaire surtout que cet outil est une technologie qui répond aux attentes liées à la rapidité, la grande couverture, l'économie et la précision du suivi de la betterave à sucre (Chen et al. 2008).

La télédétection était toujours la source des données et l'outil efficace pour la surveillance des cultures (Coppin et al. 2004; Jacquin et al. 2010). De nombreuses études ont utilisé les images des satellites à moyenne et à haute résolution spatiale tel que MODIS et TM/ETM+ (Chen and Gillieson 2009; Lupo et al. 2007; Silleos et al. 2006). Ces images ont prouvé leur utilité pour le suivi spatio-temporel des cultures de grandes superficies (Ahl et al. 2006; Zhang et al. 2003). Cependant, ces images sont trop limitées de point de vue résolution spatiale et ne fournissent pas suffisamment d'informations pour l'analyse de la variabilité intra-parcellaire du couvert végétal des petites parcelles (Xiang and Tian 2011). Arvishzadeh et al. (2019) ont analysé le potentiel de l'utilisation des images Sentinel-2 et RapidEye pour l'extraction de l'indice de surface foliaire de la betterave sucrière dans un marécage salé en utilisant le modèle de transfert radiatif PROSAIL. Comme alternative, d'autres études ont utilisé les véhicules aériens sans pilote (UAV) qui offrent de hautes résolutions spatiales et temporelles. Jay et al. (2019) ont exploité l'imagerie multispectrale à l'échelle centimétrique des drones pour la caractérisation de la betterave à sucre en modélisant diverses variables structurelles et biochimiques basées sur les indices de végétation qui sont extraits des images des drones.

Grâce à leurs corrélations avec la biomasse et le couvert végétal, les indices de végétation (VIs) étaient largement utilisés dans l'estimation de la surface foliaire, la production de la biomasse et la surveillance continue des caractéristiques du couvert et de la phénologie de la végétation (Tingting and Chuang 2010). En effet, plusieurs

études étaient effectuées pour développer des indices spectraux de végétation (VIs) pour le contrôle des cultures ([Tingting and Chuang 2010](#); [Hatfield and Prueger 2010](#); [Jay et al. 2017](#); [Jay et al. 2019](#); [Darvishzadeh et al. 2019](#)).

L'objectif principal de cette étude est le développement d'outils de surveillance et de contrôle des cultures de la betterave à sucre en utilisant les indices de végétation (NDVI, EVI et OSAVI) dérivés des deux satellites Landsat-8 et Sentinel-2A, pour cibler et contrôler l'encadrement des agriculteurs, afin de mettre en place une gestion efficace des parcelles betteravières complémentaire aux interventions sur le terrain.

4.2 Zone d'étude

Cette étude concerne l'aire du Centre de Développement Agricole (CDA) 536 relevant de la zone d'action de l'Office Régional de Mise en Valeur Agricole du Tadla (ORMVAT) (**figure 4.1**). Ce site est d'une superficie de 4045 ha. Il se situe au centre du Maroc au niveau du périmètre irrigué de Tadla sur la rive sud d'Oued Oum Er-Rabia. Il est choisi en raison de la disponibilité de données parcellaires (**figure 4.1**). Il se caractérise par des parcelles hétérogènes de moins de 5ha (46% de la superficie totale du CDA 536) avec une diversité des cultures, notamment la betterave à sucre, les céréales (blé, orge), la luzerne, l'olivier, les agrumes, le maraichage... ([Hammani et al. 2006](#); [Karrou et al. 2011](#); [ORMVAT 2017](#)). Le climat de la région est de type méditerranéen, aride à semi-aride à caractère continental avec une saison sèche d'avril à octobre et une saison pluvieuse de novembre à mars ([El Harti et al. 2016](#)).

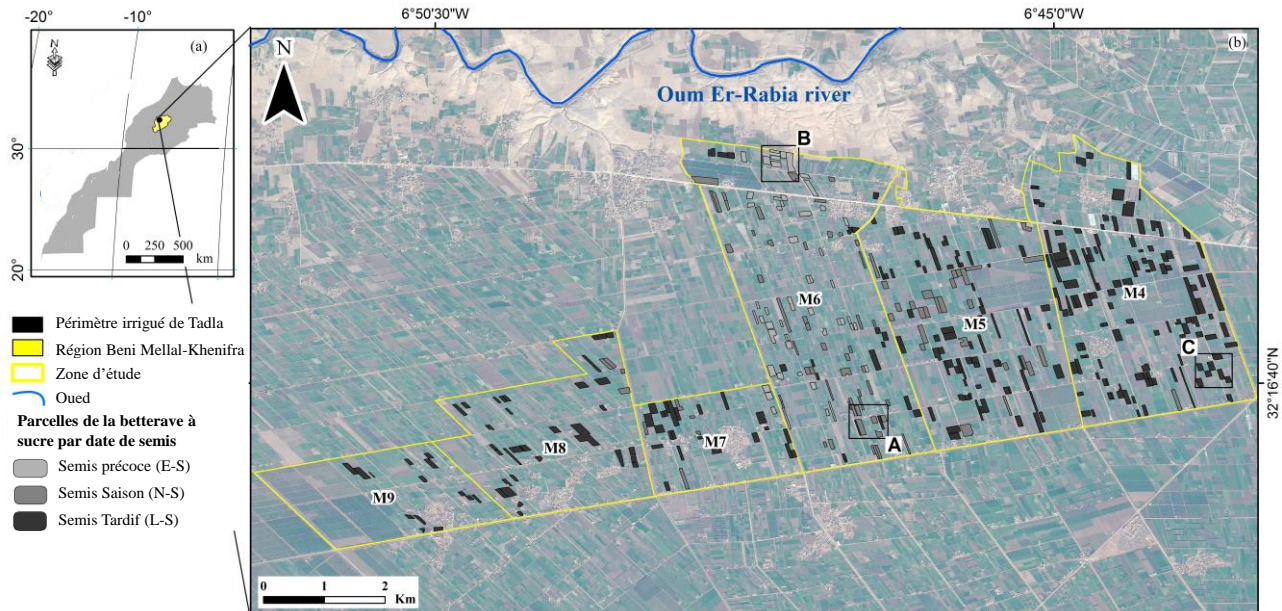


Figure 4.1 La zone d'étude. (a) Situation de la zone d'étude par rapport au territoire du Maroc ; (b) L'emplacement des parcelles de la betterave sucrière.

4.3 Matériel et Méthodes

4.3.1 Données de terrain

Dans cette étude, les données de terrain étaient prises en deux étapes à savoir : la délimitation des frontières des parcelles de la betterave à sucre de la campagne agricole 2013-2014 par des GPS (5m de précision) et sur une ortho-photo très haute résolution spatiale. Après avoir délimité les parcelles, on a procédé à leur regroupement selon la date de semis à savoir : Précoce (E-S), Saison (N-S) et Tardif (L-S) (Tardif-I, Tardif-II et Tardif-III) (**Tableau 4.1**). Puis, la collecte des paramètres agronomiques sur le couvert végétal et l'état de la betterave à sucre de cette campagne agricole, notamment :

- i) le peuplement ;
- ii) l'espacement ;
- iii) la taille du bouquet foliaire ;
- iv) la couleur ;
- v) ...etc.

Tout ceci, était effectué en tenant compte de la date de semis. La même procédure était retenue et effectuée sur la campagne agricole 2015-2016.

Les M4, M5, ... et M9 représentent des secteurs agricoles. Les sites A, B et C représentent des points aléatoires qui seront zoomés pour présenter quelques résultats ci-dessous.

Les superficies totales des parcelles de la betterave à sucre des deux campagnes agricoles déterminées via la numérisation sont respectivement de 402ha et de 396.8ha. En revanche, les superficies calculées déterminées par SUTA sont d'ordre de 404.2ha pour 2013-2014 et 400ha pour 2015-2016. Les superficies qu'on a calculées correspondent aux surfaces couvertes par la betterave à sucre pure sans tenir compte des bordures des parcelles comprenant des arbres, généralement, des oliviers. Pourtant, les superficies déterminées par SUTA correspondent à celles couvertes par la betterave à sucre en plus de tous les éléments qui les entourent (chemins entre parcelles, oliviers...). Les sols de semis précoces sont essentiellement localisés au niveau du médian M6, les sols dont le semis de la période saison sont localisés en majorité au niveau des médians M6 et M5 et les sols dont le semis est tardif se sont situés au niveau de tous les médians d'un pourcentage variant du faible (M6), moyen (M5) jusqu'à fort (M4, M7, M8 et M9) (**figure 4.1**).

Concernant le climat, la figure suivante (**figure 4.2**) décrit l'évolution de la température moyenne et les précipitations moyennes mensuelles durant les deux années agricoles 2013-2014 et 2015-2016. On observe que la pluviométrie connaît une variation importante en comparant les deux années agricoles, par contre, la température est presque similaire sur les deux périodes.




Figure 4.2 Précipitations et températures annuelles enregistrées dans la zone d'étude des années agricoles 2013-2014 et 2015-2016.

Tableau 4.1 Les périodes de semis de la betterave à sucre et les superficies de chaque période en ha et en pourcentage des deux campagnes agricoles 2013-2014 et 2015-2016.

	Type de semis	Période de semis	Surface (ha)	Surface (%)
Saison 2013-2014	Précoce	15 Septembre - 30 Septembre	55.7	13.85
	Saison	1 Octobre - 15 Octobre	126.3	31.42
	Tardif	15 Octobre - 15 Décembre	220	54.73
Saison 2015-2016	Précoce	15 Septembre - 30 Septembre	40.1	10.18
	Saison	1 Octobre - 15 Octobre	87.5	21.76
	Tardif	15 Octobre - 15 Décembre	269.2	68.06

4.3.2 Données satellitaires

Ce travail a été effectué en utilisant les images Sentinel-2A et Landsat-8 rééchantillonnés à 15m de résolution spatiale. Sentinel-2 porte un instrument multispectral (MSI) avec 13 bandes dans la partie visible y compris le red edge, proche infrarouge et moyenne infrarouge (MIR). Les images de ces deux types de capteurs ont été choisies en raison de leur disponibilité, répétitivité et l'aptitude à restituer les limites des petites parcelles. Sept images de Landsat-8 du CDA 536 ont été acquises sur la période de 24 Décembre 2013 à 4 Juillet 2014 avec une moyenne d'une image par mois. Ainsi que sept images de Sentinel-2AA de la même zone acquises du 29 Décembre 2015 à 26 Juin 2016. Les images utilisées étaient respectivement acquises aux dates consignées dans le **Tableau 4.2**. Les dates de début du suivi étaient choisies

à cause du grand pourcentage (68%) représentant les parcelles de betterave à sucre de semis tardif en plus de la date du dernier semis (**Tableau 4.1**).

Tableau 4.2 Les dates d'acquisition et les caractéristiques des images utilisées.

Saison 2013-2014				Saison 2015-2016			
Date d'acquisition	Satellite	Résolution		Date d'acquisition	Satellite	Résolution	
		Spatiale (m)	Temporelle (jour)			Spatiale (m)	Temporelle (jour)
24 Décembre	Landsat-8	15	16	29 Décembre	Sentinel-2A	10	10
26 Février	Landsat-8	15	16	17 Février	Sentinel-2A	10	10
30 Mars	Landsat-8	15	16	28 Mars	Sentinel-2A	10	10
15 Avril	Landsat-8	15	16	27 Avril	Sentinel-2A	10	10
17 Mai	Landsat-8	15	16	24 Mai	Sentinel-2A	10	10
2 Juin	Landsat-8	15	16	6 Juin	Sentinel-2A	10	10
4 Juillet	Landsat-8	15	16	26 Juin	Sentinel-2A	10	10

4.3.3 Méthodologie

La betterave à sucre est une plante ayant deux types de développement durant sa phase végétative : Un développement foliaire qui se continue, dès le jour de son émergence pour deux mois, pendant lesquels les feuilles de cette culture se développent jusqu'à ce qu'elles se touchent entre elles. Et un développement racinaire de quatre mois. Cette période se caractérise par un bon couvert végétal, par conséquent, on peut déduire la durée de la surface foliaire. Ce paramètre est en relation directe avec le rendement de la betterave à sucre. Plus la surface foliaire sera longtemps active, meilleur sera le remplissage des racines. L'idée de ce travail est de localiser les parcelles stressées et améliorer leurs durées de la surface foliaire par des interventions sur terrain en se basant sur des parcelles de références (cultures saines) de telle sorte à minimiser la différence de croissance entre ces dernières et les cultures à problèmes (**Figure 4.3**).

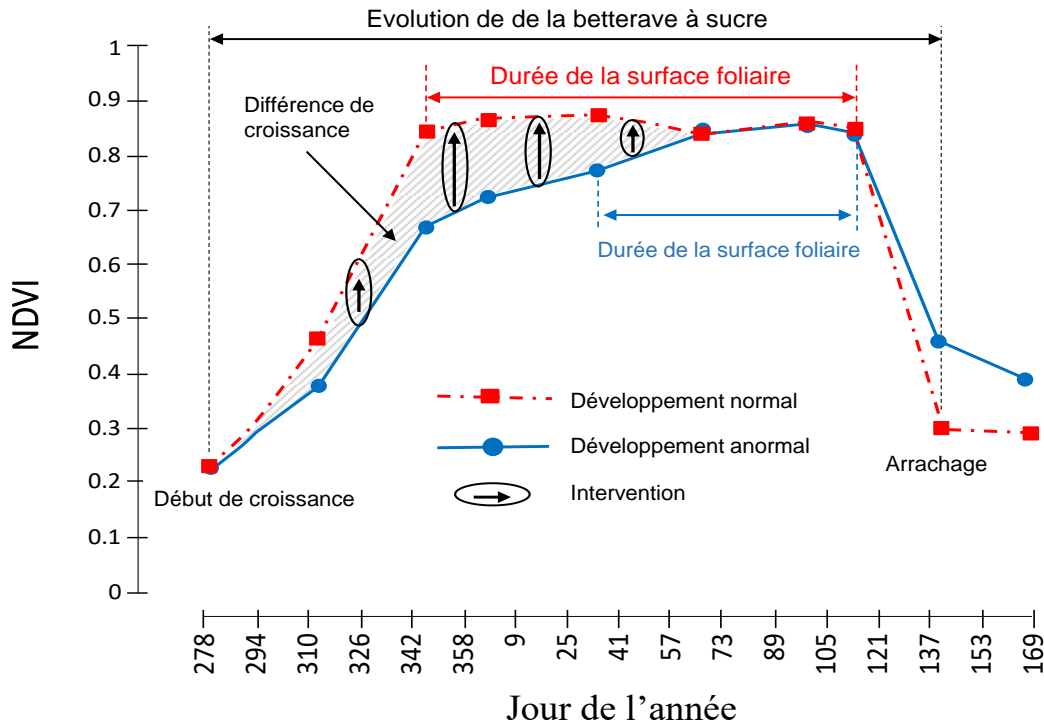


Figure 4.3 Durée de la surface foliaire d'une parcelle de betterave à sucre stressée et d'une parcelle de référence en bonne santé de la zone d'étude pendant la saison 2013-2014.

Dans cette étude, on a adopté une approche qui se base sur les indices de végétation. Cette approche consiste à suivre la croissance de la betterave à sucre en calculant une série d'indices de végétation (NDVI, EVI et OSAVI) dérivés des satellites Landsat-8 et Sentinel-2A. Durant la première campagne, des missions de terrain ont été programmées les jours de l'acquisition des images satellitaires pour la calibration et la validation des classes d'état de croissance de la betterave à sucre. Cette calibration était faite par le seuillage des valeurs des indices de végétation utilisés, afin de les faire correspondre aux quatre classes d'état de santé, à savoir : la mauvaise santé, la santé moyenne, la bonne santé, et la culture déracinée. L'état de développement et les seuils sont fixés sur le terrain en considérant le peuplement, l'espacement, la taille du bouquet foliaire et le verdissement/la couleur en tenant compte de la date de semis, et ceci en concertation avec les agronomes de la sucrerie de Tadla (SUTA). Ces seuils sont utilisés pour la classification des images et l'établissement des cartes d'états de croissances de la betterave à sucre. Pour la deuxième campagne, on a utilisé et validé

encore une fois les seuils fixés pendant la campagne précédente, et ceci dans le but de la mise en œuvre du suivi spatio-temporel de l'ensemble des parcelles de la betterave à sucre. Ce suivi nous a permis de cibler et d'intervenir sur terrain pour améliorer la qualité des parcelles qui connaissent des anomalies.

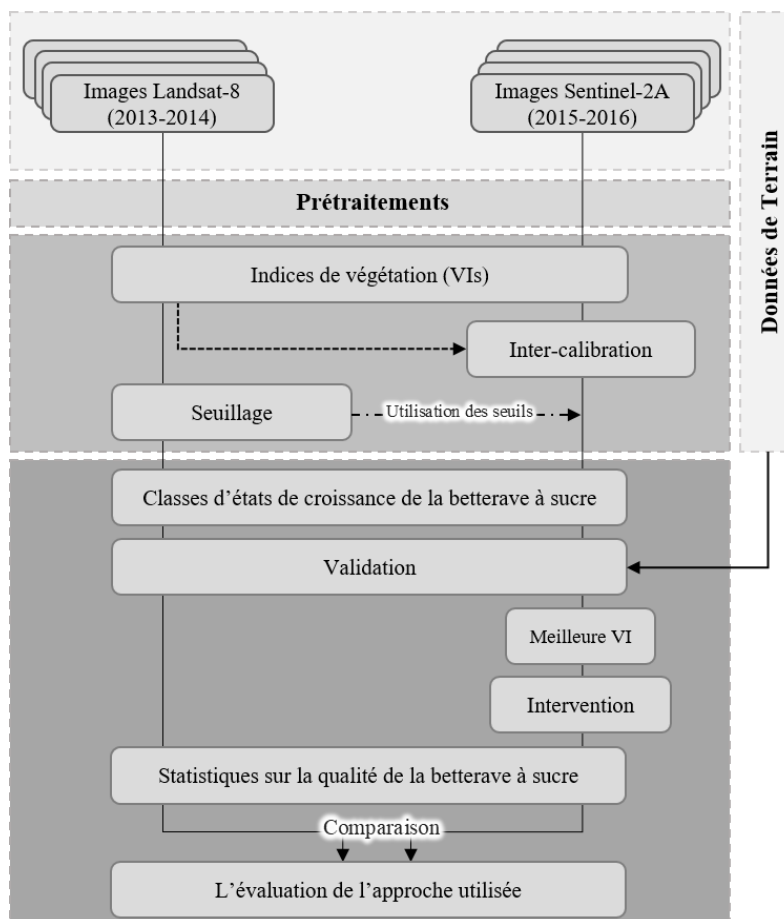


Figure 4.4 Diagramme de processus global de cette étude.

De l'autre côté, une comparaison des trois indices était réalisée pour choisir l'indice le plus adéquat pour le suivi de la betterave à sucre. Par la suite, les statistiques des deux campagnes issues de l'indice choisi ont été analysées et évaluées et comparées pour vérifier l'efficacité de l'approche utilisée (**Figure 4.4**).

4.3.4 Prétraitement des données images

Les images de niveau S-2A 1C ont été prétraitées à l'aide d'un processeur Sen2Cor afin de corriger les effets atmosphériques, de terrain et de cirrus. En ce qui concerne les

images Landsat-8 OLI, elles ont été calibrées par radiométrie et atmosphère à l'aide du modèle FLAASH. Les images ont été affinées pour améliorer la résolution spatiale à 10 et 15 m respectivement pour les images S-2A et OLI.

4.3.5 Calcul d'indices de végétation VIs

L'intérêt de la télédétection pour l'agriculture réside dans le fait que plusieurs variables biophysiques, représentatives de l'état de développement de la plante, sont accessibles par radiométrie. Des combinaisons de bandes spectrales appelées indices de végétation spectraux (VIs) sont utilisées pour décrire l'évolution de différentes variables biophysiques de surface. De nombreux indices ont été développés dans la littérature pour évaluer le suivi de la santé de la végétation. Parmi ces indices, nous avons sélectionné l'indice de végétation par différence normalisée (NDVI) grâce à sa sensibilité à la chlorophylle, l'indice de végétation amélioré (EVI) avec sa grande sensibilité aux changements structurels de la canopée, notamment la surface foliaire, et l'indice de végétation ajusté au sol optimisé (OSAVI). Ces trois VIs sont utilisés pour leur efficacité prouvée dans des travaux antérieurs. Les trois indices ont été calculés pour les images du 24 décembre 2013 au 04 juillet 2014, ainsi que pour les sept images de l'année agricole 2015-2016. Leurs équations sont respectivement:

$$EVI = 2.5 * \frac{NIR - R}{(NIR + 6 * R - 7.5 * B + 1)} \quad \text{(Equation 4.1)}$$

$$OSAVI = 1.16 * \frac{NIR - R}{(NIR + R + 0.16)} \quad \text{(Equation 4.2)}$$

Où:

B : bleue; R : rouge; NIR : proche infrarouge.

4.3.6 Inter-calibration des VIs dérivés des données S-2A et OLI

Dans les applications agricoles, seuls les satellites à haute résolution spatiale fournissent les détails spatiaux nécessaires, mais leur répétitivité est relativement faible par rapport aux périodes de croissance des cultures, en particulier lorsque l'acquisition de données est limitée par la couverture nuageuse. Pour traiter ce problème, il s'est

révélé essentiel de combiner les données de plusieurs capteurs. Selon [Teillet et al. \(1997\)](#), étant donné que les largeurs des bandes spectrales rouge et proche infrarouge varient nettement d'un capteur à l'autre, les valeurs des VIs basées sur les bandes spectrales de différents satellites ne seront pas directement comparables. Une étude de [Steven et al. \(2003\)](#) indique que la comparaison des NDVI calculées à partir de plusieurs capteurs est variable, mais que leur linéarité est élevée, ce qui permet de normaliser les différences entre les VIs dérivés de différents capteurs. Une inter-calibration des VIs des satellites OLI et S-2A a été réalisée pour obtenir des valeurs comparatives de ces indices et, par conséquent, un bon suivi de l'état des cultures de betteraves à sucre. Nous avons effectué une analyse de régression linéaire entre les VIs dérivés des images S-2A acquises le 21 août 2015 et le 19 décembre 2015 et les images OLI acquises le 24 août 2015 et le 21 décembre 2015. Par conséquent, les équations de régression obtenues ont été inversées afin de normaliser les valeurs des VIs issues d'OLI et de S-2A (**Figure 4.5**).




Figure 4.5 Inter-calibration de Landsat-8 et Sentinel-2A's VIs. (a) NDVI, (b) EVI et (c) OSAVI

4.3.7 Seuillage et validation des VIs

Le seuillage est un outil commun utilisé pour la prise de décision. La difficulté liée à cette méthode est évidemment l'estimation du seuil optimal, qui peut être variable en fonction des images utilisées. Le seuil le plus approprié est déterminé par rapport à la connaissance de la vérité sur le terrain. Des missions sur le terrain ont été programmées le jour de l'acquisition de l'image pour déterminer l'état de santé de la betterave à sucre en calibrant les seuils en fonction des paramètres agronomiques (le peuplement, l'espacement, la taille du bouquet foliaire et le verdissement/la couleur en tenant compte de la date de semis) collectés sur chaque parcelle. Pour chaque image, nous avons effectué deux missions sur le terrain. La première est réalisée le jour du passage du satellite sur les cultures afin d'établir les seuils de classe pour chaque VI

en localisant les champs de betteraves sucrières avec nos différentes classes pour déterminer les valeurs des seuils à partir des images VIs. La seconde a été réalisée dans les deux jours suivants et après la création des cartes préliminaires des conditions de la betterave à sucre. Cette mission a pour objectif de valider et d'ajuster les seuils résultant de la première mission. Selon notre expérience, la mission de validation ne devrait pas dépasser, dans le pire des cas, quinze jours après le passage du satellite. En effet, une différence de quinze jours entraîne un changement énorme de la plante, en particulier pendant la période de développement végétatif. En d'autres termes, l'état de la plante passe d'une classe d'état à une autre.

Dans notre cas, les deux constellations (S-2 et L-8) ont effectivement été utilisées en synergie au cours de la deuxième année. Cette synergie nous a permis de travailler avec deux images par mois dans le pire des cas, sauf en janvier et en octobre où il nous a été impossible d'avoir une image ou une mission sur le terrain en raison de plusieurs facteurs, notamment les conditions météorologiques et les nuages. De plus, afin de pouvoir comparer correctement entre deux années, les dates doivent être proches entre les deux années. Ainsi, lors de la deuxième année, nous avons choisi les dates qui correspondent le plus possible à celles de la première année, ce qui permettra de montrer clairement la différence entre la croissance de la betterave sucrière avec et sans intervention sur le terrain en fonction des résultats de la télédétection.

Lors de ces missions, la date de semis a été prise en compte. Par conséquent, des seuils ont été établis pour chaque groupe, un groupe de semis précoce (E-S), un groupe de (semis normal) N-S ainsi que trois autres groupes de la catégorie semis tardif (L-S) (L-S-I, L-S-II et L-S-III). Le groupe L-S a été subdivisé en raison de sa longue durée. Pour des raisons de précision, l'étalonnage des seuils d'une même classe reposait sur plusieurs échantillons (parcelle). Ainsi, les seuils ou les intervalles des classes d'état de santé ont été définis empiriquement en utilisant l'histogramme des parcelles collectées et échantillonnées sur le terrain pour chaque classe. Ceci a été réalisé de telle sorte que les classes de la vérité de terrain se situent bien dans ces intervalles. Ces intervalles ont été utilisés pour générer la carte de l'état de santé pour la deuxième année. Par la suite, cette carte a été validée par la mission de terrain afin de confirmer ou d'ajuster les intervalles. Les ajustements consistent à faire la moyenne des seuils obtenus durant la

première et la deuxième année. Souvent, les valeurs de seuil entre les deux années sont trop proches (différence dans le deuxième chiffre décimal). Il y a très peu de cas où la différence est relativement plus importante. Dans ces cas, les seuils ont été modifiés de manière à vérifier et respecter la vérité terrain pour les deux années.

La cartographie du suivi spatio-temporel de la betterave sucrière a été réalisée en utilisant les derniers seuils sélectionnés après validation (**Tableau 4.3**). La validation a été effectuée en calculant la précision (P) pour chaque date (ou image) en appliquant l'équation (**Equation 4.3**) et la précision globale (PG) suivant l'équation (**Equation 4.4**):

$$P = \frac{n}{N} * 100 \quad (\text{Equation 4.3})$$

Où:

P : Précision; **n** : Nombre des observations correctes; **N** : Nombre total des échantillons (N=40).

$$PG = \frac{\sum_{i=1}^q p}{q} \quad (\text{Equation 4.4})$$

Où:

PG : Précision Globale; **q** : Nombre des validations dans une période donnée; **p** : Précision obtenue pour chaque date.

Tableau 4.3 Seuils de NDVI retenus après validation.

Date	Classes	Période de semis				
		Précoce	Saison	Tardif I	Tardif II	Tardif III
29-Dec	Médiocre	Min-0.35	Min-0.33	Min-0.28	Min-0.25	Min-0.22
	Moyen	0.35-0.65	0.33-0.6	0.28-0.45	0.25-0.38	0.22-0.3
	Bon	0.65-Max	0.6-Max	0.45-Max	0.38-Max	0.3-Max
	Arraché	-	-	-	-	-
17-Fev	Médiocre	Min-0.6	Min-0.58	Min-0.46	Min-0.43	Min-0.38
	Moyen	0.6-0.75	0.58-0.73	0.46-0.68	0.43-0.6	0.38-0.5
	Bon	0.75-Max	0.73-Max	0.68-Max	0.6-Max	0.5-Max
	Arraché	-	-	-	-	-
28-Mars	Médiocre	Min-0.7	Min-0.66	Min-0.65	Min-0.6	Min-0.6
	Moyen	0.7-0.8	0.66-0.78	0.65-0.74	0.6-0.72	0.6-0.72
	Bon	0.8-Max	0.78-Max	0.74-Max	0.72-Max	0.72-Max
	Arraché	-	-	-	-	-
27-Avr	Médiocre	0.51-0.63	0.51-0.65	0.51-0.65	0.51-0.68	0.51-0.67
	Moyen	0.63-0.79	0.65-0.79	0.65-0.79	0.68-0.78	0.67-0.75
	Bon	0.79-Max	0.79-Max	0.79-Max	0.78-Max	0.75-Max
	Arraché	Min-0.51	Min-0.51	Min-0.51	Min-0.51	Min-0.51
22-Mai	Médiocre	0.45-0.62	0.45-0.6	0.45-0.58	0.45-0.55	0.45-0.53
	Moyen	0.62-0.67	0.6-0.66	0.58-0.65	0.55-0.63	0.53-0.61
	Bon	0.67-Max	0.66-Max	0.65-Max	0.63-Max	0.72-Max
	Arraché	Min-0.45	Min-0.45	Min-0.45	Min-0.45	Min-0.45
06-Juin	Médiocre	0.42-0.6	0.42-0.62	0.42-0.64	0.42-0.652	0.42-0.66
	Moyen	0.6-0.7	0.62-0.71	0.64-0.732	0.652-0.739	0.66-0.74
	Bon	0.7-Max	0.71-Max	0.732-Max	0.739-Max	0.74-Max
	Arraché	Min-0.42	Min-0.42	Min-0.42	Min-0.42	Min-0.42
26-Juin	Médiocre	-	-	0.42-0.63	0.42-0.65	0.42-0.65
	Moyen	-	-	0.63-0.72	0.65-0.73	0.65-0.73
	Bon	-	-	0.72-Max	0.73-Max	0.73-Max
	Arraché	-	-	Min-0.42	Min-0.42	Min-0.42

4.4 Résultats et discussions

4.4.1 Suivi spatio-temporel de l'état de la betterave à sucre

Le suivi spatio-temporel a été réalisé lors de la deuxième campagne agricole (2015-2016) en se basant sur des seuils fixés lors de la campagne agricole 2013-2014. Trois différents VIs ont été utilisés pour la surveillance spatio-temporelle et la cartographie de

l'état de santé de la betterave à sucre dans le CDA 536. Ensuite, une comparaison a été effectuée pour déterminer l'indice le plus représentatif de l'état réel de la betterave à sucre. La **Figure 4.6** illustre des extraits agrandis de trois sites A, B et C mentionnés sur la **Figure 4.1**. Ces extraits représentent l'évolution des conditions de la betterave à sucre au cours de la campagne agricole 2015-2016 en fonction des dates d'acquisition des images (**Tableau 4.2**), par parcelle et selon la période de semis (**Tableau 4.1**) en utilisant NDVI, EVI et OSAVI.

Les seuils de tous ces indices de végétation étaient déterminés en même temps en se basant sur la réalité de terrain de sorte qu'ils soient comparables. Les trois extraits montrent la croissance des parcelles de la betterave à sucre de différentes dates de semis.

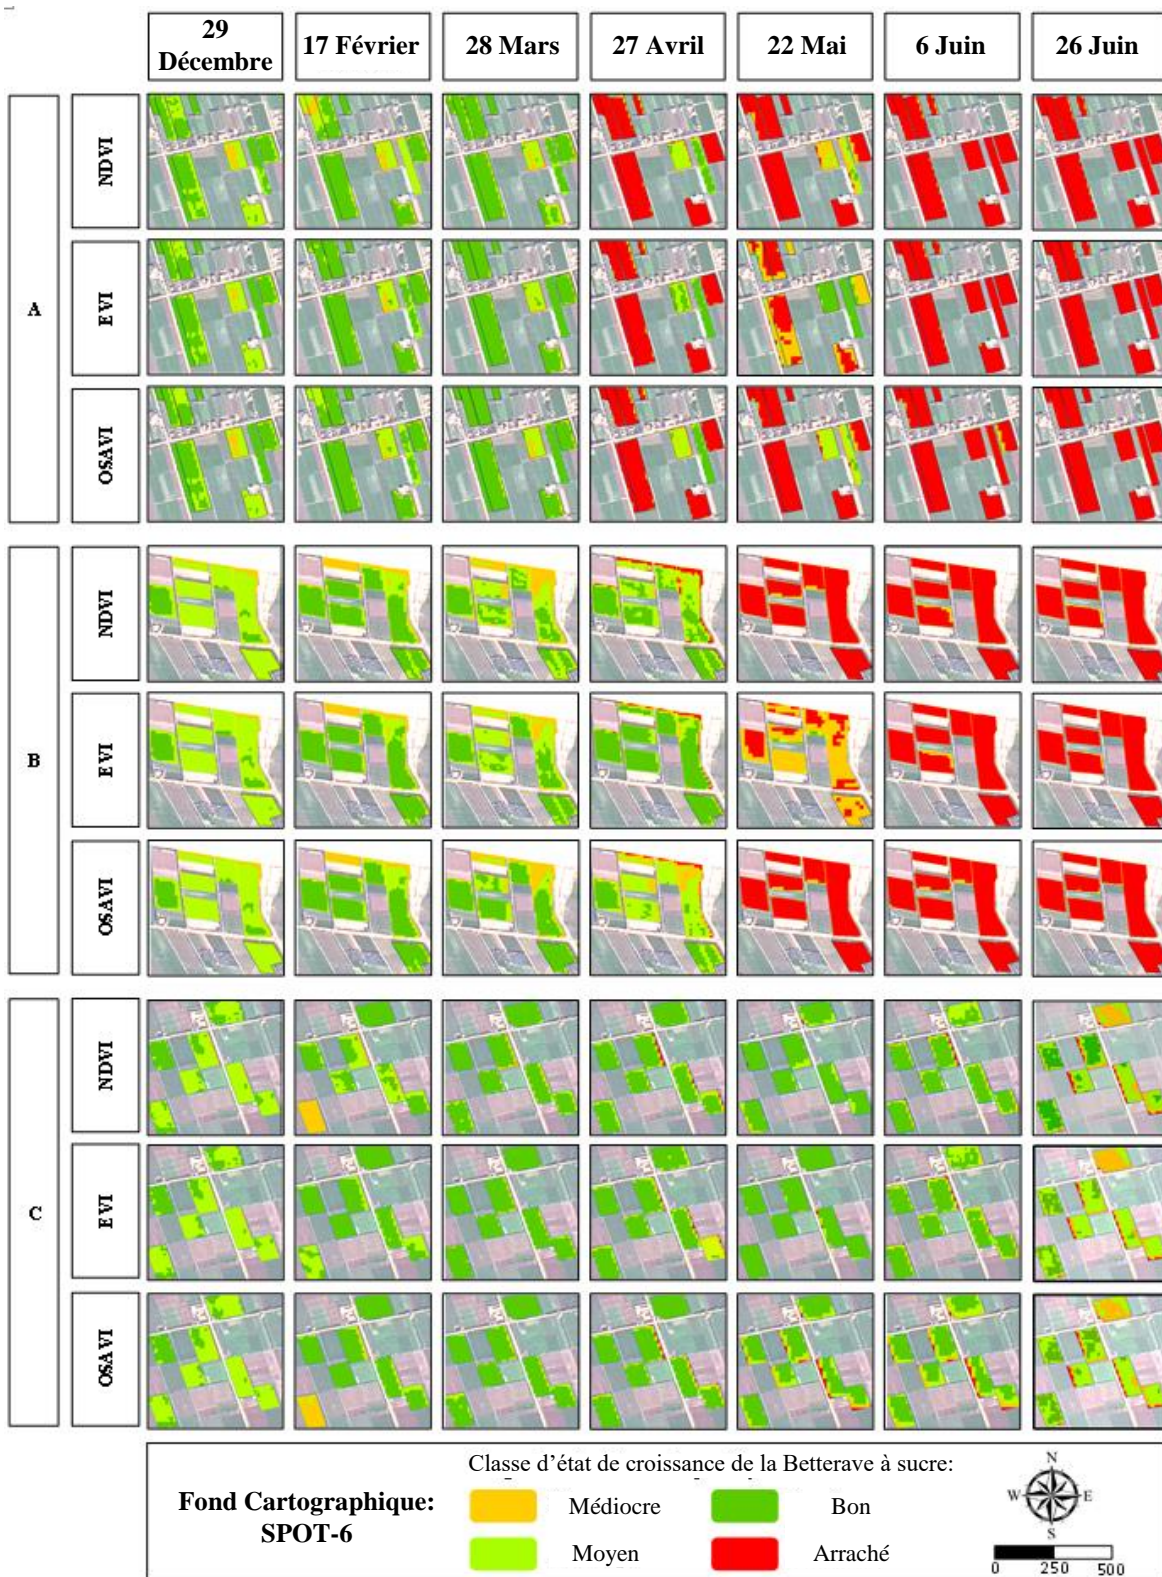


Figure 4.6 L'état des cultures de betterave à sucre à l'aide des trois VIs dans les trois sites (A), (B) et (C) au cours de la saison 2015-2016.

Pour les trois sites, comme pour toute la zone d'étude, on observe que les trois indices de végétation de chaque date varient en général d'une manière légèrement différente à l'intérieur de la même parcelle. Cependant, le cumul de cette différence sera probablement très important et doit être pris en considération lors de la comparaison des trois indices de l'ensemble des parcelles de la zone d'étude. L'étude des profils spectraux des trois indices de la betterave à sucre montre qu'à la fin du mois de décembre les valeurs des indices de végétation des parcelles de la betterave précoce et de saison sont presque similaires avec une même tendance d'évolution. En revanche, les valeurs des indices de végétation de la betterave tardive sont décalées par rapport aux deux autres semis. Ce qui traduit une évolution et un développement phénologique différents entre les cultures précoces et saisons d'une part et les cultures tardives d'autre part. Par conséquent, les parcelles arrachées commencent à apparaître à partir du 27 Avril dans le site A et du 22 Mai dans le site B parce que les deux sites A et B contiennent des parcelles de semis précoce et saison qui ont subi l'arrachage depuis le 14 Avril. Contrairement au site C dont les parcelles arrachées sont encore absentes au 26 juin du fait qu'il se situe au médian M4 et qu'il contient des parcelles de semis tardif. L'apparition des parcelles arrachées dans le site A avant le site B même si elles appartiennent aux parcelles de semis précoce et saison est justifiée par le début de l'arrachage du sud vers le nord selon l'ordre des médians M6, M5, M4, M7, M8 et M9.

Les **Figure 4.7.a**, **Figure 4.7.b**, **Figure 4.7.c** et **Figure 4.7.d** représentent respectivement les superficies des parcelles faibles, moyennes, bonnes et arrachées de chaque date. Elles étaient calculées en se basant sur les trois indices de végétation NDVI, EVI et OSAVI. Ces graphiques illustrent la différence entre les indices de végétation utilisés dans cette étude. On distingue, que pour chaque date les superficies calculées diffèrent d'un indice à l'autre, ce qui confirme l'hypothèse qui suppose que le cumul va accentuer l'importance de la différence entre les indices. Le seuillage effectué sur OSAVI montre par exemple la présence d'un grand nombre de parcelles d'un faible état avec une superficie d'environ de 19ha pendant le mois du février et 26ha en Avril. La même chose pour EVI qui a montré une augmentation des parcelles à faible état pendant le mois d'Avril avec une superficie d'environ de 11ha (**Figure 4.7.a**). Ces valeurs sont très importantes et elles ne présentent pas la réalité terrain. Les superficies

obtenues en fonction de l'état de la betterave à sucre en utilisant OSAVI et EVI n'expriment pas les observations menées lors des missions de terrain et n'ont pas montré une efficacité pour la cartographie de l'état de la betterave à sucre. Le seuillage effectué sur NDVI a montré une grande potentialité dans la cartographie de l'état de la betterave à sucre. Les superficies calculées en fonction de l'état de la betterave à sucre en se basant sur NDVI sont les plus proches de la réalité terrain. En effet, les résultats de la validation sur le terrain de la précision des seuils montrent que, pendant toutes les dates, la précision des seuils EVI et OSAVI était peu performante par rapport à celle de NDVI (**Figure 4.7.e**). Les précisions globales de NDVI, EVI et OSAVI sont 94,29%, 87,5% et 87,14% respectivement. Au terme de l'analyse, NDVI est l'indice le plus adéquat pour le suivi spatio-temporel de l'état de la betterave à sucre.

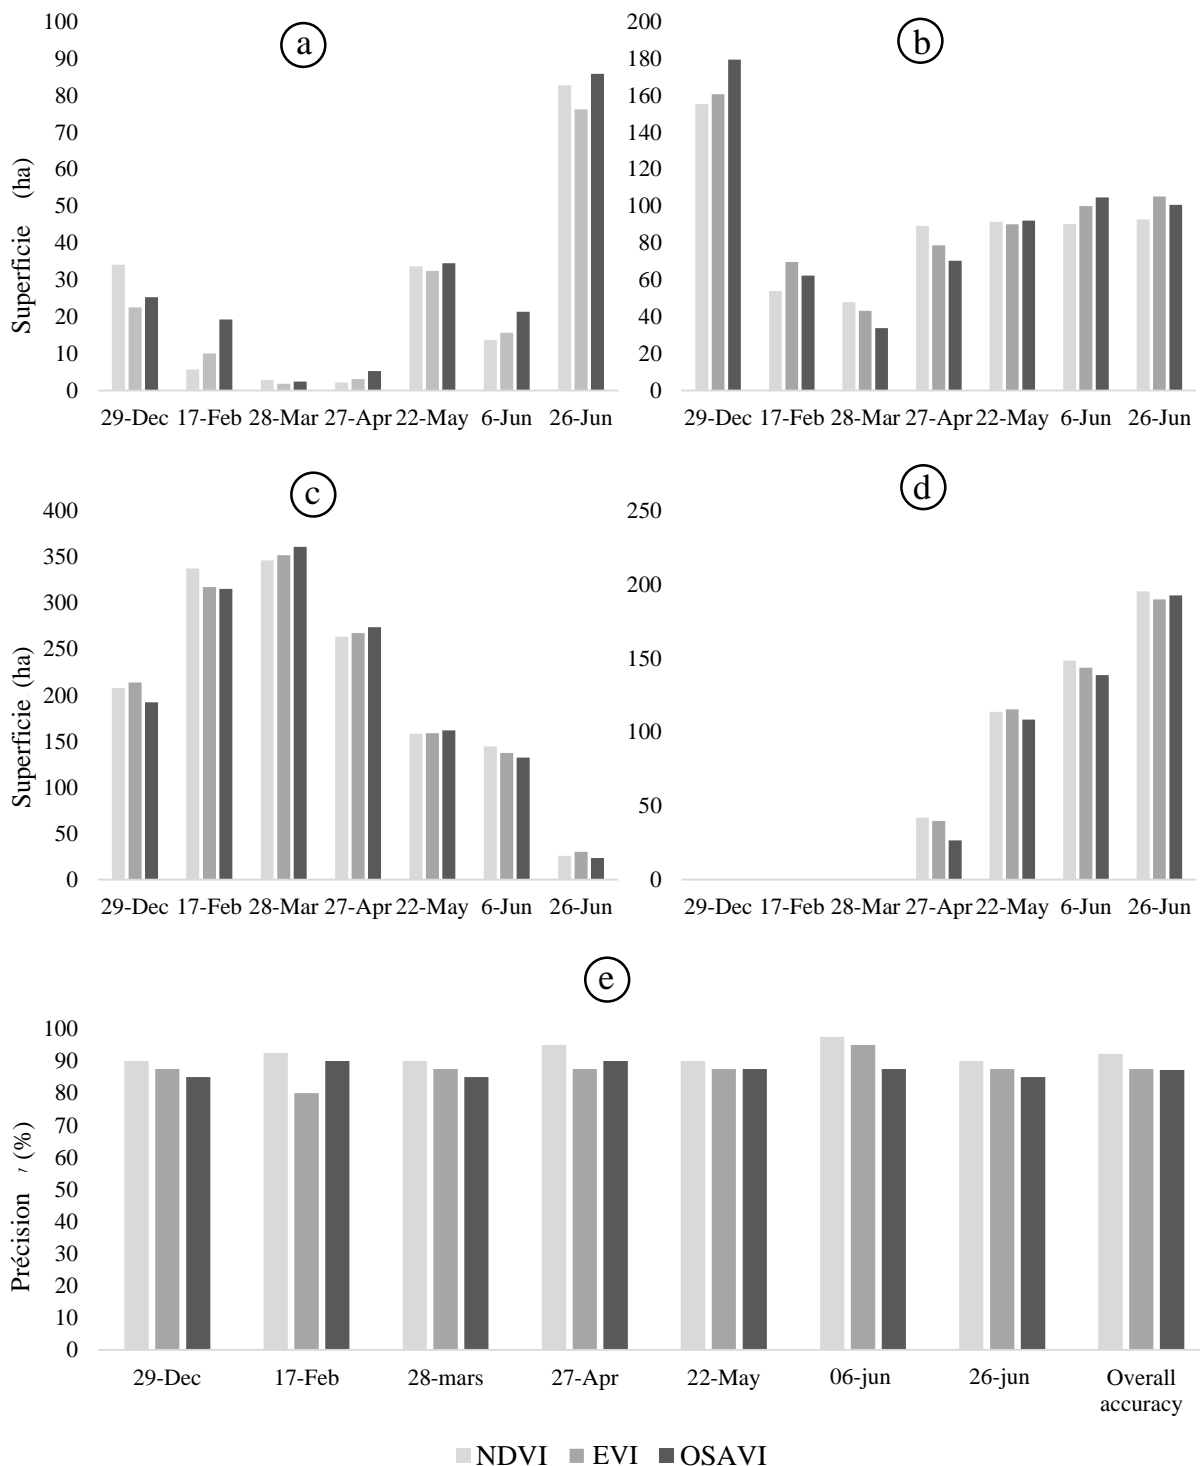


Figure 4.7 Analyse statistique de l'état de la betterave à sucre sur le terrain à l'aide des trois Vis. (a) Médiocre, (b) Moyen, (c) Bon, (d) Arraché et (e) précision globale.

Les cartes adoptées pour le suivi spatio-temporel de l'état de la betterave à sucre ont été réalisées en utilisant NDVI. Elles sont réalisées essentiellement à la base de la réalité terrain. Plusieurs missions de terrain ont été effectuées pour la validation des cartes issues de la calibration. La **Figure 4.8** montre un exemple de l'état de cinq parcelles (médiocre, moyen, bon, arraché et en cours d'arrachage) suivis par télédétection au 26 Juin 2016 et de leurs états réels observés sur le terrain.

L'arrachage de la betterave à sucre au niveau du CDA 536 a commencé depuis le 14 Avril. La cartographie de l'arrachage de la betterave à sucre a été effectuée en suivant la même méthodologie pour le suivi de son état de croissance. On a procédé à un seuillage mettant en évidence les parcelles arrachées. Le nombre des parcelles arrachées a évolué d'une façon croissante entre 27 Avril et 26 Juin suivant les médians M6, M5 et M4 (**Figure 4.7.d**).

Une planification d'arrachage est fixée préalablement pour assurer une meilleure gestion de cette opération. Les cartes du suivi de l'arrachage de la betterave à sucre réalisées, montrent que l'arrachage a commencé par les Médians qui contiennent les parcelles à semis précoce. Puis, l'arrachage continu en incluant des parcelles à semis normal (saison) et enfin les parcelles à semis tardif, comme illustré dans la **Figure 4.8**. Cette dernière montre la grande efficacité du seuillage effectué et de la potentialité importante de l'indice de végétation NDVI pour le suivi de l'état de croissance et l'arrachage de la betterave à sucre au niveau du CDA 536.

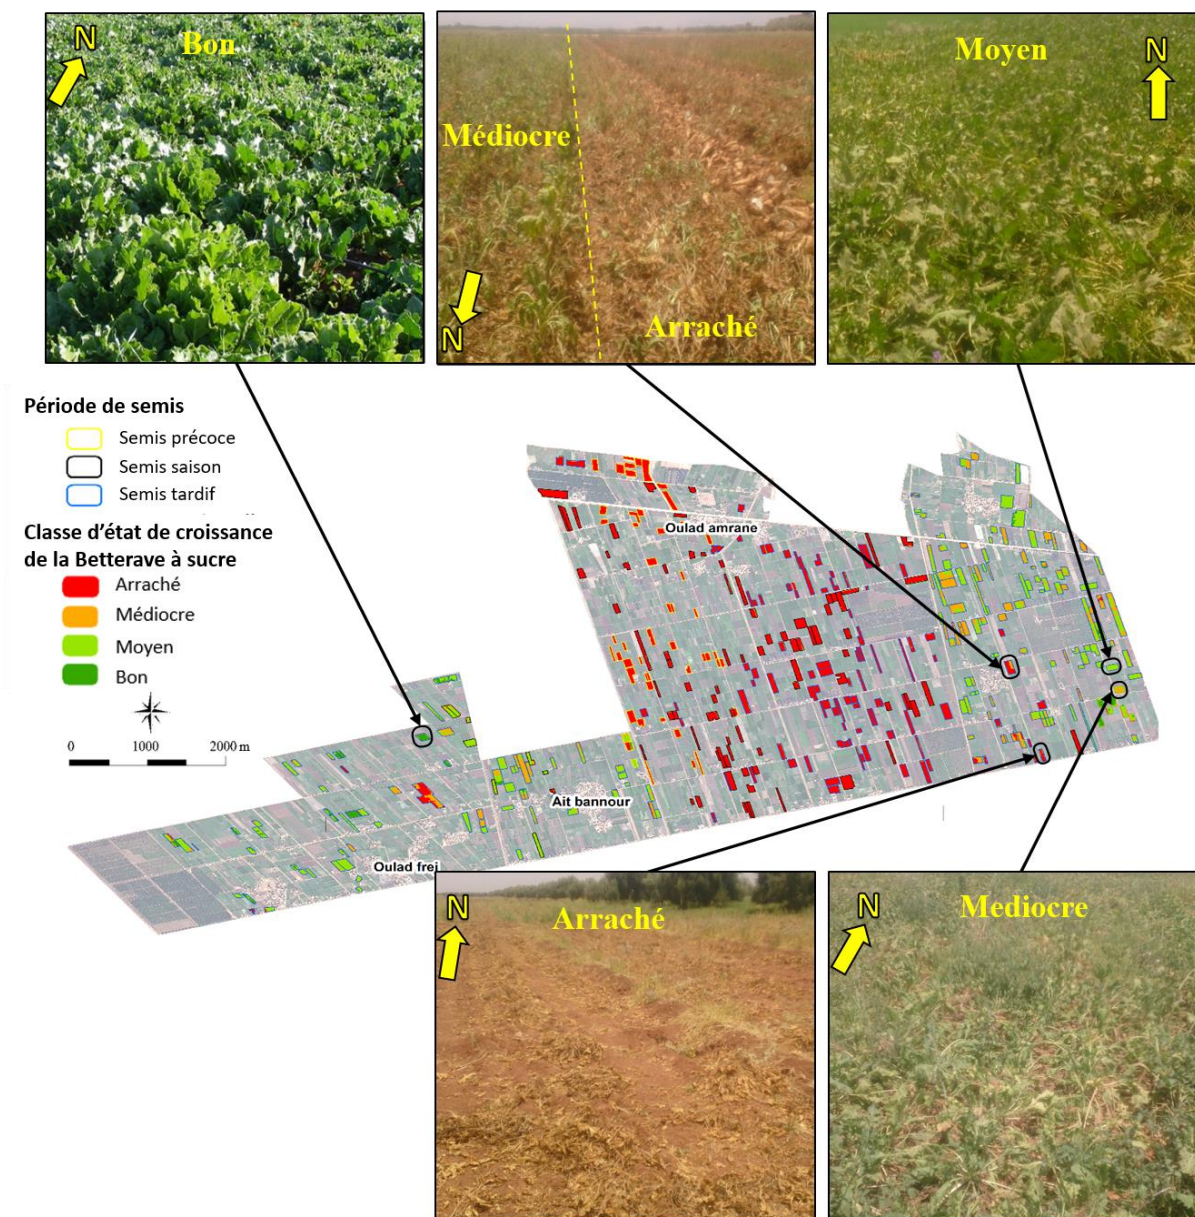


Figure 4.8 Localisation et photographies de quelques exemples de différentes classes d'état de betteraves à sucre au 26 juin 2016.

Pour mettre en évidence l'apport du suivi réalisé, nous avons procédé à une comparaison de l'état de la betterave à sucre entre les deux années agricoles 2013-2014 et 2015-2016. Pour la première année agricole, aucun suivi ni intervention n'ont eu lieu.

Les **Figure 4.9.a** et **Figure 4.9.b** illustrent respectivement l'évolution de la betterave à sucre des deux campagnes agricoles 2013-2014 et 2015-2016, en déterminant le

pourcentage de chaque état (médiocre, moyen, bon et arraché) en fonction du temps. Le pourcentage a été utilisé dans la comparaison au lieu des superficies, parce que la superficie totale de la betterave à sucre de la zone d'étude est différente dans les deux années agricoles.

Pour la **Figure 4.9.a**, on observe que pour les trois dates 24 Décembre, 26 Février et 30 Mars, les superficies de la betterave à sucre en bon état sont très élevées par rapport à celles des parcelles à moyen et à faible état. Les pourcentages des surfaces des trois états évoluent d'une manière constante, supérieure à 75%, supérieure à 19%, environ 1% et égale à 0% respectivement pour les états bons, moyens, faibles et arrachés. Ensuite, la courbe des parcelles à bon état commence à diminuer progressivement à partir de 30 Mars jusqu'à 5% au 4 Juillet, alors que la courbe des superficies des parcelles en moyen état, croît jusqu'à 31% au 15 Avril et recommence à descendre à 19% au 4 Juillet. La même chose pour la courbe des superficies des parcelles à médiocre état, sauf que, celle-ci a connu une deuxième augmentation à partir du 17 Mai pour enregistrer 24% au 4 Juillet. Pour la courbe des superficies des parcelles arrachées, elle est désignée par une croissance graduelle du 15 Avril pour arriver à la moitié du pourcentage des superficies de la betterave à sucre à la date finale du suivi. Pour la **Figure 4.9.b**, toutes les courbes se manifestent apparemment de la même manière que celles de la **Figure 4.9.a**. Toutefois, les pourcentages des parcelles à bon, à moyen et à médiocre état au 29 Décembre sont respectivement 52,3%, 39,1% et 8,6%. Puis, une augmentation des superficies des parcelles à bon état (85%) en parallèle avec une diminution de celle de faible (1,5%) et moyen état (13,6%) est observée au 17 Février.

Le début de la première année agricole s'est caractérisé par une dominance de la betterave sucrière à bon état contrairement à ce qui est observé pendant la deuxième année agricole, qui a connu l'existence de superficies importantes de la betterave sucrière à médiocre et à moyen état. Cette diminution de la superficie des parcelles à bon état est due principalement au retard d'irrigation. Ce retard est causé par les travaux de reconversion du système d'irrigation du gravitaire au goutte à goutte, au début de la campagne agricole 2015-2016. L'augmentation des superficies de la betterave sucrière à bon état entre 29 Décembre et 28 Mars est expliquée par le suivi

spatio-temporel et les interventions effectuées sur terrain. Ledit suivi a mis en évidence les parcelles anormalement entretenues et qui nécessitent une intervention de l'agriculteur. Grâce à ces interventions durant la période du suivi, l'état des parcelles a connu une amélioration progressive. Ceci a permis aux parcelles de bon état d'atteindre un maximum de 87,2% des superficies au 28 Mars et de dépasser le maximum (79,81%) de la même classe enregistré au 30 Mars de l'année agricole 2013-2014.

L'arrachage était effectué selon un calendrier bien défini dont la date d'arrachage de chaque parcelle était fixée en fonction de son emplacement (**Section 4.4**). En se basant sur ces dates, les agriculteurs arrêtent l'irrigation des parcelles programmées pour l'arrachage 15 jours avant cette opération. Chose qui explique une évolution croissante des parcelles à médiocre état accompagnée d'une chute des superficies des parcelles à bon état juste avant l'arrachage qui a eu lieu le 17 avril (**Figure 4.9.a**). A cause de cette action (arrachage), on observe une diminution des parcelles de la betterave sucrière à médiocre état. Pour la **Figure 4.9.b** (2015-2016) la même chose est arrivée avant et après l'arrachage, mais on ne l'observe pas dans cette figure parce que l'arrachage s'est effectué entre les deux dates 28 Mars et 27 avril. Concernant la classe de la betterave à sucre à moyen état, on constate qu'elle reste presque constante durant la plupart du temps dans les deux campagnes agricoles. La stabilité de cette classe est justifiée par sa position intermédiaire jouant un rôle de correspondance entre les deux classes faible et bon état.

Vers la fin des deux campagnes agricoles, les parcelles de la betterave sucrière à bon et à moyen état disparaissent progressivement au moment où la superficie des parcelles à faible état et les parcelles arrachées continuent en augmentation jusqu'à la disparition totale des deux premières classes. Par la suite, le pourcentage des parcelles à faible état diminue en subissant à l'arrachage jusqu'à ce que la classe des parcelles arrachées atteigne 100%.

Le contrôle des parcelles de la betterave à sucre a donné ses fruits sur le rendement moyen du CDA 536 qui a passé du 73 T/ha durant l'année 2013/2014 à 75 T/ha pendant l'année agricole 2015/2016 ([SUTA, 2016](#)).

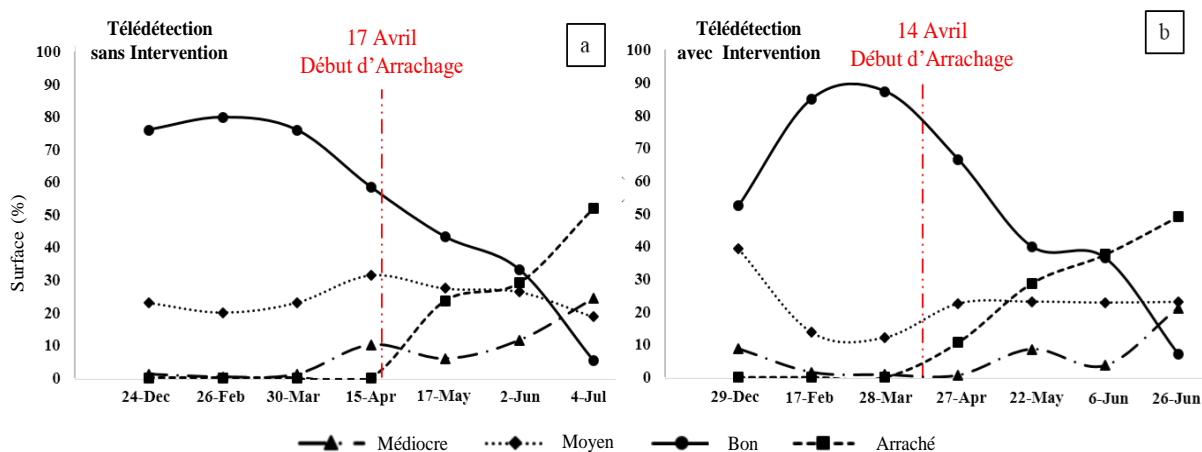


Figure 4.9 Variation de la dynamique des différents états de la betterave à sucre à l'aide de NDVI. (a) Landsat-8 en 2013-2014 et (b) Sentinel-2A en 2015-2016.

4.4.2 Problèmes agricoles détectés

Le suivi spatio-temporel effectué sur la betterave à sucre dans le cadre de cette étude a permis d'identifier des problèmes dans des parcelles précises et donc de les traiter par des actions ciblées, afin de réduire les impacts économiques et écologiques négatifs de la gestion des parcelles en réduisant les effets des stress hydriques, des mauvaises herbes, des maladies cryptogamiques (par exemple via l'application contrôlée de fertilisants ou de pesticides). Ce suivi a autorisé la détection des parcelles mal entretenues qui exigent une intervention immédiate par l'agriculteur. Parmi les paramètres dégradant l'état de la betterave sucrière et limitant sa croissance normale on trouve les mauvaises herbes (**Figure 4.10.a**). Ces éléments entrent en concurrence avec la betterave sucrière en ce qui concerne l'eau, les éléments nutritifs et la lumière, ce qui minimise l'interception de rayonnement par la plante. A ce stade un désherbage est recommandé, soit manuel ou chimique en utilisant des herbicides. La **Figure 4.10.b** illustre l'effet de l'utilisation irrationnelle des herbicides sur la betterave sucrière. L'application excessive de ce type de produits provoque des effets nuisibles sur le développement des plantes, à savoir le retard de croissance. En plus des mauvaises herbes, les ravageurs comme la larve Cléon (larva of Beet weevil en anglais) **Figure 4.10.c**, provoquent également des gros dégâts de la betterave à sucre, notamment les morsures ainsi que le jaunissement des feuilles de cette plante provoquant une

diminution de l'activité chlorophyllienne, du poids des racines et de la teneur en sucre (Stevens *et al.*, 2004). La carence en oligo-élément, notamment le Magnésium est aussi l'un des problèmes qu'on a détecté (**Figure 4.10.f**). Durant cette situation, la plante essaie de minimiser le nombre de feuilles de son bouquet foliaire en libérant les feuilles les plus âgées et en gardant les nouvelles feuilles situant au cœur de la plante.

La méthodologie développée a montré aussi une grande efficacité concernant la localisation des problèmes liés au stress hydrique (**Figure 4.10.d**). D'autres anomalies émanant des mauvaises pratiques agricoles dans les parcelles étudiées ont été reconnues, on cite à titre d'exemple :

- (1) l'utilisation des semoirs déréglés qui peuvent causer un semis profond des grains, ce qui engendre des complications au moment du lever de la plante (**Figure 4.10.e**) ;
- (2) L'écart temporel entre la date de semis et la date de la première irrigation provoque une perte énorme des semences par les ravageurs surtout les oiseaux.

Tous ces problèmes ont été détectés en se basant sur les classes des faibles valeurs des indices spectraux de végétation. Ces valeurs ont été enregistrées au niveau des plantes anormales dont l'activité chlorophyllienne est perturbée par le stress ou les maladies. En outre, l'effet de la mixture entre la végétation et le sol affecte les valeurs des indices spectraux de végétation, ce qui signifie qu'il y a une faiblesse dans la densité des plantes (peuplement).

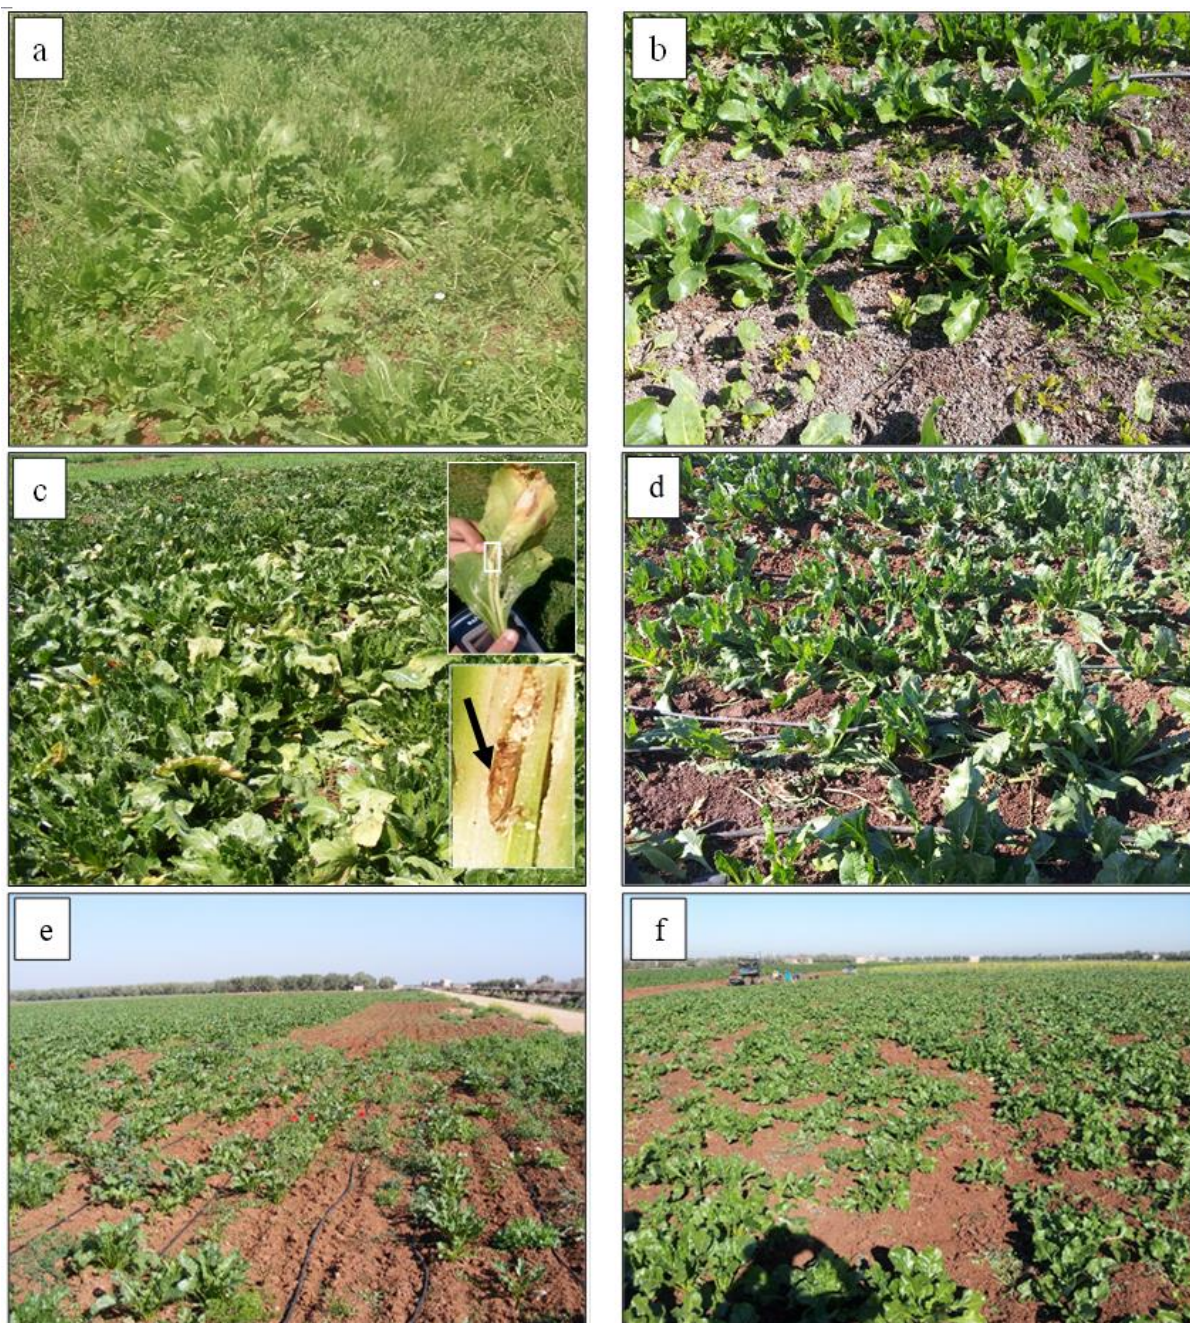


Figure 4.10 Photographies de différents problèmes détectés à l'aide de notre méthodologie.

4.5 Conclusion

Le suivi spatio-temporel de la betterave à sucre est une étape très importante pour l'amélioration du rendement de cette culture. Les enquêtes aléatoires de terrain ne sont pas efficaces au niveau du suivi de la croissance de la betterave à sucre. La

méthodologie développée en utilisant les deux satellites Landsat-8 et Sentinel-2A a prouvé son utilité pour l'estimation des superficies, le suivi et la surveillance des parcelles de la plante en question. Le seuillage des indices spectraux de végétation a permis une bonne restitution des classes de l'état de croissance de la betterave à sucre.

L'utilisation des trois indices NDVI, OSAVI et EVI couplée aux observations de terrain a permis le suivi spatio-temporel du développement de la betterave à sucre et la bonne gestion de ses parcelles. D'après la comparaison et la confrontation des résultats de ces trois indices à la réalité de terrain, NDVI était l'indice le plus approprié pour le suivi de la betterave à sucre.

A la fin du mois de décembre de la deuxième campagne agricole, 52,3% de la superficie cultivée se trouvait dans un bon état. Par la détection et la localisation géographique des parcelles dont la croissance était moyenne à faible, l'intervention sur le terrain du staff agronomique de SUTA pour la sensibilisation des agriculteurs était ciblée et concentrée sur les parcelles à problèmes potentiels ainsi que les parcelles mal entretenues nécessitant une intervention immédiate. Ainsi, plus de 87,2% de la superficie cultivée s'est trouvée dans un état bon à moyen à la fin du mois de mars de la même campagne. Ce suivi a abouti à une amélioration de l'état des parcelles. Il est considéré également comme étant un moyen de contrôle des parcelles qui subissent une dégradation. En comparant les deux campagnes agricoles 2013-2014 et 2015-2016, on a observé que la deuxième année a connu une amélioration remarquable au niveau de l'évolution de la qualité de la betterave sucrière. Cette amélioration s'est traduite par la contribution de la méthodologie adoptée avec d'autres facteurs dans l'amélioration du rendement moyen des parcelles par 2 T/ha dans la deuxième année agricole.

À la lumière des résultats obtenus, il s'avère que les données et les techniques utilisées peuvent être développées pour améliorer la précision des résultats. De ce fait, on recommande la fusion des images satellitaires optiques Sentinel-2 et des images radar Sentinel-1, surtout pour avoir plus de précision sur l'état hydrique de la betterave à sucre.

**5. ANALYSE SYNERGETIQUE DES DONNEES RADAR
ET OPTIQUES POUR UNE CARTOGRAPHIE PRECOCE
DE LA BETTERAVE A SUCRE**

5 ANALYSE SYNERGETIQUE DES DONNEES RADAR ET OPTIQUES POUR UNE CARTOGRAPHIE PRECOCE DE LA BETTERAVE A SUCRE

5.1 Introduction

Selon les Nations unies, la population mondiale devrait passer de 6,1 milliards en 2000 à 9,7 milliards en 2050 (*United Nations*). Cette énorme croissance démographique, exige plus d'efforts pour produire davantage de produits alimentaires (agricoles), et ceci pour satisfaire les besoins en approvisionnement alimentaire (*Foley et al, 2011*). Cette croissance provoque une augmentation du taux d'expansion sur les terres agricoles ainsi que la pression sur les ressources naturelles (*Lambin et al, 2011; Godfray et al, 2010; Searchinger et al, 2008*). Parallèlement au changement climatique, le contrôle des ressources en eau et des terres arables devient de plus en plus important (*Brown et al, 2012*).

L'identification et la cartographie des types de cultures sont très importantes. Elles permettent en plus de la création d'un inventaire des zones agricoles, la délimitation des parcelles agricoles, la bonne gestion de l'itinéraire technique des parcelles agricoles et la prévision des rendements (*Georgi et al., 2018; Vizzari et al., 2019; Houborg et al., 2018*). Par conséquent, la procuration des informations au secteur public et privé, y compris les industries de l'agroalimentaire et des assurances, leur permet de bénéficier de ces informations pour estimer la production agricole et avoir des statistiques agricoles (*Sonobe et al, 2017; Fritz et al, 2018; Coleman et al, 2018*).

La betterave à sucre revêt une importance économique énorme au Maroc où la fourniture d'informations fiables en temps réel sur le développement de cette culture est essentielle pour faciliter son suivi spatio-temporel et vulgariser les interventions sur terrain visant l'amélioration de son rendement. Cependant, pour le suivi spatio-temporel de l'état de croissance de la betterave à sucre, on fournit encore des efforts manuels pour déterminer précocement son emplacement. Le coût élevé de ces méthodes manuelles suggère la nécessité de la transition vers des techniques plus efficaces. La

téledétection est un outil très utile pour collecter simultanément une grande quantité d'informations ([Ryu et al., 2011](#)). Comme il est convenu, certaines données in situ sont toujours indispensables pour calibrer et valider des modèles de classification. Essentiellement, la télédétection est généralement efficace pour réduire les coûts des enquêtes de terrain.

Aujourd'hui l'abondance des données optiques qui ont connu une progression au niveau de la résolution spatiale, temporelle et spectrale offrent des opportunités inévitables pour les applications en agriculture et améliorent constamment les résultats de la classification ([Tatsumi et al, 2015](#) ; [Li et al, 2015](#); [Jia et al, 2014](#) ; [Durgun et al, 2016](#)). De multiples travaux récents ont montré que l'imagerie optique fournie par des satellites comme Sentinel-2 est capable de fournir une cartographie précise des types de cultures ([Inglada et al., 2016](#) ; [Van Tricht et al., 2018](#)). Cependant, les nuages et les brouillards empêchent souvent l'acquisition des images optiques. Ils restent un inconvénient majeur pour les capteurs optiques, car ils ne peuvent pas être pénétrés par le rayonnement électromagnétique du VNIR. Ces derniers entraînent donc des lacunes dans l'imagerie optique ([Baret et al, 2013](#)). Parfois, même une seule image optique sans nuage ne peut pas être acquise à partir de la saison de croissance.

Le rayonnement de micro-onde (RADAR) à basse fréquence (1-10 GHz), ne dépend pas de l'éclairage solaire. Il a des longueurs d'onde supérieures à la taille des particules des nuages et pénètre dans la couverture nuageuse sans altération ([Campbell et al., 2011](#)). Le plus important encore, c'est que les observations de ces capteurs utilisant cette gamme de fréquences sont sensibles aux composantes structurelles de la végétation telle que la taille, la forme, l'orientation et à la rugosité ([Bouman et al, 1990](#)). En raison de la grande valeur de l'information sur la structure végétale contenue dans les amplitudes de rétrodiffusion du radar à synthèse d'ouverture (SAR) et la disponibilité gratuite des données SAR en bande C de l'ESA Sentinel-1, de nombreuses études précédentes se sont axées sur toute une gamme de méthodes avancées de classification pour cartographier les cultures, par le biais des séries chronologiques Sentinel-1 ([Xu et al., 2018](#); [Veloso et al., 2017](#); [Whelen et al., 2018](#); [Sonobe et al., 2017](#) ; [Rüetschi et al., 2017](#); [Ndikumana et al., 2018](#)).

L'utilisation des données d'image provenant d'un seul capteur peuvent présenter des limitations , notamment des informations incomplètes, incohérentes ou imprécises (*Fatone, Maponi et Zirilli 2001*) et l'incapacité de recueillir des données à des moments critiques. La complémentarité de l'information optique et radar permet le développement de procédures de classification multicapteurs qui exploitent simultanément les deux sources (*Joshi et al, 2016 ; Inglada et al., 2016*). Cela indique que l'intégration des données de Sentinel-1 et Sentinel-2 peut aussi représenter un grand potentiel pour une classification très précise des cultures. *Veloso et al, 2017* ont analysé des séries temporelles Sentinel-1 et des données optiques Sentinel-2 et ont montré que la rétrodiffusion SAR et l'indice NDVI peuvent être complémentaires pour des applications agricoles. Le rapport VH/VV en bande C, en particulier, s'est avéré être un bon élément de discrimination et adapté notamment aux applications sur les cultures.

Même si les classifications basées sur les pixels (PXB) ont permis d'avoir des classifications des différents objets de la surface terrestre avec des normes de précision satisfaisantes, Il faut se tourner vers les approches orienté-objet (OO) (*Lu & Weng 2005*). L'analyse d'images en se basant sur l'approche OO présente beaucoup d'avantages, notamment la capacité d'exploiter plus que l'information spectrale pour différencier les classes et incorporer d'autres éléments tels que la texture dans l'analyse (*Blaschke 2010*).

Bien que des efforts aient été déployés pour combiner l'imagerie optique et SAR en vue de l'identification des types de cultures, il existe à ce jour peu d'études qui se basent sur la combinaison de l'imagerie (Sentinel-1 et Sentinel-2) à date unique. Et vu que la cartographie précoce des types de cultures est primordiale pour un système opérationnel de suivi spatio-temporel de ces dernières, l'objectif de cette recherche est l'évaluation de la combinaison Optique/SAR pour l'extraction précoce des parcelles de la betterave à sucre en se basant sur l'approche de classification SVM basée sur l'approche orienté-objet.

5.2 Zone d'étude et données de terrain

Pour la zone d'étude, elle fait partie du périmètre irrigué de Tadla. On a travaillé sur deux sites (Pivots_FBS et Pivots_ZIDOUH) relevant du sous périmètre de Beni Amir (la rive nord d'oued Oum-Errabia) (**figure 5.1**). La majorité des surfaces agricoles dans ces sites sont de grandes parcelles en pivots irriguées avec un système d'aspersion. Le choix de la zone d'étude est justifié par la disponibilité des données de terrain. Ces données ont été collectées lors des missions de terrain menées dans le cadre du projet Sen2Agri ([Defourny et al., 2019](#) ; [El harti et al., 2017](#)). Elles comprennent l'emplacement des différents types de cultures. La deuxième raison pour laquelle on a choisi de travailler sur ces deux sites précités, c'est pour minimiser la durée des traitements qui prend beaucoup de temps et éviter la cession du travail de l'ordinateur. L'emplacement des deux sites d'étude est centré à 32° 47' 59" N et 6° 80' 81" O et 32° 37' 43" N 6° 97' 74" O pour les Pivots_FBS et les Pivots_ZIDOUH respectivement.

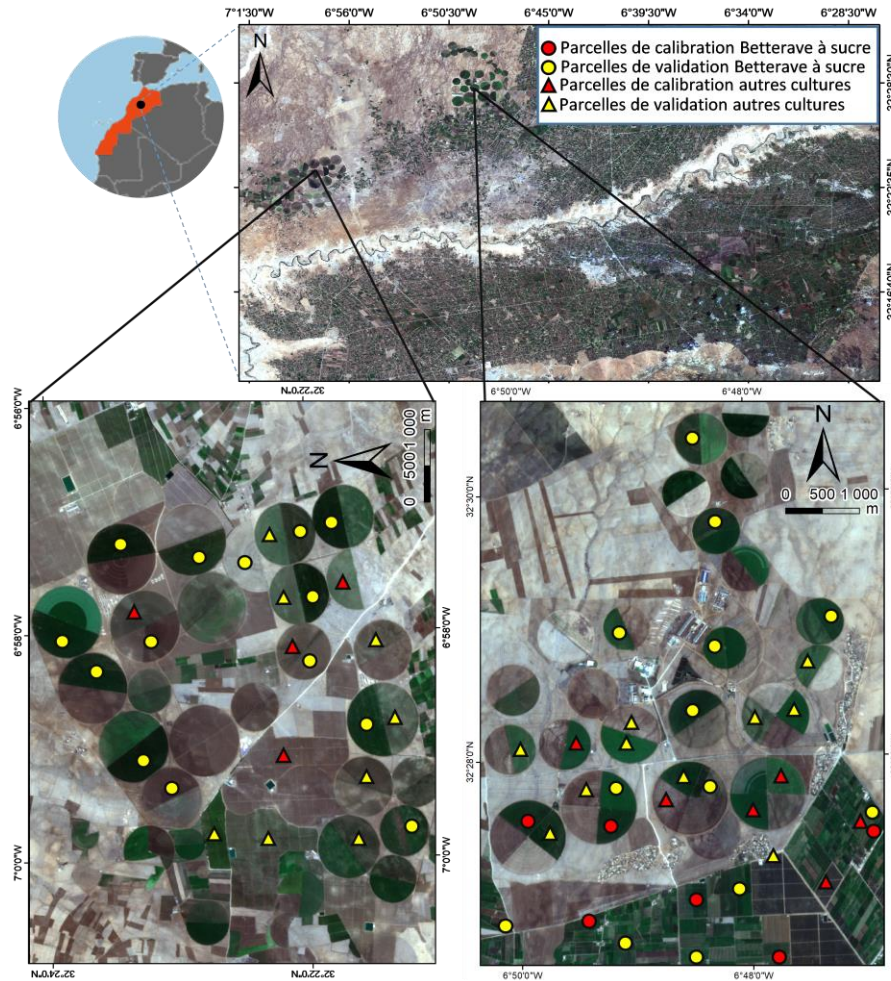


Figure 5.1 Localisation de la zone d'étude et des échantillons de calibration et de validation.

5.3 Matériel et Méthodes

5.3.1 Données images

La constellation Sentinel-1 (S-1) fait partie de la mission de l'agence européenne de l'espace (ESA) qui a pour but de mesurer la surface terrestre. On a collecté deux images S1 fonctionnant dans la bande C (fréquence = 5,405 GHz, longueur d'onde (λ) ~6 cm) pour les deux dates 26 décembre 2015 et 15 janvier 2016 (**Tableau 5.1**). Les deux images S-1 ont été générées à partir du produit du niveau 1 à haute résolution GRD (Ground Range Detected) avec un espacement de pixels de 10x10 m. elles étaient acquises en mode d'imagerie IW (interferometric wide swath) avec les polarisations VV

et VH. Ces images sont librement accessibles via la plateforme Web de Copernicus (<https://scihub.copernicus.eu/dhus/#/home>).

Aujourd'hui, Sentinel-2 (S-2) offre des images optiques à haute résolution spectrale et spatiale avec 13 bandes spectrales allant de 10 m à 60 m de résolution spatiale et avec une résolution temporelle de de 5 jours en combinant les satellites de la constellation S-2A et S-2B. Trois images ont été acquises sur nos sites d'étude pour les dates 29 décembre 2015, 07 février 2016 et 28 Mars 2016 (**Tableau 5.1**). Les images S-2 ont été téléchargées depuis le même hub de Copernicus.

Tableau 5.1 Les dates d'acquisition des images S-1 et S-2

Images	Satellite	Date d'acquisition
SAR	Sentinel-1	26 décembre 2015
		15 janvier 2016
Optique	Sentinel-2	29 décembre 2015
		07 février 2016
		28 mars 2016

5.3.2 Méthodologie

Comme indiqué dans l'introduction, le but de cette étude est d'évaluer l'utilité de la classification OO d'une combinaison d'images S-1 et S-2 pour l'identification précoce des parcelles de la betterave à sucre. La procédure adoptée pour atteindre les objectifs cités ci-dessus a été présentée dans la **figure 5.2**. Cette figure comprend principalement les prétraitements des données images, afin d'extraire des caractéristiques polarimétriques à partir des images S-1 et de segmenter les images S-2 pour la délimitation des parcelles agricoles. Puis, on a procédé à la détermination et à l'élimination des parcelles non cultivées. Par la suite, des classifications ont été effectuées sur les différentes images acquises suivant les deux approches PXB et OO.

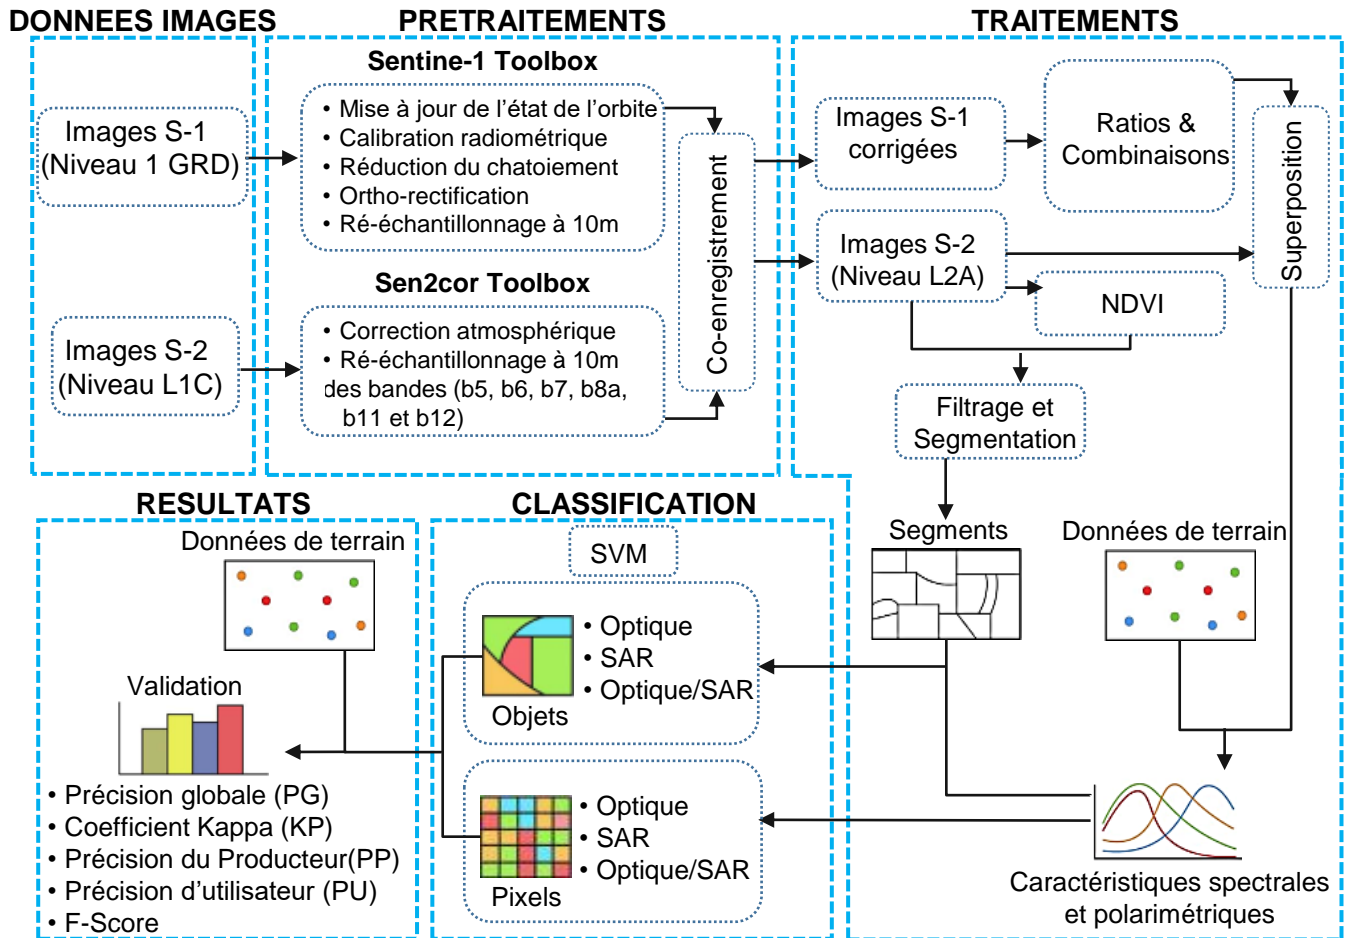


Figure 5.2 Organigramme de la méthodologie utilisée.

5.3.3 Prétraitements et traitements des données S-1 et S-2

Les images S-1 utilisées ont subi des corrections radiométriques et géométriques à l'aide de S-1 ToolBox (S-1TBX) développé par l'ESA. L'état de l'orbite des métadonnées S-1 a été mis à jour à l'aide de l'outil AOF (*Apply Orbit File*). La calibration radiométrique effectuée, vise à convertir les valeurs numériques des images S-1 en coefficients de rétrodiffusion (σ^0) tandis que la correction géométrique vise à ortho-rectifier l'image SAR en utilisant le MNT du SRTM à 30 m de résolution spatiale et ré-échantillonnées par la suite à 10m de résolution. On a amélioré la qualité de l'image en réduisant le chatoiement (speckle) radar par l'application du filtre Gamma Map avec une fenêtre de 5x5 pixels.

Les images S-2 ont été ortho-rectifiées et corrigées de l'effet atmosphérique en utilisant l'algorithme Sen2Cor. Un rééchantillonnage par interpolation bilinéaire à une résolution spatiale de 10 m a été effectué pour les bandes spectrales b5, b6, b7, b8a, b11 et b12.

A ce moment, un co-enregistrement des deux types d'images est nécessaire. Cette opération avait pour objectif d'aligner les pixels des deux images afin d'obtenir une précision inférieure au pixel près. C'est-à-dire, s'assurer que chaque cible au sol correspond au même pixel dans les deux types d'images. Puis, un ensemble de ratios et de combinaisons ont été calculés pour les images S-1 en se basant sur leurs polarisations VV et VH (**Tableau 5.2**). De même pour les images S-2, on a calculé l'indice de végétation NDVI pour chacune.

Pour la tâche de la combinaison des images S-1 et S-2, l'image optique et l'image SAR (y compris ses ratios et combinaisons) acquises respectivement le 29 décembre 2015 et 26 décembre 2015, ont fait l'objet d'une superposition et ont été enregistrées par la suite en une seule image.

Tableau 5.2 Les polarisations, Ratios et Combinaisons utilisées.

Images	Satellite	Date d'acquisition	Polarisations, Ratios et Combinaisons
SAR	Sentinel-1	26 décembre 2015	VV
			VH
		15 janvier 2016	VV-VH
			VH-VV
		VV+VH	
		Abs (VV-VH)	
		VV*VH	
		Abs (VV*VH)	
		VV/VH	
		VH/VV	

5.3.4 Les classifications par pixel (PXB) et Orienté-Objet (OO)

On appelle classification d'une image, le processus d'assigner un ensemble de pixels d'une image à une classe définie. Ce processus peut rencontrer des difficultés qui peuvent influencer la qualité de la classification. Ainsi, plusieurs approches de classification ont été développées au cours du temps pour remédier à cette complexité.

Parmi ces approches, on trouve la classification basée sur pixel (PXB) et la classification orienté-objet (OO).

La première approche consiste à différencier les éléments de la surface de la terre en se basant sur l'information spectrale contenue dans le pixel. Cela se fait soit d'une manière non-supervisée dont l'algorithme regroupe les structures sous-jacentes à partir de données non étiquetées, ou d'une manière supervisée qui consiste à entraîner l'algorithme par des exemples annotés. Mais cette approche est toujours exposée au problème de la mixture spectrale des pixels. L'approche OO consiste en la subdivision de l'image en régions (segments) à partir de pixels voisins en utilisant des algorithmes de segmentation.

Toutes les classifications implémentées dans le présent travail (**Tableau 5.1**) ont été effectuées à la base du classificateur SVM (**Section 3.3.5.2**).

Une classification à la base de la combinaison optique/SAR, une classification optique et une classification SAR ont été effectuées. Afin d'avoir des résultats de classifications directement comparables, les mêmes régions d'entraînements et de contrôle ont été utilisées d'une part pour l'apprentissage de l'algorithme SVM et d'autre part pour la validation de ses résultats pour toutes les classifications effectuées dans cette étude.

Tableau 5.3 Les différentes classifications effectuées.

Approche de classification	Type d'image unique ou combinaison	Date d'acquisition d'image
Pixels	Optique	29 Décembre 2015
	SAR	26 Décembre 2015
	Optique/SAR	26 Décembre 2015 & 29 Décembre 2015
Orienté-Objet	Optique	29 Décembre 2015
	SAR	26 Décembre 2015
	Optique/SAR	26 Décembre 2015 & 29 Décembre 2015
Orienté-Objet	SAR	15 Janvier 2016
Pixels	Optique	07 Février 2016
Pixels	Optique	28 Mars 2016

L'apprentissage de l'algorithme SVM a été fait dans des régions d'intérêts représentant les différentes cultures majeures, notamment La betterave à sucre, les céréales, la luzerne, le colza et l'arboriculture. A la fin de la classification, toutes les cultures sauf la betterave sucrière ont été mergées dans une seule classe dans le but d'obtenir une carte thématique contenant juste deux classes de culture (Betterave à sucre et autres cultures).

5.3.5 La segmentation

La segmentation des images Radar pour la délimitation des parcelles agricoles est très limitée à cause du chatoiement ([Qi et al., 2012](#) ; [Jiao et al., 2014](#)). Ce qui fait que les images S-1 sont inappropriées pour la délimitation des parcelles agricoles. En effet, on s'était basé complètement sur les images S-2 pour réaliser ce processus.

Dans ce travail, la segmentation a été mise en œuvre pour les images S-2 du 29 décembre 2015 et 07 février 2016 suivant plusieurs étapes, à savoir la détection des contours, l'agrégation des images de contours et la segmentation.

Détection des contours : Pour notre cas, on a utilisé l'algorithme Canny pour la détection des contours. Le contour est défini comme étant un changement brusque ou une discontinuité dans les valeurs des niveaux de gris (*Shrivakshan & Chandrasekar, 2012*). Cette opération est très indispensable pour une bonne analyse de l'image car elle sert à restituer les limites de parcelles. Le résultat de cette opération est obtenu sous forme d'une image de niveau de gris représentant les contours de l'objet (**Figure 5.3**). Plus le niveau de gris est élevé plus la discontinuité augmente entre les pixels adjacents. Cet algorithme était utilisé pour chacune des bandes spectrales et l'indice NDVI dérivé de S-2.

Agrégation des images de contours (AIC) : Cette étape consistait à agréger 11 images de contours (NDVI+10 bandes) pour chaque date. Ceci, se fait par l'application de la formule **Equation 5.1** sur les images de contours en conservant un poids égal pour chaque image. Par conséquent, on a eu une seule image en niveau de gris dont chaque pixel représente la somme des valeurs de 11 pixels superposés. Ensuite, une binarisation de cette dernière image par seuillage était mise en œuvre (**figure 5.3**).

$$AIC = b2+b3+...+b12+NDVI \quad (\text{Equation 5.1})$$

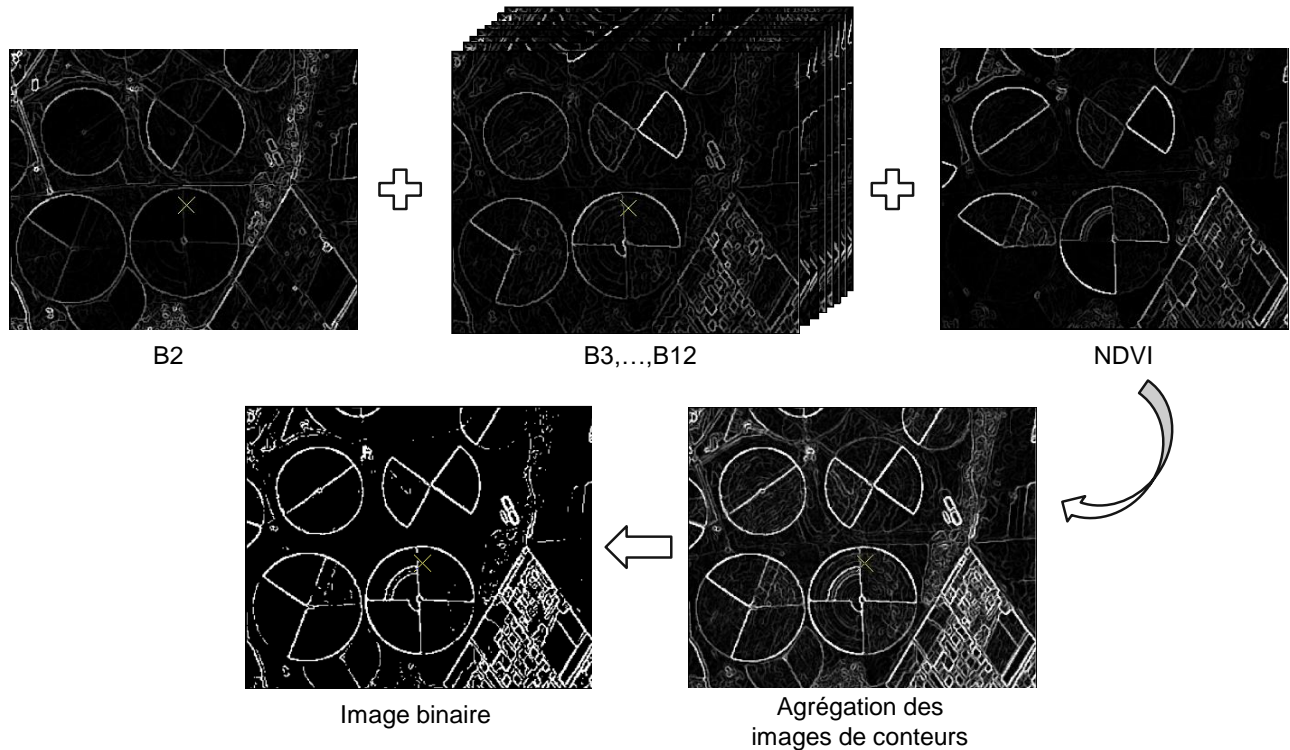


Figure 5.3 Illustration de l'agrégation de plusieurs images de contours issues de l'algorithme Canny et leur binarisation.

Segmentation : Dans l'étape de segmentation de l'image, les 10 bandes spectrales, l'image issue de l'agrégation et l'image binaire ont été utilisées comme entrées pour l'algorithme de segmentation multi-résolution (MRS). Cet algorithme consiste en la maximisation de l'homogénéité des objets en minimisant l'hétérogénéité moyenne entre objets et ceci en intégrant l'information spectrale et spatiale ([Watkins et al., 2019](#) ; [Niu et Ban, 2012](#) ; [Baatz & Schäpe, 2000](#)).

La MRS fonctionne selon une approche d'adaptation mutuelle en commençant du bas en haut à partir du niveau des pixels. Ceci se fait par la fusion des paires d'éléments adjacents de façon itérative sur la base des critères d'homogénéités prédéfinis par l'utilisateur, notamment Echelle (Scale), Couleur (Color)/ Forme (Shape) et la Douceur (smoothness)/Compacité (compactness) (**figure 5.4**).

L'échelle est un paramètre restrictif pour éviter que les objets ne deviennent trop hétérogènes. Pour des données hétérogènes, les objets résultants pour un paramètre d'échelle donné seront plus petits que pour des données plus homogènes. En effet,

l'échelle contrôle la taille des objets (*Benz et al., 2004*). Outre l'importance du paramètre d'échelle, la forme et la couleur ont un impact sur les caractéristiques des segments. Dans le cas de la MRS, l'augmentation de l'hétérogénéité f est en fonction du poids de l'information spectrale (couleur) et de l'hétérogénéité de la forme. Autrement dit, la forme est utilisée pour pondérer l'importance de l'information spatiale par rapport à l'information spectrale.

L'hétérogénéité spectrale est une fonction de l'écart-type qui dépend de la valeur de la bande spectrale et du nombre de pixels d'un objet. De plus, l'hétérogénéité des formes est en fonction à la fois de la douceur et de la compacité de l'objet. La douceur est définie comme étant le rapport entre la longueur de la bordure de l'objet et le cadre de délimitation de l'objet tandis que la compacité est décrite comme étant le rapport entre la longueur de la bordure de l'objet et le nombre de pixels de l'objet (*Dronova et al., 2015 ; Shuai et al., 2019 ; Akcay et al., 2018*). Les équations (**Equation 5.2**) et (**Equation 5.3**) calculent l'augmentation de l'hétérogénéité (f), tandis que w est le poids, Δh est l'hétérogénéité, n est le nombre de pixels, et σ_{band} est l'écart type.

$$f = w_{color} * \Delta h_{color} + w_{shape} * \Delta h_{shape} \quad (\text{Equation 5.2})$$

Avec : $w_{color} \in [0,1]$, $w_{shape} \in [0,1]$, and $w_{color} + w_{shape} = 1$

$$\Delta h_{Color} = \sum_{band} w_{band} (n_{merge} * \sigma_{band,merge} - (n_{obj1} * \sigma_{band,obj1} + n_{obj2} * \sigma_{band,obj2})) \quad (\text{Equation 5.3})$$

$$\Delta h_{shape} = w_{comp} * \Delta h_{comp} + w_{smooth} * \Delta h_{smooth} \quad (\text{Equation 5.4})$$

Avec : $w_{comp} \in [0,1]$, $w_{smooth} \in [0,1]$, and $w_{comp} + w_{smooth} = 1$

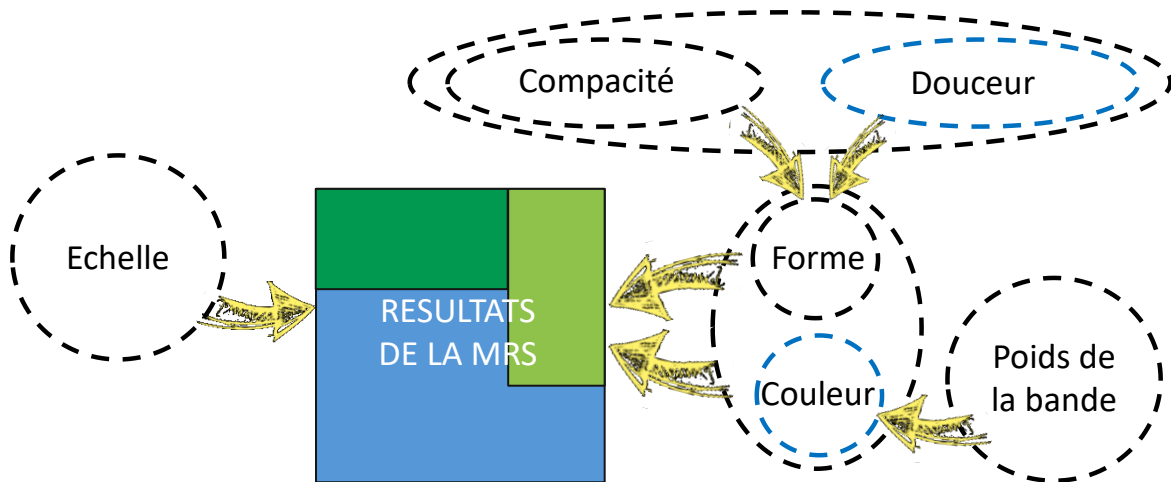


Figure 5.4 Fonctionnement de la segmentation Multirésolution.

Ces paramètres n'ont pas de règles définies. Les valeurs utilisées ont été choisies suivant une approche d'essais et d'erreurs dont chaque valeur a été testée de manière individuelle et incrémentale. Les deux étapes : détection des contours et segmentation sont implémentées sous Trimble eCognition Developer (version 9.0.1).

5.3.6 Parcelles non cultivées

L'élimination des surfaces qui ne représente aucun intérêt pour cette étude est une étape indispensable. Elle nous a permis de garder juste les parcelles agricoles contenant de la végétation respectivement pour l'image de 29 décembre 2015 et 07 février 2016. Pour ce faire, on a procédé à l'extraction de la moyenne des valeurs NDVI des deux images en utilisant les objets qui résultent de la segmentation. Puis, un seuillage a été effectué pour la suppression des objets portant des valeurs inappropriées.

5.3.7 La validation des résultats

Un ensemble de données sur les limites des champs de référence a été numérisé manuellement à partir d'images aériennes à très haute résolution acquise récemment. Les limites de champ numérisées ont été superposées des composés colorés des images Sentinel-2 acquises au cours de la saison de croissance actuelle de l'étude,

pour supprimer les limites qui ont changé entre la date d'acquisition de l'image à très haute résolution et les images sentinel-2 de la saison de croissance 2015-2016.

Les résultats de chacun des tests réalisés font l'objet d'une validation par comparaison des limites extraites par rapport aux limites des champs numérisées.

5.4 Résultats et discussions

5.4.1 La segmentation

La segmentation est une tâche difficile car comme il est cité dans la **section 5.3.5**, l'obtention d'une bonne segmentation s'effectue par un long processus d'essais et d'évaluation. Dans cette étude, nous avons testé tant de valeurs pour chaque paramètre en commençant par le poids de chaque bande. Pour cette étape, les bandes qui ont un effet important sur la segmentation sont B2, B8, B11, B12, l'image de l'agrégation des contours et l'image binaire des contours. En ce qui concerne l'échelle, les valeurs testées appartiennent à l'intervalle [50 ;...; 100]. L'incrémentation des valeurs testées était au début de l'ordre de 10. Après avoir déterminé la valeur approximative de l'échelle optimale, l'incrémentation des valeurs des tests est devenue de l'ordre de 1. Concernant la forme et la compacité, la même démarche était adoptée, en commençant par les valeurs les plus basses. Il faut noter que les valeurs de la couleur et la douceur sont aussi paramétrables, mais de manière indirecte par le changement respectivement de celles de la forme et la compacité.

Pour notre cas, les paramètres qui ont produit des résultats significatifs et qui ont été définis après un long processus d'essais sont 63 pour l'échelle, 0,8 pour la compacité et 0,7 pour la forme et 1, 3, 1, 1, 2, 3 respectivement pour les poids des bandes suivantes : B2, B8, B11, B12, l'image de l'agrégation des contours et l'image binaire des contours de cette dernière.

La **figure 5.5** représente les différents résultats de la segmentation. Sauf l'illustration **E** de la **figure 5.5** qui montre le résultat des bons paramètres, toutes les autres illustrations comprennent un seul paramètre différent de ce qui est choisi. Pour les illustrations **A** et **B**, on a changé juste l'échelle, et pour **C** la forme et la compacité ont

été changées en gardant l'échelle. L'illustration **D** garde les valeurs optimales pour l'échelle, la forme et la compacité, mais les poids des bandes ont connu des changements.

L'étude conduite par [Yan et Roy en 2016](#), confirme que la surface et la forme (géométrie) des parcelles influencent la qualité de la segmentation. Pour notre cas, les pivots, les grandes parcelles et les parcelles rectangulaires dont l'orientation est carrément parallèle aux directions Est ou Nord étaient bien délimitées. Cependant, les grandes parcelles présentant une forte variation interne étaient sur-segmentées. Ce défi était relevé par les post-traitements consistant en la fusion des objets composant une seule parcelle, le cas des pivots dans les illustrations **B**, **D** et **E**. Outre la segmentation excessive, la sous-segmentation des parcelles est un autre problème qu'on a observé lors de l'utilisation de grandes valeurs d'échelle. Surtout pour les petites parcelles connaissant une forte fragmentation spatiale où les frontières entre les parcelles voisines sont indistinguables. Un exemple de cette anomalie figure dans l'extrait **B'** de la **figure 5.5**. Un autre exemple de la sous-segmentation situé dans l'extrait **D'** et **D''** est causé par l'exclusion du poids des bandes (précitées) qui a un impact sur la segmentation.

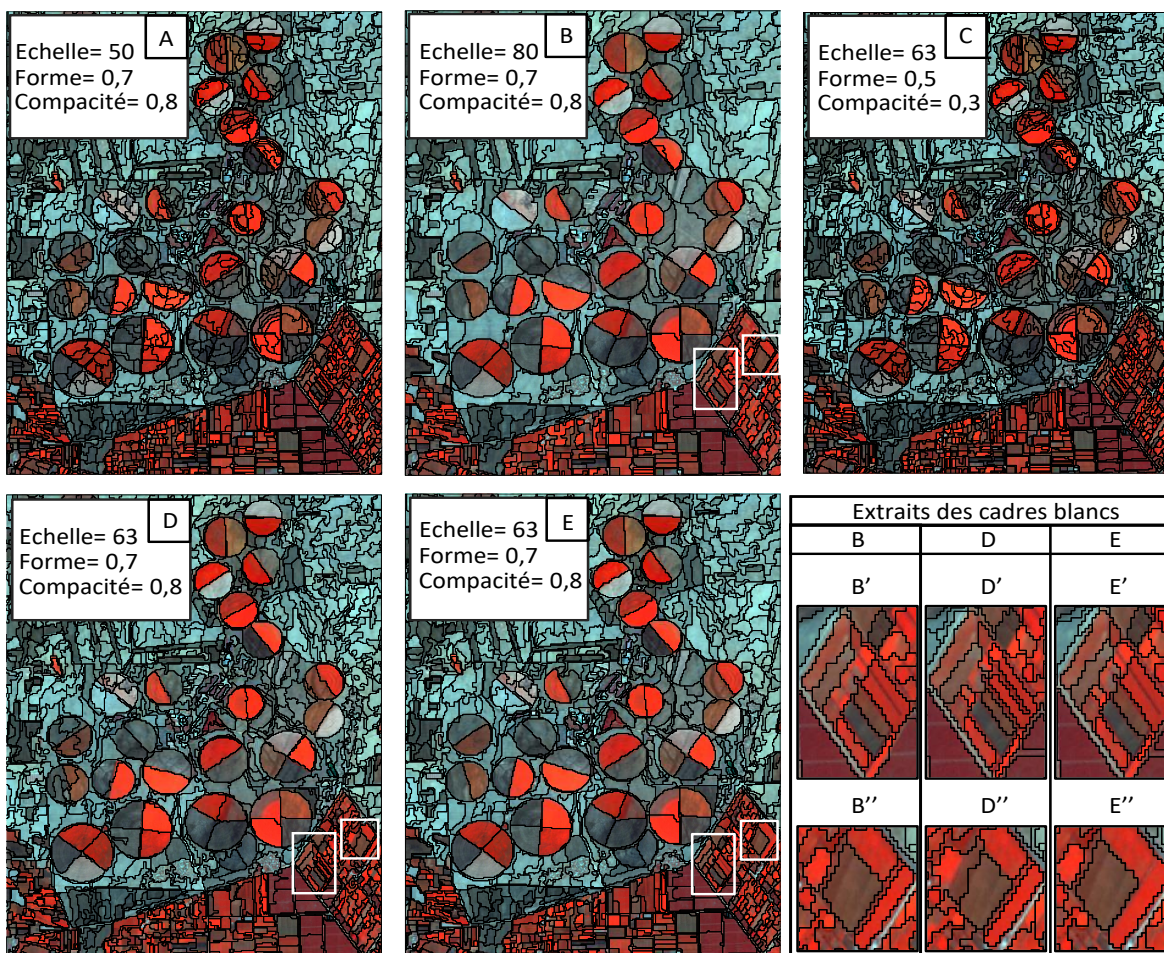


Figure 5.5 Illustration des limites extraites de la segmentation Multi-résolution MRS.

5.4.2 Les classifications PXB et OO

Dans cette section, on va vérifier si l'utilisation synergique de S-1 et S-2 a donné de meilleurs résultats de classification que l'imagerie à capteur unique. De même, les deux approches de classifications PXB et OO en utilisant l'algorithme de classification SVM ont été évaluées pour déterminer l'approche qui apporte plus de précision.

La **figure 5.6** et **figure 5.7** illustrent respectivement les classifications SVM d'images par PXB et par OO pour les Pivots_FBS et Pivots_Zidouh en utilisant les satellites S-1 et S-2 (acquises en décembre). Pour que la comparaison des deux approches PXB et OO soit raisonnable, aucune post-classification n'a été effectuée pour les résultats de l'approche PXB.

Pour les deux sites (**Figure 5.6** et **Figure 5.7**), les trois classifications (Optique, SAR et Optique/SAR) basées sur PXB représentent une différence au niveau de la capacité d'identifier les parcelles de la betterave à sucre.

Concernant la classification basée sur l'image optique, on observe que quelques parcelles présentent une variabilité intra-parcellaire ou autrement dit intra-classe. C'est-à-dire, des parcelles qui contiennent les deux classes de cultures (Betterave à sucre et Autres cultures). Certaines parcelles ont été également classées à tort en tant que autres cultures, alors que ces mêmes parcelles étaient correctement identifiées comme betterave à sucre dans les résultats issus de l'utilisation du SAR seul et en combinaison avec l'optique. L'autre observation, c'est qu'il y a des parcelles de la betterave à sucre que l'optique n'a pas pu identifier et classer en tant qu'autres cultures. La même chose a été observée pour les classifications basées sur OO. Cependant, grâce à cette dernière approche le problème de la mixture intra-classe a été efficacement traité. Ce qui fait que les résultats basés sur OO n'ont présenté aucune trace de chatoiement. Les cartes (PXB) produites à la base des données SAR et Optique/SAR montrent moins de chatoiement par rapport à celles issues seulement des données optiques.

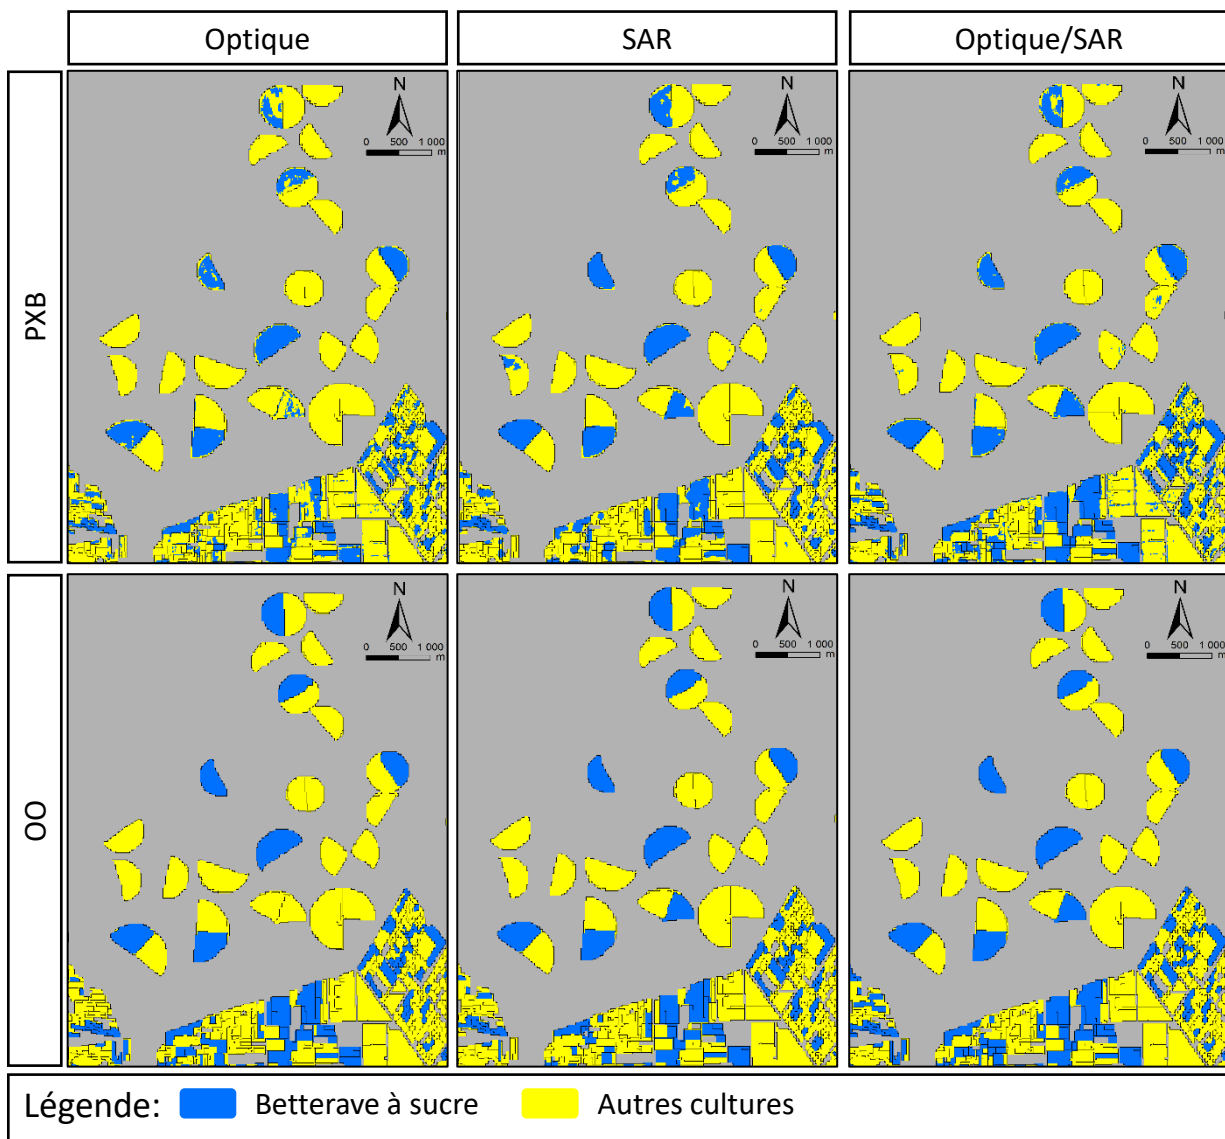


Figure 5.6 Les classifications SVM d'images S-1 et S-2 acquises en décembre par l'approche PXB et par OO pour le site Pivots_FBS.

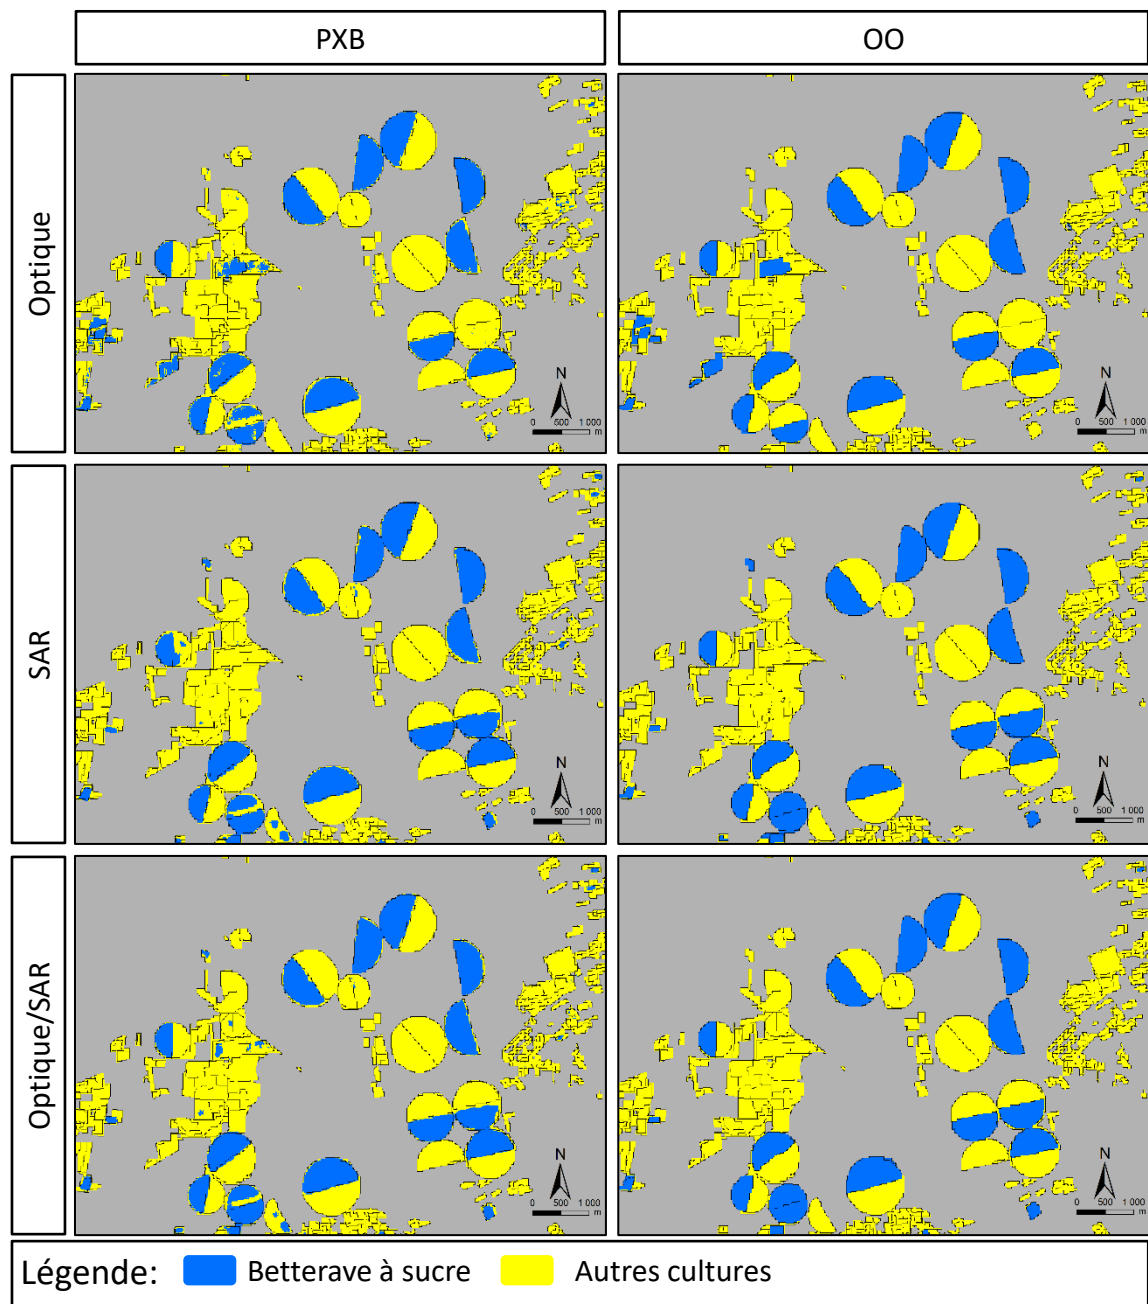


Figure 5.7 Les classifications SVM d'images S-1 et S-2 acquises en décembre par l'approche PXB et par OO pour le site Pivots_Zidouh.

De multiples études ont souligné que la classification OO, en combinant les données images SAR et Optique, fournit de plus intéressantes cartes de la couverture terrestre par rapport aux classifications par PXB. Compte tenu de ces faits, et de crainte que les résultats soient mieux évalués, une analyse comparative de la performance a été

effectuée à l'aide de la précision globale ainsi que du coefficient Kappa calculé pour toutes les classifications.

Le **tableau 5.3** montre l'évolution de la précision globale et du coefficient kappa pour les différentes classifications effectuées dans cette étude. Comme prévu, la précision globale et le kappa augmentent graduellement avec l'utilisation de l'approche OO. Cette augmentation est également observée en introduisant le SAR et la combinaison SAR/Optique.

Tableau 5.4 Les résultats de la précision globale et coefficient kappa pour chaque approche utilisée.

Dates	Décembre						Janvier	Février	Mars
Type du satellite	Optique		SAR		Optique/SAR		SAR	Optique	Optique
Approche de classification	PXB	OO	PXB	OO	PXB	OO	OO	PXB	PXB
Précision globale (%)	71,27	85,90	86,07	92,97	92,10	97,62	97,37	82,94	93,73
Coefficient Kappa	0,42	0,72	0,72	0,86	0,84	0,95	0,95	0,65	0,87

L'approche OO a donné de bons résultats de classification dans les trois types de données images (**Tableau 5.3**). Les précisions globales obtenues en décembre à la base de cette approche sont 85,90% pour l'optique, 92,97% pour le SAR et 97,37% pour la combinaison Optique/SAR, suivie par le résultat du SAR en janvier avec une précision globale de 97,37%. En février et Mars, l'approche PXB, la seule adoptée, a donné une précision de 82,94% et de 93,73% respectivement pour février et mars. Le coefficient kappa évolue de la même manière que la précision globale. Toutefois, il avait enregistré de mauvais résultats (0,42 et 0,65) pour la classification PXB des données optique respectivement en décembre et février.

L'évaluation de la performance de chaque classe a été évaluée à l'aide du score F1 qui se calcule suivant l'équation (**Equation 5.4**), la précision (P_i) et les paramètres de rappel (R_i). Autrement dit, P_i signifie la précision de l'utilisateur et R_i signifie la précision du producteur.

La figure 5.8 montre l'évolution des paramètres F1 score, Ri et Pi des approches utilisées pour la classe betterave à sucre, elle traduit de manière visuelle la variation des valeurs résultantes.

$$F1score = 2 * \frac{Pi * Ri}{Pi + Ri} \quad (\text{Equation 5.4})$$




Figure 5.8 L'évolution des paramètres F1 score, Ri et Pi des approches de classifications utilisées. (A) Approche PXB, (B) Approche OO, (C) Evolution des paramètres F1 score, Ri et Pi pour chaque approche de classification utilisée en fonction du temps.

Dans le cas de l'approche PXB, la Ri, la Pi et la F1 pour le SAR/Optique ont atteint les valeurs les plus élevées (94,57%, 88,28 et 91,31 respectivement). Pour l'approche OO, les mêmes facteurs d'évaluation ont atteint respectivement les valeurs 97,71%,

96,88% et 97,30% pour le SAR/Optique. A l'image de cette dernière, la classification des données SAR en janvier par l'approche OO a enregistré de bonnes précisions, 100% pour Ri, et 94,34%, 97,10% respectivement pour Pi et F1. Cependant, l'approche PXB en février a produit des valeurs moyennes (Ri (80,86%), Pi (80,40%) et F1 (80,63%)). Tandis que la même classification en mars a enregistré des valeurs élevées (Ri (92,00%), Pi (93,60%) et F1 (92,80%)) par rapport à celles de février, mais en même temps elle n'a pas atteint les valeurs du SAR/Optique_OO en décembre ni du SAR_OO en janvier.

Les résultats trouvés en se basant sur l'approche OO des données combinées Optique/SAR, ont prouvé qu'aucune image satellitaire prise en une date postérieure ne sera pas nécessaire pour l'amélioration de la classification portant sur l'isolement des parcelles de la betterave sucrière dans des stades de croissance précoces. Sauf pour la détermination des parcelles betteravières dont le semis est très tardif ou celles connaissant des problèmes de croissance au moment de l'émergence (les parcelles qui ne contiennent pas encore de végétation en fin décembre).

Brièvement, la difficulté rencontrée en essayant de distinguer les différents types de cultures étudiés qui présentent des caractéristiques spectrales optiques semblables dans leurs premiers stades de croissance, devient plus aisée avec l'utilisation des données Radar.

Le choix de fin décembre pour l'isolement des parcelles de la betterave à sucre n'a pas été fait par hasard, il était basé sur quelques paramètres, à savoir :

- 60% des surfaces cultivées en betterave à sucre ont un semis tardif ;
- L'analyse des séries temporelles de rétrodiffusion présentées par les papiers suivants : Khabbazan et al. 2019 ; Haagsma et al. 2015 ont montré que, la période choisie est celle la plus précoce présentant une différence élevée au niveau de la rétrodiffusion entre les cultures étudiées.

Cependant, il est possible d'utiliser cette méthode à partir d'octobre dans le but de déterminer les parcelles de la betterave sucrière (à semis précoce) qui ont déjà poussés.

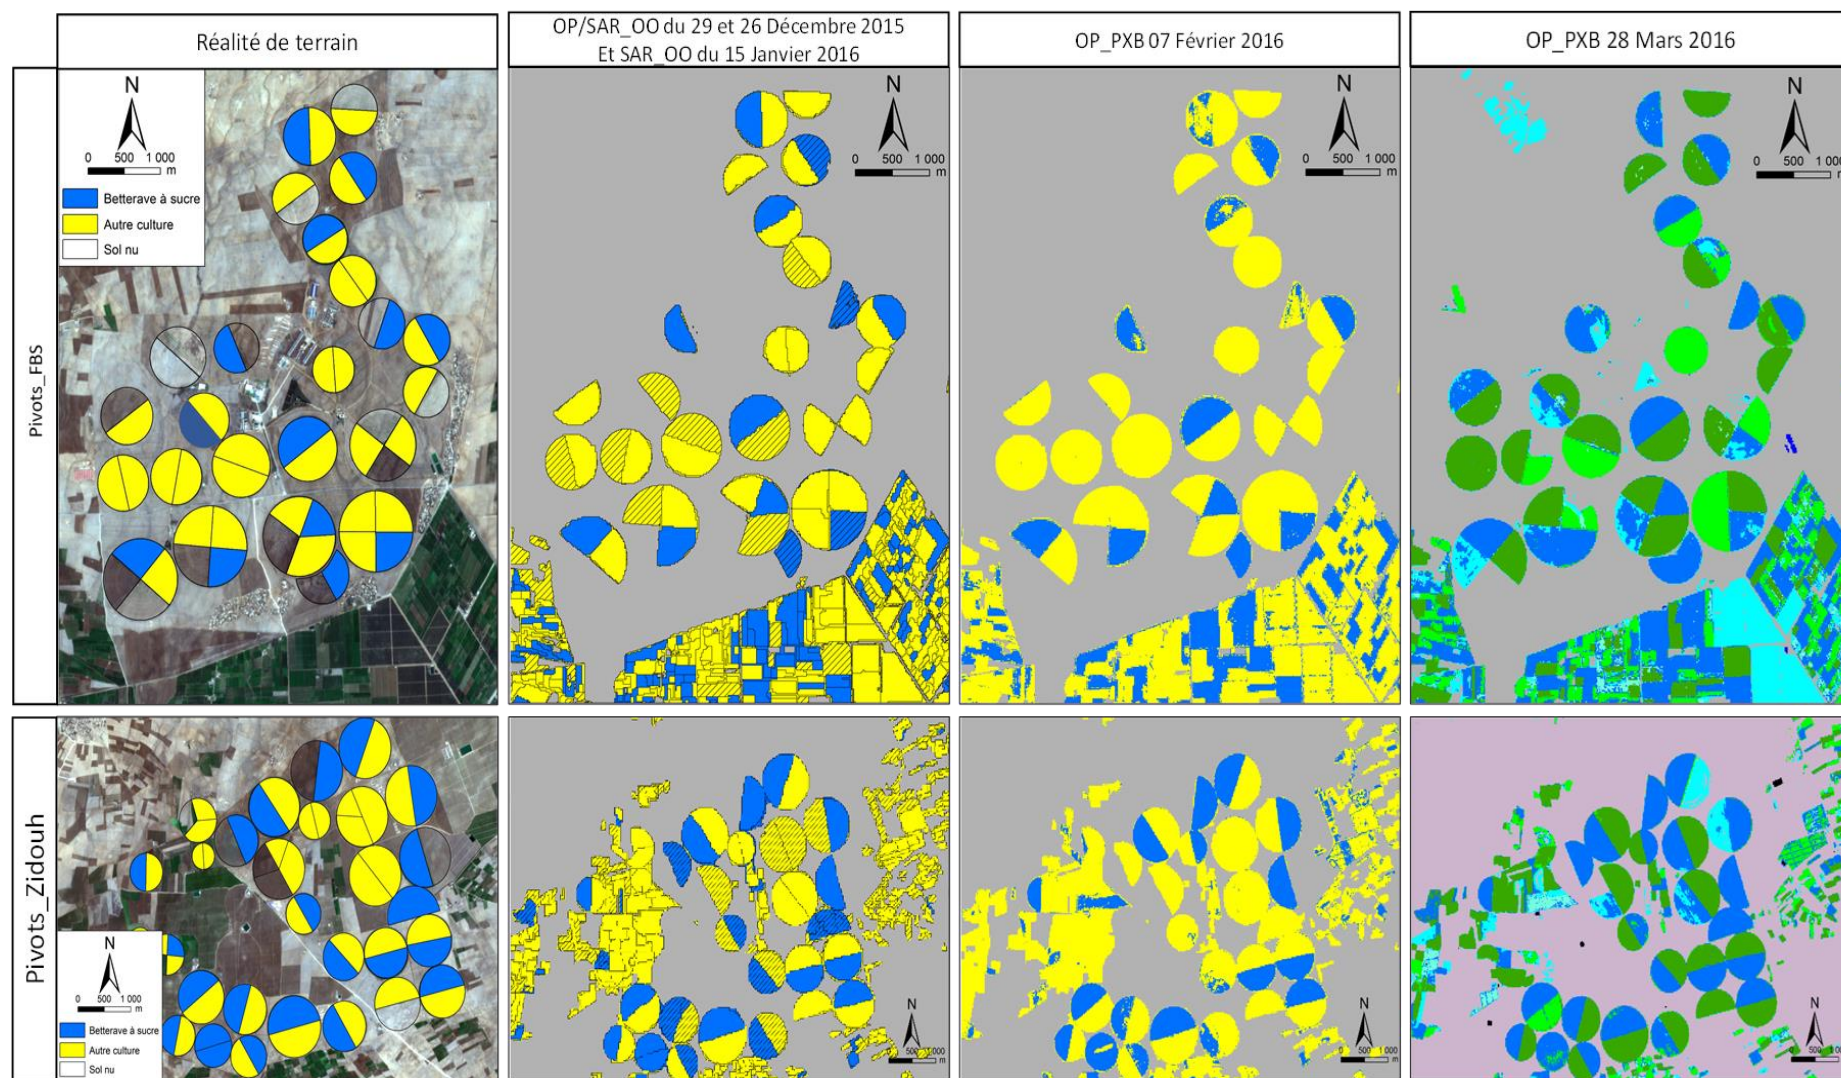


Figure 5.9 Comparaison de la distribution des parcelles de la betterave à sucre dans les deux zones de pivots étudiées.

La **figure 5.9** expose la distribution des parcelles isolées de la betterave à sucre à côté des autres cultures pour les deux zones de pivots étudiées. Celles de la deuxième position gauche présente le résultat issu de la classification OO des données combinées Optique/SAR en décembre et des données SAR seules en janvier, superposés en une seule carte (Dans le but de présenter les parcelles connaissant un retard de croissance). Au milieu droite, les deux cartes montrent les mêmes résultats mais qui sont issus de la classification PXB des données optiques en février. Les deux cartes de la droite montrent le résultat final de l'étude menée par [El Harti et al. 2017](#) dont l'objet était le choix de la meilleure date pour cartographier les cultures en se basant sur une seule image satellitaire optique.

La vision comparative globale de tous les résultats permet d'observer une grande similarité de ses derniers. Tandis qu'une analyse visuelle plus détaillée, confirme qu'il n'y a pas mal de différences entre les résultats. Citons à titre d'exemple quelques cas :

- Une bonne restitution des parcelles de la betterave à sucre en fin décembre par la méthode adoptée, par rapport aux résultats du février et mars;
- Une mauvaise capacité de distinguer quelques parcelles de la betterave à sucre en février en utilisant seulement les données optiques;
- Une confusion totale ou partielle dans la cartographie des parcelles de la betterave à sucre en février et en mars en utilisant seulement les données optiques.

En guise de conclusion, l'analyse statistique et visuelle des résultats a prouvé que la classification Orienté Objet des données combinées Optique/SAR, est une méthode très efficace pour la distinction et l'isolement des parcelles de la betterave à sucre dans un état de croissance précoce. Outre que cette méthode va autoriser le démarrage d'un suivi spatio-temporel précis et au bon moment, elle permettra de réduire le taux de travail de terrain par 80%. Les 20% du travail qui reste a pour objectif la calibration et le contrôle (validation) des résultats.

5.5 Conclusion

Dans ce chapitre, on a étudié la pertinence de l'utilisation synergétique de l'imagerie radar et optique pour la cartographie précoce des cultures de la betterave à sucre. Les résultats témoignent que l'utilisation combinée des données radar (Sentinel-1) et optique (Sentinel-2) perfectionne et améliore d'une manière significative la précision des classifications en comparaison avec le cas où l'imagerie optique ou radar est utilisée seule. Cette étude a également illustré que les rétrodiffusions VV et VH de Sentinel-1 en plus des ratios dérivés de ses dernières, ont un potentiel très important pour la cartographie précoce et précis de la betterave sucrière.

Contrairement à la classification basée sur les pixels (PXB), la classification orienté objet (OO) a montré qu'elle est très indispensable pour tous travaux de cartographie des cultures. Elle a permis à la base de la segmentation de restituer nettement les limites de parcelles et par conséquent, estimer avec précision la surface occupée par chaque cultures (dans notre cas : la betterave à sucre).

Pendant que l'analyse des séries temporelles des images optiques affirme qu'il est impossible d'atteindre un certain niveau de précision des cultures plus tôt dans la saison, l'analyse des séries temporelles des images radar montre le contraire. Non seulement cette dernière a prouvé que la distinction de la betterave sucrière par rapport des autres cultures dans un état de croissance précoce soit abordable, mais aussi elle nous a donné une idée sur la période éventuelle pour obtenir les meilleurs résultats.

En comparaison avec ce qui est constaté par les recherches menée par [El Hachimi et al 2021](#); [El Harti et al. 2017](#), notre étude a réalisé des résultats semblables. La précision globale des classifications des données optiques évolue en avançant dans le temps. La même chose pour le coefficient kappa. Concernant les données radar, la précision globale et le coefficient kappa des mêmes périodes ont enregistré des valeurs plus élevées que ceux des données optiques. Ils ont connu également une amélioration au fil du temps.

D'après les résultats trouvés, il s'avère que les techniques adoptées dans ce travail sont très ambitieuses. Elles peuvent être utilisées pour relever un autre défi qui porte

sur le suivi spatio-temporel des différentes cultures, en plein temps sans avoir aucune utilisation des algorithmes comblant les lacunes provoquées par les conditions météorologiques et plus particulièrement le couvert nuageux.

6. CONCLUSION GENERALE ET PERSPECTIVES

6 CONCLUSION GENERALE ET PERSPECTIVES

6.1 Conclusions

L'identification, la cartographie et la surveillance des cultures irriguées sont des étapes très importantes pour une bonne gestion de l'agriculture et pour le contrôle de la sécurité alimentaire visant une production alimentaire accrue, une rationalisation et optimisation de la consommation des eaux d'irrigation.

Les techniques conventionnelles de cartographie et de surveillance des cultures sont, laborieuses, longues, coûteuses et moins précises. Ces techniques ne conviennent plus à la vitesse de la croissance démographique et à la brutalité des changements climatiques nécessitant l'adoption de procédés techniques rapides et précis. Toutes les études menées sur l'utilité de la télédétection spatiale dans l'agriculture de précision ont prouvé l'efficacité de cette dernière dans l'identification et la surveillance des cultures soit en terme de précision ou en terme de rapidité.

Les résultats de ce travail de thèse peuvent être subdivisés en trois parties.

Malgré la petite taille des parcelles, la diversité des cultures et les changements de pratiques agricoles d'une parcelle à l'autre dans le périmètre irrigué de Tadla, l'utilisation des séries chronologiques de NDVI dérivées des données de Landsat-8 OLI rééchantillonnées à 15m a permis, de cartographier avec précision les cultures de ce périmètre.

La deuxième partie de ce travail de recherche est consacrée au développement d'un modèle de croissance de la betterave à sucre pour la surveillance du développement de cette culture. Afin d'atteindre notre objectif, la culture était surveillée durant les campagnes agricoles 2013-2014 et 2015-2016 en utilisant les données OLI de Landsat-8 et MSI de Sentinel-2. Le modèle de croissance développé dans la première année agricole est validé dans la deuxième année. En outre, des seuils de croissance sont déterminés pour chaque stade de développement de la culture. La comparaison des parcelles de la betterave à sucre au modèle de croissance développé a permis de classer les champs en fonction de leur état de croissance. Ce qui a permis de cibler les interventions de sensibilisation des agriculteurs et de traitements de la culture.

En revanche, durant la totalité du travail, on a rencontré des difficultés ainsi que des limitations de la méthode utilisée. Certaines acquisitions de Landsat-8 au printemps pourraient notamment être affectées par les nuages en plus de l'impossibilité de distinguer une culture de l'autre qu'après la fin de la saison agricole. L'utilisation des données optiques pour la cartographie des cultures et la surveillance de la betterave à sucre a permis d'atteindre des résultats satisfaisantes. Cependant, la disponibilité de la donnée est limitée par la couverture nuageuse. Ainsi, la troisième partie de ce travail était consacrée à l'utilisation de la donnée optique et Radar et la classification orientée objet pour la délimitation et la cartographie de la betterave à sucre. Les résultats obtenus ont montré une nette amélioration de la précision de classification de la betterave à sucre même en mois de décembre.

6.2 Perspectives

En perspective, d'autres travaux sont en cours de réalisation à savoir :

- L'utilisation et l'évaluation du potentiel des images radar pour le suivi spatio-temporel de la betterave à sucre;
- La combinaison des données météorologiques et satellitaires pour la prévision du rendement de la betterave à sucre;
- L'utilisation des données optique et radar pour l'estimation du besoin journalier en eaux, des cultures du périmètre irrigué de Tadla;
- La mise en place d'un système automatisé et cohérent sous forme d'une plateforme web permettant l'identification, la surveillance, l'estimation des besoins en eaux et la prévision du rendement de la betterave à sucre.
- L'utilisation de la plateforme Google Earth Engine pour l'automatisation des traitements.

BIBLIOGRAPHIE

Liste des références

1. Abbas A., S. Khan, N. Hussain, M.N. Hanjra, and S. Akbar, "Characterizing soil salinity in irrigated agriculture using a remote sensing approach" *J. Phys. Chem. Earth*. 2011. [doi:10.1016/j.pce.2010.12.004](https://doi.org/10.1016/j.pce.2010.12.004).
2. Abdikan, S., Bilgin, G., Sanli, F.B., Uslu, E., Ustuner, M.,. 2015. Enhancing Land Use Classification with Fusing Dual-Polarized TerraSAR-X and Multispectral RapidEye Data. *Journal of Applied Remote Sensing*, 9 (1).
3. ACHARKI, Siham, AMHARREF, Mina, FRISON, Pierre-Louis, et al. Cartographie des cultures dans le périmètre du Loukkos (Maroc): Apport de la télédétection radar et optique. *Revue Française de Photogrammétrie et de Télédétection*, 2020, no 222, p. 15-29.
4. Ahl, D.E., Gower, S.T., Burrows, S.N., Shabanov, N.V., Myneni, R.B., & Knyazikhin, Y. (2006). Monitoring spring canopy phenology of a deciduous broadleaf forest using MODIS. *Remote Sensing of Environment*, 104, 88-95
5. Ait Kadi, M., 2004. From water scarcity to water security in the Maghreb Region: the Moroccan Case. In: Marquina, A. (Ed.), *Environmental Challenges in the Mediterranean 2000–2050*. Springer, Netherlands, Dordrecht, pp. 175–185. http://dx.doi.org/10.1007/978-94-007-0973-7_11.
6. Ait Kadi, M., Ziyad, A., 2018. *Integrated Water Resources Management in Morocco. Global Water Security: Lessons Learnt and Long-Term Implications*. Springer, Singapore, Singapore, pp. 143–163. <http://dx.doi.org/10.1007/978-981-10-7913-96>.
7. Akcay, O., Avsar, E., Inalpulat, M., Genc, L., & Cam, A. (2018). Assessment of Segmentation Parameters for Object-Based Land Cover Classification Using Color-Infrared Imagery. *ISPRS International Journal of Geo-Information*, 7(11), 424.
8. Asseng, S., Van Keulen, H., & Stol, W. (2000). Performance and application of the APSIM Nwheat model in the Netherlands. *European journal of Agronomy*, 12, 37-54
9. Atzberger, C., 2013. Advances in remote sensing of agriculture: context description, existing
10. Azar, R., Villa, P., Stroppiana, D., Crema, A., Boschetti, M., Brivio, P.A., 2016a. Assessing in-season crop classification performance using satellite data: a test case in Northern Italy. *Eur. J. Remote Sens.* 49, 361–380. <http://dx.doi.org/10.5721/EuJRS20164920>.
11. Baatz, M., Schäpe, A., 2000. Multiresolution Segmentation: an optimization approach for high quality multi-scale image segmentation. [online]. Available from: In:

- Angewandte Geographische Informationsverarbeitung XII. Beiträge zum AGITSymposium Salzburg 2000, Karlsruhe, Herbert Wichmann Verlag, pp. 12–23. <http://scholar.google.com/scholar?hl=en&btnG=Search&q=intitle:Multiresolution+Segmentation+:+an+optimization+approach+for+high+quality+multi-scale+image+segmentation#1>.
12. Baret, F.; Weiss, M.; Lacaze, R.; Camacho, F.; Makhmara, H.; Pacholczyk, P.; Smets, B. GEOV1: LAI and FAPAR essential climate variables and FCOVER global time series capitalizing over existing products. Part1: Principles of development and production. *Remote Sens. Environ.* 2013, 137, 299–309.
 13. Bastiaanssen, W.G.M., Molden, D.J., Makin, I.W., 2000. Remote sensing for irrigated agriculture: examples from research and possible applications. *Agriculture Water Management* 46, 137-155.
 14. Basukala, A.K., Oldenburg, C., Schellberg, J., Sultanov, M., Dubovyk, O., 2017. Towards improved land use mapping of irrigated croplands: performance assessment of different image classification algorithms and approaches. *Eur. J. Remote Sens.* 50,187–201. <http://dx.doi.org/10.1080/22797254.2017.1308235>.
 15. Baup, F., Villa, L., Fieuzal, R., 2016. Sensitivity of X-band (σ° , γ) and optical (NDVI) satellite data to corn height variation. Accepted in *Advances in Remote Sensing*.
 16. Benz, U.C., Hofmann, P., Willhauck, G., Lingenfelder, I., Heynen, M., 2004. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. *ISPRS J. Photogramm. Remote. Sens.* 58 (3), 239–258. <https://doi.org/10.1016/j.isprsjprs.2003.10.002>.
 17. Berni, J., Zarco-Tejada, P., Suárez, L., González-Dugo, V., & Fereres, E. (2009). Remote sensing of vegetation from UAV platforms using lightweight multispectral and thermal imaging sensors. *Int. Arch. Photogramm. Remote Sens. Spatial Inform. Sci.* 38
 18. Betbeder, J., Fieuzal, N., Baup, F., 2016. Assimilation of LAI and dry biomass derived from optical and microwave satellite images into an agro-meteorological model to estimate soybean yield. Accepted in *Journal Selected Topics Applied Earth Observation and Remote Sensing*.
 19. Blaschke T 2010. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing* 65(1): 2-16.
 20. Borgogno-Mondino, E., Sarvia, F., & Gomasasca, M. A. (2019, July). Supporting Insurance Strategies in Agriculture by Remote Sensing: A Possible Approach at Regional Level. In *International Conference on Computational Science and Its Applications* (pp. 186-199). Springer, Cham.

21. Bouman, B.A.M.; van Kasteren, H.W.J. Ground-based X-band (3-cm wave) radar backscattering of agricultural crops. I. Sugar beet and potato; backscattering and crop growth. *Remote Sens. Environ.* 1990, 34, 93–105.
22. BOURAS, El Houssaine, JARLAN, Lionel, ER-RAKI, Salah, et al. Linkages between rainfed cereal production and agricultural drought through remote sensing indices and a land data assimilation system: a case study in Morocco. *Remote Sensing*, 2020, vol. 12, no 24, p. 4018.
23. Brandt, T., Mather, P.M., 2009. *Remote Sensing in the Optical and Microwave Regions, Classification Methods for Remotely Sensed Data*, second ed. CRC Press, New York, USA, pp. 1–39. <http://dx.doi.org/10.1201/9781420090741.ch1>.
24. Breiman, L., 2001. Random forests. *Mach. Learn.* 45, 5–32. <http://dx.doi.org/10.1023/A:1010933404324>.
25. Breiman, L., Friedman, J.H., Olshen, R.A., Stone, C.J., 1984. *Classification and Regression Trees*. Wadsworth & Brooks, Monterey, CA. Bruzzone, L., Carlin, L., 2006. A multilevel context-based system for classification of very high spatial resolution images. *IEEE Trans. Geosci. Remote Sens.* 44, 2587–2600. <http://dx.doi.org/10.1109/TGRS.2006.875360>.
26. Campbell, J.B.; Wynne, R.H. *Introduction to Remote Sensing*, 5th ed.; The Guilford Press: New York, NY, USA, 2011; ISBN 160918176X.
27. Carfagna, E., Gallego, F.G., 2005. Using Remote Sensing for Agricultural Statistics. *International Statistical Review*, 73, 3, 389-404.
28. Chang-an, L., Zhong-xin, C., Yun, S., Jin-song, C., Hasi, T., Hai-zhu, P., 2019. Research advances of SAR remote sensing for agriculture applications: A review. *Journal of Integrative Agriculture* 2019, 18(3), 506–525.
29. Chavez, P.S., 1988. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. *Remote Sens. Environ.* 24, 459–479. [http://dx.doi.org/10.1016/0034-4257\(88\)90019-3](http://dx.doi.org/10.1016/0034-4257(88)90019-3).
30. Chein, I.C., 2000. An information-theoretic approach to spectral variability, similarity, and discrimination for hyperspectral image analysis. *IEEE Trans. Inf. Theory* 46, 1927–1932. <http://dx.doi.org/10.1109/18.857802>.
31. Chen, Y., & Gillieson, D. (2009). Evaluation of Landsat TM vegetation indices for estimating vegetation cover on semi-arid rangelands: a case study from Australia. *Canadian Journal of Remote Sensing*, 35, 435-446
32. Chen, Z., Li, S., Ren, J., Gong, P., Zhang, M., Wang, L., Xiao, S., & Jiang, D. (2008). Monitoring and management of agriculture with remote sensing. *Advances in land remote sensing* (pp. 397-421): Springer

33. Cho, M.A., Debba, P., Mathieu, R., Naidoo, L., Aardt, Jv, Asner, G.P., 2010. Improving discrimination of Savanna tree species through a multiple-endmember Spectral Angle Mapper approach: canopy-level analysis. *IEEE Trans. Geosci. Remote Sens.* 48, 4133–4142. <http://dx.doi.org/10.1109/tgrs.2010.2058579>.
34. Claverie, M., Demarez, V., Duchemin, B., Hagolle, O., Ducrot, D., Marais Sicre, C., Dejoux, J.F., Huc, M., Keravec, P., Beziat, P., Fieuzal, R., Ceschia, E., Dedieu, G., 2012. Maize and sunflower biomass estimation in southwest France using high spatial and temporal resolution remote sensing data. *Remote Sensing of Environment*, 124, 844-857.
35. Clevers, J.G.P.W. (1997). A Simplified Approach for Yield Prediction of Sugar Beet Based on Optical Remote Sensing Data. *Remote Sensing of Environment*, 61, 221-228
36. Coleman, E.; Dick, W.; Gilliams, S.; Piccar, I.; Rispoli, F.; Stoppa, A. Remote Sensing for Index Insurance. Findings and Lessons Learned for Smallholder Agriculture. Available online: https://www.ifad.org/documents/38714170/39144386/RemoteSensing_LongGuide_2017.pdf/f2d22adb-c3b0-4fe3-9cbb-c25054d756fe (accessed on 12 October 2018).
37. Conrad, C., Fritsch, S., Zeidler, J., Rücker, G., Dech, S., 2010. Per-field irrigated crop classification in arid Central Asia using SPOT and ASTER data. *Remote Sens.* 2, 1035. <http://dx.doi.org/10.3390/rs2041035>.
38. Cooke, D.A., & Scott, J. (2012). *The sugar beet crop*. Springer Science & Business Media
39. Coppin, P., Jonckheere, I., Nackaerts, K., Muys, B., & Lambin, E. (2004). Review Article Digital change detection methods in ecosystem monitoring: a review. *International journal of remote sensing*, 25, 1565-1596
40. Crósta, A.P., Sabine, C., Taranik, J.V., 1998. Hydrothermal alteration mapping at Bodie, California, Using AVIRIS Hyperspectral data. *Remote Sens. Environ.* 65, 309–319. [http://dx.doi.org/10.1016/S0034-4257\(98\)00040-6](http://dx.doi.org/10.1016/S0034-4257(98)00040-6).
41. Darvishzadeh R, Wang T, Skidmore A, Vrieling A, O'Connor B, Gara WT, et al. Analysis of Sentinel-2 and RapidEye for Retrieval of Leaf Area Index in a Saltmarsh Using a Radiative Transfer Model. *Remote Sensing* 2019; 11. [10.3390/rs11060671](http://dx.doi.org/10.3390/rs11060671)
42. Daumard, F. (2010). Contribution à la télédétection passive de la fluorescence chlorophyllienne des végétaux. In: Ecole Polytechnique X
43. Davis, K.F., Rulli, M.C., Seveso, A., D'Odorico, P., 2017. Increased food production and reduced water use through optimized crop distribution. *Nat. Geosci.* <http://dx.doi.org/10.1038/s41561-017-0004-5>.

44. Defourny, P., Bontemps, S., Bellemans, N., Cara, C., Dedieu, G., Guzzonato, E., ... & Savinaud, M. (2019). Near real-time agriculture monitoring at national scale at parcel resolution: Performance assessment of the Sen2-Agri automated system in various cropping systems around the world. *Remote sensing of environment*, 221, 551-568.
45. Dennison, P.E., Halligan, K.Q., Roberts, D.A., 2004. A comparison of error metrics and constraints for multiple endmember spectral mixture analysis and spectral angle mapper. *Remote Sens. Environ.* 93, 359–367. <http://dx.doi.org/10.1016/j.rse.2004.07.013>.
46. Devadas, R., Denham, R.J., Pringle, M., 2012. Support vector machine classification of object-based data for crop mapping, using multi-temporal Landsat imagery. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* XXXIX B7, 185–190. <http://dx.doi.org/10.5194/isprsarchives-XXXIX-B7-185-2012>.
47. Dronova, I., Gong, P., Wang, L., Zhong, L., 2015. Mapping dynamic cover types in a large seasonally flooded wetland using extended principal component analysis and objectbased classification. *Remote Sens. Environ.* 158, 193–206. <https://doi.org/10.1016/j.rse.2014.10.027>.
48. Du, Y., Teillet, P.M., Cihlar, J., 2002. Radiometric normalization of multitemporal highresolution satellite images with quality control for land cover change detection. *Remote Sens. Environ.* 82, 123–134. [http://dx.doi.org/10.1016/S0034-4257\(02\)00029-9](http://dx.doi.org/10.1016/S0034-4257(02)00029-9).
49. Duarte, L., Teodoro, A.C., Monteiro, A.T., Cunha, M., Gonçalves, H., 2018. QPhenoMetrics: an open source software application to assess vegetation phenology metrics. *Comput. Electron. Agric.* 148, 82–94. <http://dx.doi.org/10.1016/j.compag.2018.03.007>.
50. Duchemin, B., Fieuzal, R., Augustin Rivera, M., Ezzahar, J., Jarlan, L., Cesar Rodriguez, J., Hagolle, O., Watts, C., 2015. Impact of sowing date on yield and water use efficiency of wheat analyzed through spatial modeling and Formosat-2 images. *Remote Sensing*, 7, 5951-5979.
51. Duchemin, B., Hadria, R., Erraki, S., Boulet, G., Maisongrande, P., Chehbouni, A., Escadafal, R., Ezzahar, J., Hoedjes, J.C.B., Kharrou, M.H., Khabba, S., Mougnot, B., Olioso, A., Rodriguez, J.C., Simonneaux, V., 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. *Agriculture Water Management*, 79, 1-27.
52. Durgun, Y.; Gobin, A.; Van De Kerchove, R.; Tychon, B. Crop Area Mapping Using 100-m Proba-V Time Series. *Remote Sens.* 2016, 8, 585.
53. El harti, A., Bachaoui, E., Elghomari, A., Elhachimi, J., Ouzemou, J. Determination of the most favorable period for discrimination of different crops using a single S-2 image. 3rd Sen2Agri User Workshop-Rome,28-29 (2017).

54. El Harti, A., Lhissou, R., Chokmani, K., Ouzemou, J.-E., Hassouna, M., Bachaoui, E.M., El Ghmari, A., 2016. Spatiotemporal monitoring of soil salinization in irrigated Tadla Plain (Morocco) using satellite spectral indices. *Int. J. Appl. Earth Obs. Geoinf.* 50, 64–73. <http://dx.doi.org/10.1016/j.jag.2016.03.008>.
55. Exelis Visual Information Solutions, 2016. Some details about ENVI's Support Vector Machine (SVM) classifier. (<http://www.harrisgeospatial.com/Learn/CaseStudiesDetail/TableId/320/ArtMID/1302/ArticleID/4267/4267.aspx>).
56. FAO: Food and Agriculture Organization, 2003. *World Agriculture: Towards 2015/2030 an FAO Perspective*. Earthscan Publications Ltd, London, UK, pp. 432. (Available from). (<http://www.fao.org/docrep/005/y4252e/y4252e00.htm>).
57. Fatone L, Maponi P & Zirilli F 2001. Fusion of SAR/optical images to detect urban areas. IEEE ISPRS Joint Workshop on Remote Sensing and Data Fusion over Urban Areas held 8-9 November 2001, Rome, Italy. University of Rome: 217-221.
58. Fieuzal, R., Baup, F., 2016. Estimation of leaf area index and crop height of sunflowers using multi-temporal optical and SAR satellite data. *International Journal of Remote Sensing*, 37, 2780-2809.
59. Fieuzal, R., Duchemin, B., Jarlan, L., Zribi, M., Baup, F., Merlin, O., Hagolle, O., Garatuza-Payan, J., 2011. Combined use of optical and radar satellite data for the monitoring of irrigation and soil moisture of wheat crops. *Hydrological Earth System Science*, 15, 1117-1129.
60. Fieuzal, R., Marais Sicre, C., Baup, F., 2017. Estimation of sunflower yield using a simplified agrometeorological model controlled by optical and SAR satellite data. *IEEE Journal of Selected Topics of Applied Earth Observation and Remote Sensing*.
61. Foley, J., Ramankutty, N., Brauman, K. et al. Solutions for a cultivated planet. *Nature* 478, 337–342 (2011). <https://doi.org/10.1038/nature10452>.
62. Folhes, M.T., Renno, C.D., Soares, J.V., 2009. Remote sensing for irrigation water management in the semiarid Northeast of Brazil. *Agriculture Water Management*, 96, 1398-1408.
63. Food and Agriculture Organization of the United Nations (FAO), 2017. Review of the available remote sensing tools, products, methodologies and data to improve crop production forecasts.
64. Fritz, S., See, L., Laso Baya, J.C., Waldner, F., Jacques, D., Becker-Reshef, I., Whitcraft, A., Baruth, B., Bonifacio, R., Crutchfield, J., Rembold, F., Rojas, O., Schucknechti, A., Van der Velde, M., Verdin, J., Wu, B., Yan, N., You, L., Gilliams, S., Mùcher, S., Tetrault, R., Moorthy, I., McCallum, I., 2018. A comparison of global agricultural monitoring systems and current gaps. *Agric. Syst.* 168, 258–272.

65. Garcia-Pedrero, A., Gonzalo-Martin, C., Fonseca-Luengo, D., Lillo-Saavedra, M., 2015a. AGEOBIA methodology for fragmented agricultural landscapes. *Remote Sens.* 7,767–787. <http://dx.doi.org/10.3390/rs70100767>.
66. Ghiyamat, A., Shafri, H.Z.M., Amouzad Mahdiraji, G., Shariff, A.R.M., Mansor, S., 2013. Hyperspectral discrimination of tree species with different classifications using single- and multiple-endmember. *Int. J. Appl. Earth Obs. Geoinf.* 23, 177–191. <http://dx.doi.org/10.1016/j.jag.2013.01.004>.
67. Girouard, G., Bannari, A., Harti, A.E., Desrochers, A., 2004. Validated spectral Angle Mapper Algorithm for geological mapping: Comparative study between Quickbird and Landsat-TM. In: *Proceedings 20th ISPRS Congress: Geo-Imagery Bridging Continents*, pp. 599–604, Available from: (<http://libra.msra.cn/Publication/10869785/validated-spectral-angle-mapperalgorithmforgeologicalmappingcomparative-study-between>).
68. Godfray, H.C.J.; Beddington, J.R.; Crute, I.R.; Haddad, L.; Lawrence, D.; Muir, J.F.; Pretty, J.; Robinson, S.; Thomas, S.M.; Toulmin, C. Food security: The challenge of feeding 9 billion people. *Science* 2010, 327, 812–818.
69. González Sanpedro, M.D.C., 2008. Optical and Radar Remote Sensing Applied to Agricultural Areas in Europe. Thèse présentée à l'université de Valence, Espagne.
70. Gumma, M.K., Nelson, A., Thenkabail, P.S., Singh, A.N., 2011. Mapping rice areas of South Asia using MODIS multitemporal data. *J. Appl. Remote Sens.* 0001 5 (1), 053547–053547-26. <http://dx.doi.org/10.1117/1.3619838>.
71. Haagsma, M. (2015). Crop monitoring with Radar.
72. Hadria, R., Duchemin, B., Baup, F., Le Toan, T., Bouvet, A., Dedieu, G., 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. *Agriculture Water Management*, 96, 1120-1127.
73. Hammani, A., Kuper, M., Bekkar, Y., & Zaz, H. (2006). Exploitation des Eaux souterraines dans le périmètre irrigué de Tadla (Maroc) Etat des lieux et éléments de méthodologie pour contribuer à une réflexion sur une gestion intégrée et durable des eaux souterraines et de surface. In, *Economies d'eau en Systèmes IRigués au Maghreb. Deuxième atelier régional du projet Sirma*
74. Hansen, P., & Schjoerring, J. (2003). Reflectance measurement of canopy biomass and nitrogen status in wheat crops using normalized difference vegetation indices and partial least squares regression. *Remote Sensing of Environment*, 86, 542-553

75. Hao, P., Wang, L., Niu, Z., 2015. Comparison of hybrid classifiers for crop classification using Normalized Difference Vegetation Index time series: a Case Study for Major Crops in North Xinjiang, China. PLoS One 10, e0137748. <http://dx.doi.org/10.1371/journal.pone.0137748>.
76. Hatfield, J.L., & Prueger, J.H. (2010). Value of using different vegetative indices to quantify agricultural crop characteristics at different growth stages under varying management practices. *Remote Sensing*, 2, 562-578
77. Hill, M. J., Ticehurst, C.J., Lee, J.-S. Grunes, M.R., Donald, G.E., Henry, D., 2005. Integration of Optical and Radar Classifications for Mapping Pasture Type in Western Australia. *IEEE Transactions on Geoscience and Remote Sensing*, 43 (7): 1665-1681.
78. Hill, R. V., Kumar, N., Magnan, N., Makhija, S., de Nicola, F., Spielman, D. J., & Ward, P. S. (2019). Ex ante and ex post effects of hybrid index insurance in Bangladesh. *Journal of development economics*, 136, 1-17.
79. Hong, G., Zhang, A., Zhou, F., Brisco, B., 2014. Integration of Optical and Synthetic Aperture Radar (SAR) Images to Differentiate Grassland and Alfalfa in Prairie Area. *International Journal of Applied Earth Observation and Geoinformation*, 28, 12–19.
80. Hsu, C.-W., Chang, C.-C., Lin, C.-J., 2010. A Practical Guide to Support Vector Classification. National Taiwan University, Taipei City, Taiwan. (<http://ntu.csie.org/~cjlin/papers/guide/guide.pdf>).
81. Huang, C., Davis, L.S., Townshend, J.R.G., 2002. An assessment of support vector machines for land cover classification. *Int. J. Remote Sens.* 23, 725–749. <http://dx.doi.org/10.1080/01431160110040323>.
82. Huang, C., et al., 2008. Use of a dark object concept and support vector machines to automate forest cover change analysis. *Remote Sens. Environ.* 112 (3), 970–985. <http://dx.doi.org/10.1016/j.rse.2007.07.023>.
83. Inglada, J., Vincent, A., Arias, M., Marais-Sicre, C., 2016. Improved Early Crop Type Identification by Joint Use of High Temporal Resolution SAR and Optical Image Time Series. *Remote Sensing*, 8 (5): 362.
84. Iounousse, J., Er-Raki, S., Elmotassadeq, A., Chehouani, H. 2015. Using an unsupervised approach of Probabilistic Neural Network (PNN) for land use classification from multitemporal Satellite images. *Applied Soft Computing* 30: 1-13.
85. Jacquin, A., Sheeren, D., & Lacombe, J.-P. (2010). Vegetation cover degradation assessment in Madagascar savanna based on trend analysis of MODIS NDVI time series. *International Journal of Applied Earth Observation and Geoinformation*, 12, S3-S10

86. Jaouad El Hachimi, Abderrazak El Harti, **Jamal-Eddine Ouzemou**, Rachid Lhissou, Chakouri Mouhcine et Amine Jellouli. (2021). Assessment of the benefit of a single sentinel-2 satellite image to small crop parcels mapping. *Geocarto International*, 1-17. <https://doi.org/10.1080/10106049.2021.1974955>
87. Jay S, Baret F, Dutartre D, Malatesta G, Héno S, Comar A, et al. Exploiting the centimeter resolution of UAV multispectral imagery to improve remote-sensing estimates of canopy structure and biochemistry in sugar beet crops. *Remote Sensing of Environment* 2019; 231: 110898. <https://doi.org/10.1016/j.rse.2018.09.011>
88. Jay S, Gorretta N, Morel J, Maupas F, Bendoula R, Rabatel G, et al. Estimating leaf chlorophyll content in sugar beet canopies using millimeter- to centimeter-scale reflectance imagery. *Remote Sensing of Environment* 2017; 198: 173-186. <https://doi.org/10.1016/j.rse.2017.06.008>
89. Jia, K.; Wei, X.; Gu, X.; Yao, Y.; Xie, X.; Li, B. Land cover classification using Landsat 8 Operational Land Imager data in Beijing, China. *Geocarto Int.* 2014, 29, 941–951.
90. Jiao, X., Kovacs, J., Shang, J., McNairn, H., Walters, D., Ma, B., Geng, X., 2014. Objectoriented crop mapping and monitoring using multi-temporal polarimetric RADARSAT-2 data. *ISPRS J. Photogramm. Remote. Sens.* 96, 38–46.
91. Joachims, T., 1998. Text categorization with Support Vector Machines: Learning with many relevant features. In: Proceedings C. Nédellec and C. Rouveirol, *Machine Learning: ECML-98: 10th European Conference on Machine Learning* Chemnitz, Germany, April 21–23. Berlin, Heidelberg, Springer Berlin Heidelberg, pp. 137–142. <http://dx.doi.org/10.1007/BFb0026683>.
92. Joshi, N.; Baumann, M.; Ehammer, A.; Fensholt, R.; Grogan, K.; Hostert, P.; Jepsen, M.R.; Kuemmerle, T.; Meyfroidt, P.; Mitchard, E.T.A.; et al. A review of the application of optical and radar remote sensing data fusion to land use mapping and monitoring. *Remote Sens.* 2016, 8, 70.
93. Karrou, M., Oweis, T., & Bahri, A. (2011). Improving water and land productivities in rainfed systems. *Community-Based Optimization of the Management of Scarce Water Resources in Agriculture in CWANA*. In: Report
94. Keshava, N., 2004. Distance metrics and band selection in hyperspectral processing with applications to material identification and spectral libraries. *IEEE Trans. Geosci. Remote Sens.* 42, 1552–1565. <http://dx.doi.org/10.1109/tgrs.2004.830549>.
95. Khabbazan, S., Vermunt, P., Steele-Dunne, S., Arntz, L. R., Marinetti, C., van der Valk, D., ... van derSande, C. (2019). Crop monitoring using Sentinel-1 data: A case study from The Netherlands. *Remote Sensing*, 11(16), [1887].

96. Kruse, F.A., Lefkoff, A.B., Boardman, J.W., Heidebrecht, K.B., Shapiro, A.T., Barloon, P.J., Goetz, A.F.H., 1993. Airborne imaging spectrometry the spectral image processing system (SIPS) - interactive visualization and analysis of imaging spectrometer data. *Remote Sens. Environ.* 44, 145–163. [http://dx.doi.org/10.1016/0034-4257\(93\)90013-N](http://dx.doi.org/10.1016/0034-4257(93)90013-N).
97. Kurtz, D.B., Schellberg, J., Braun, M., 2009. Ground and satellite based assessment of rangeland management in sub-tropical Argentina. *Applied Geographie*.
98. Kussul, N., Lemoine, G., Gallego, F.J., Skakun, S.V., Lavreniuk, M., Shelestov, A.Y., 2016. Parcel- Based Crop Classification in Ukraine Using Landsat-8 Data and Sentinel-1A Data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 9 (6): 2500–2508.
99. Kussul, N., Mykola, L., Shelestov, A., Skakun, S., 2018. Crop Inventory at Regional Scale in Ukraine: Developing in Season and End of Season Crop Maps with Multi-Temporal Optical and SAR Satellite Imagery. *European Journal of Remote Sensing* 51 (1): 627–636.
100. Laben C.A., Brower B.V., 1998. Process for Enhancing the Spatial Resolution of Multispectral Imagery using Pan-Sharpener. US Patent 6011875 A.
101. Lambin, E.F.; MeyFroidt, P. Global land use change, economic globalization, and the looming land scarcity. *Proc. Natl. Acad. Sci. USA* 2011, 108, 3465–3472.
102. Lamine, C., Meynard, J.M., Perrot, N., & Bellon, S. (2009). Analyse des formes de transition vers des agricultures plus écologiques: les cas de l'Agriculture Biologique et de la Protection Intégrée. *Innovations agronomiques*, 4, 483-493
103. Le Hegarat-Masclé, S., Quesney, A., Vidal-Madjar, D., Taconet, O., Normand, M., Loumagne, C., 2000. Land Cover Discrimination from Multitemporal ERS Images and Multispectral Landsat Images: A Study Case in an Agricultural Area in France. *International Journal of Remote Sensing* 21 (3): 435–456.
104. Lhissou, R., El Harti, A., Chokmani, K., 2014. Mapping soil salinity in irrigated land using optical remote sensing data. *Eurasia. J. Soil Sci.* 3, 82–88. <http://dx.doi.org/10.18393/ejss.84540>.
105. Li, Q.; Wang, C.; Zhang, B.; Lu, L. Object-Based Crop Classification with Landsat-MODIS Enhanced Time-Series Data. *Remote Sens.* 2015, 7, 16091–16107.
106. Li, X., Lee, W.S., Li, M., Ehsani, R., Mishra, A.R., Yang, C., Mangan, R.L., 2012. Spectral difference analysis and airborne imaging classification for citrus greening infected trees. *Comput. Electron. Agric.* 83, 32–46. <http://dx.doi.org/10.1016/j.compag.2012.01.010>.
107. Liaghat, S. & Balasundram, S. K. (2010). A Review: The Role of Remote Sensing in Precision Agriculture. *American Journal of Agricultural and Biological Sciences*, 5(1), 50-55. <https://doi.org/10.3844/ajabssp.2010.50.55>

108. Löw, F., Michel, U., Dech, S., Conrad, C., 2013. Impact of feature selection on the accuracy and spatial uncertainty of per-field crop classification using support vector machines. *ISPRS J. Photogramm. Remote Sens.* 85, 102–119. <http://dx.doi.org/10.1016/j.isprsjprs.2013.08.007>.
109. Lu D & Weng Q 2005. Urban classification using full spectral information of Landsat ETM+ imagery in Marion County, Indiana. *Photogrammetric Engineering and Remote Sensing* 71(11): 1275-1284.
110. Lupo, F., Linderman, M., Vanacker, V., Bartholome, E., & Lambin, E. (2007). Categorization of land-cover change processes based on phenological indicators extracted from time series of vegetation index data. *International journal of remote sensing*, 28, 2469-2483
111. Lussem, U., Hütt, C., Waldhoff, G., 2016. Combined Analysis of Sentinel-1 and RapidEye Data for Improved Crop Type Classification: An Early Season Approach for Rapeseed and Cereals. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences* 41: 959–963.
112. Mancosu, N., Snyder, R., Kyriakakis, G., Spano, D., 2015. Water scarcity and future challenges for food production. *Water* 7, 975–992. <http://dx.doi.org/10.3390/w7030975>.
113. Mansaray, L. R., Huang, W., Zhang, D., Huang, J., Li, J., 2017. Mapping Rice Fields in Urban Shanghai, Southeast China, Using Sentinel-1A and Landsat 8 Datasets. *Remote Sensing*, 9 (3).
114. Marais Sicre, C., Baup, F., Fieuzal, R., 2014. Determination of the crop row orientations from Formosat-2 multi-temporal and panchromatic images. *ISPRS Journal of Photogrammetry and Remote. Sensing*, 94, 127-142.
115. Marais Sicre, C., Fieuzal, R., Baup, F., 2017. Apport des images satellites multi-spectrales (optique et radar) pour la classification des surfaces en herbe. *Revue Française de Photogrammétrie et de Télédétection* 215, 25-41.
116. Marais Sicre, C., Fieuzal, R., Baup, F., 2020. Contribution of multispectral (optical and radar) satellite images to the classification of agricultural surfaces. *International Journal of Applied Earth Observation and Geoinformation*, 84, 101972.
117. Marais Sicre, C., Inglada, J., Fieuzal, R., Baup, F., Valero, S., Cros, J., Huc, M., Demarez, V., 2016. Early detection of summer crops using high spatial resolution optical images times series. submitted in. *Remote Sensing*.
118. McNairn, H., Brisco, B., 2004. The application of C-band polarimetric SAR for agriculture: a review. *Canadian Journal of Remote Sensing*, 30, No. 3, 525–542.

119. McNairn, H., Champagne, C., Shang, J., 2007. The Value of SAR Multi-Polarization Data in Delivering Annual Crop Inventories. IEEE International Geoscience and Remote Sensing Symposium, Barcelona, Spain, July 23-27.
120. McNairn, H., Champagne, C., Shang, J., Holmstrom, D., Reichert, G., 2009. Integration of Optical and Synthetic Aperture Radar (SAR) Imagery for Delivering Operational Annual Crop Inventories. ISPRS Journal of Photogrammetry and Remote Sensing, 64 (5): 434-449.
121. Moran, M.S., Alonso, L., Moreno, J.F., Pilar Cendrero Mateo, M., Fernando de la Cruz, D., Montoro, A., 2012. A Radarsat-2 quad-polarized time series for monitoring crop and soil conditions in Barrax, (Spain). International Geosciences and Remote Sensing IEEE, Trans 50, 1057–1070.
122. Moreau, S., Toan, T.L., 2003. Biomass quantification of Andean wetland forages using ERS satellite SAR data for optimizing livestock management. Remote Sensing of Environnement, 84, 477-492.
123. Ndikumana, E.; Ho Tong Minh, D.; Baghdadi, N.; Courault, D.; Hossard, L. Deep Recurrent Neural Network for Agricultural Classification using multitemporal SAR Sentinel-1 for Camargue, France. *Remote Sens.* 2018, 10, 1217.
124. Nitze, I., Barrett, B., Cawkwell, F., 2015. Temporal optimisation of image acquisition for land cover classification with Random Forest and MODIS time-series. Int. J. Appl. Earth Obs. Geoinf. 34, 136–146. <http://dx.doi.org/10.1016/j.jag.2014.08.001>.
125. Niu, X., Ban, Y., 2012. Multi-temporal RADARSAT-2 polarimetric SAR data for urban land-cover classification using an object-based support vector machine and a rulebased approach. Int. J. Remote Sens. 34 (1), 1–26. <https://doi.org/10.1080/01431161.2012.700133>.
126. operational monitoring systems and major information needs. Remote Sensing, 5, 4124-4124.
127. ORMVAT (2017). Production végétale. In
128. ORMVAT, 2015. Tadla Agricultural Development Regional Office [on line], Available from: (<http://ormva-tadla.ma/filieres/production-v%C3%A9g%C3%A9tale>).
129. ORMVAT: Tadla Agricultural Development Regional Office [on line]. 2017. Available from: <<http://ormva-tadla.ma/filieres/production-v%C3%A9g%C3%A9tale>>. [Consulted at 14 November 2017].
130. Orynbaikyzy, A.; Gessner, U.; Conrad, CH. Crop type classification using a combination of optical and radar remote sensing data: A review. Int. J. Remote Sens. 2019, 40, doi:10.1080/01431161.2019.1569791.
131. Ouaidrari, H., Vermote, E.F., 1999. Operational atmospheric correction of Landsat TM data. Remote Sens. Environ. 70, 4–15. [http://dx.doi.org/10.1016/S0034-4257\(99\)000541](http://dx.doi.org/10.1016/S0034-4257(99)000541).

132. Ouzemou, J.-E., El Harti, A., El Moujahid, A., Bouch N., El Ouazzani, R., Lhissou, R., Bachaoui, E.M., 2015. Mapping crop based on phenological characteristics using time-series NDVI of operational land imager data in Tadla irrigated perimeter, Morocco. In: Proceedings SPIE 9637, Remote Sensing for Agriculture, Ecosystems, and Hydrology XVII, 96372 G. (<http://dx.doi.org/10.1117/12.2194466>).
133. Ozdarici-Ok, A., Ok, O.A., Schindler, K., 2015. Mapping of agricultural crops from single high-resolution multispectral images—data-driven smoothing vs. parcel-based smoothing. *Remote Sens.* 7, 5611–5638. <http://dx.doi.org/10.3390/rs70505611>.
134. Pal, M., Mather, P.M., 2005. Support vector machines for classification in remote sensing. *Int. J. Remote Sens.* 26, 1007–1011. <http://dx.doi.org/10.1080/01431160512331314083>.
135. Pelletier, C., Valero, S., Inglada, J., Champion, N., Dedieu, G., 2016. Assessing the robustness of Random Forests to map land cover with high resolution satellite image time series over large areas. *Remote Sens. Environ.* 187, 156–168. <http://dx.doi.org/10.1016/j.rse.2016.10.010>.
136. Pinter Jr, P.J., Hatfield, J.L., Schepers, J.S., Barnes, E.M., Moran, M.S., Daughtry, C.S., & Upchurch, D.R. (2003). Remote sensing for crop management. *Photogrammetric Engineering & Remote Sensing*, 69, 647-664
137. Qi, J., Wang, C., Inoue, Y., Zhang, R., Gao, W., 2003. Synergy of optical and radar remote sensing in agricultural applications. *Proceedings of SPIE Vol. 5153*, 153-158.
138. Qi, Z., Yeh, A., Li, X., Lin, Z., 2012. A novel algorithm for land use and land cover classification using RADARSAT-2 polarimetric SAR data. *Remote Sens. Environ.* 188, 21–39. <https://doi.org/10.1016/j.rse.2011.11.001>.
139. Qiao, C., Daneshfar, B., Davidson, A., Jarvis, I., Liu, T., Fiset, T., 2014. Integration of Optical and Polarimetric SAR Imagery for Locally Accurate Crop Classification. *Geoscience and Remote Sensing Symposium (IGARSS)*, 2014 IEEE International, Québec, Canada, July 13-18.
140. Ressources naturelles Canada. <https://www.rncan.gc.ca/cartes-outils-publications/imagerie-satellitaire-photos-aer/tutoriels-sur-la-teledetection/analyse-interpretationimages/traitement/9404>.
141. Rouse, J.W., Haas, R.H., Schell, J.A., Deering, D.W., 1974. Monitoring vegetation systems in the Great Plains with ERTS. In: Stanley, C., Freden, E.P.M., Becker, Margaret A. (Eds.), *Third Earth Resources Technology Satellite-1 Symposium*. NASA, Washington, D.C., USA, pp. 309–317. (<http://adsabs.harvard.edu/abs/1974NASSP.351..309R>).

142. Rowan, L.C., Mars, J.C., 2003. Lithologic mapping in the Mountain Pass, California area using Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER) data. *Remote Sens. Environ.* 84, 350–366. [http://dx.doi.org/10.1016/S0034-4257\(02\)00127-X](http://dx.doi.org/10.1016/S0034-4257(02)00127-X).
143. Roy, D.P., et al., 2014. Landsat-8: science and product vision for terrestrial global changeresearch. *Remote Sens. Environ.* 145, 154–172. <http://dx.doi.org/10.1016/j.rse.2014.02.001>.
144. Rüetschi, M.; Schaepman, M.; Small, D. Using Multitemporal Sentinel-1 C-band Backscatter to Monitor Phenology and Classify Deciduous and Coniferous Forests in Northern Switzerland. *Remote Sens.* 2017, 10, 55.
145. Ryu, C., Suguri, M., Iida, M., Umeda, M. & Lee, C., 2011. Integrating remote sensing and GIS for prediction of rice protein contents. *Precision Agriculture*, 12, 378- 394.
146. Searchinger, T.; Heimlich, R.; Houghton, R.A.; Dong, F.; Elobeid, A.; Fabiosa, J.; Tokgoz, S.; Hayes, D.; Yu, T.H. Use of U.S. croplands for biofuels increases greenhouse gases through emissions from land use change. *Science* 2008, 319, 1238–1240.
147. Seelan, S.K., Laguette, S., Casady, G.M., Seielstad, G.A., 2003. Remote sensing applications for precision agriculture: a learning community approach. *Remote Sensing of Environment*, 88, 157-169.
148. Sellin, V., Magnanon, S., Gourmelon, F., Debaine, F., & Nabucet, J. (2015). Etude expérimentale en cartographie de la végétation par télédétection. *Cybergeo: European Journal of Geography*
149. Shahriar Pervez, M., Budde, M., Rowland, J., 2014. Mapping irrigated areas in Afghanistan over the past decade using MODIS NDVI. *Remote Sens. Environ.* 149, 155–165. <http://dx.doi.org/10.1016/j.rse.2014.04.008>.
150. Shang, J., McNairn, H., Champagne, C., Jiao, X., 2008. Contribution of Multi-Frequency, Multi-Sensor, and Multi-Temporal Radar Data to Operational Annual Crop Mapping. *Geoscience and Remote Sensing Symposium, 2008. IGARSS 2008. IEEE International, Boston, USA, July 8-11.*
151. Shanmugapriya, P., Rathika, S., Ramesh, T., Janaki, P., 2019. Applications of Remote Sensing in Agriculture - A Review. *International Journal of Current Microbiology and Applied Sciences*, 8(1), 2270-2283.
152. Shao, Y., Lunetta, R.S., 2012. Comparison of support vector machine, neural network, and CART algorithms for the land-cover classification using limited training data points. *ISPRS J. Photogramm. Remote Sens.* 70, 78–87. <http://dx.doi.org/10.1016/j.isprsjprs.2012.04.001>.

153. Shrivakshan, G.T., Chandrasekar, C., 2012. A comparison of various edge detection techniques used in image processing. [online]. Available from: Int. J. Comput. Sci. Iss. (IJCSI) 9 (5), 269–276. <http://ul.summon.serialssolutions.com/2.0.0/link/0/>. Trimble, 2016. eCognition ® Developer 9.2.eCognition ® Developer 9.2.
154. Shuai, G., Zhang, J., Basso, B., Pan, Y., Zhu, X., Zhu, S., & Liu, H. (2019). Multi-temporal RADARSAT-2 polarimetric SAR for maize mapping supported by segmentations from high-resolution optical image. *International Journal of Applied Earth Observation and Geoinformation*, 74, 1-15.
155. Silleos, N.G., Alexandridis, T.K., Gitas, I.Z., & Perakis, K. (2006). Vegetation indices: advances made in biomass estimation and vegetation monitoring in the last 30 years. *Geocarto International*, 21, 21-28
156. Sivasankar, T., Kumar, D., Srivastava, H.S., Patel, P., 2018. Advances in Radar Remote Sensing of Agricultural Crops: A Review. *International Journal on Advanced Science Engineering Information Technology*, 8 (4), 1126-1137.
157. Solberg, A.H.S., 2006. Data Fusion for Remote Sensing Applications. In *Signal and Image Processing for Remote Sensing*, edited by C. H. Chen, 249–271. CRC Press, Taylor and Francis Group.
158. Song, C., Woodcock, C.E., Seto, K.C., Lenney, M.P., Macomber, S.A., 2001. Classification and change detection using Landsat TM data: when and how to correct atmospheric effects? *Remote Sens. Environ.* 75, 230–244. [http://dx.doi.org/10.1016/S0034-4257\(00\)00169-3](http://dx.doi.org/10.1016/S0034-4257(00)00169-3).
159. Sonobe, R., Yamaya, Y., Tani, H., Wang, X., Kobayashi, N., Mochizuki, K.-I., 2017. Assessing the Suitability of Data from Sentinel-1A and 2A for Crop Classification. *GIScience and Remote Sensing* 54 (6): 918-938.
160. Sonobe, R.; Yamaya, Y.; Tani, H.; Wang, X.; Kobayashi, N.; Mochizuki, K.I. Assessing the suitability of data from Sentinel-1A and 2A for crop classification. *GISci. Remote Sens.* 2017, 54, 918–938.
161. Soria-Ruiz, J., Fernandez-Ordonez, Y., McNairn, H., 2009. Corn monitoring and crop yield using optical and microwave remote sensing. In: Ho, P.-G.P. (Ed.), *Geoscience and Remote Sensing*. InTech, Open Access Publisher Chapter 19.
162. Steele-Dunne, S.C., McNairn, H., Monsivais-Huertero, A., Judge, J., 2017. Radar Remote Sensing of Agricultural canopies: a review. *ieee journal of selected topics in applied earth observations and Remote Sensing*.

163. Steven, Michael D., Timothy J. Malthus, Frédéric Baret, Hui Xu, Mark J. Chopping. Intercalibration of vegetation indices from different sensor systems. *Remote Sensing of Environment* 88 (2003) 412–422.
164. Stevens, M., Hallsworth, P.B., & Smith, H.G. (2004). The effects of Beet mild yellowing virus and Beet chlorosis virus on the yield of UK field-grown sugar beet in 1997, 1999 and 2000. *Annals of applied biology*, 144, 113-119
165. Tatsumi, K.; Yamashiki, Y.; Canales Torres, M.A.; Taïpe, C.L.R. Crop classification of upland fields using Random forest of time-series Landsat 7 ETM+ data. *Comput. Electron. Agric.* 2015, 115, 171–179.
166. Teillet, P. M., Staenz, K., & Williams, D. J. (1997). Effects of spectral spatial and radiometric characteristics of remote sensing vegetation indices on forested regions. *Remote Sensing of Environment*, 61, 139–149.
167. Teodoro, A.C., Araujo, R., 2016. Comparison of performance of object-based image analysis techniques available in open source software (Spring and Orfeo Toolbox/ Monteverdi) considering very high spatial resolution data. *J. Appl. Remote Sens.* 10, 016011. <http://dx.doi.org/10.1117/1.JRS.10.016011>.
168. Thenkabail, P.S., Schull, M., Turrall, H., 2005. Ganges and Indus River Basin Land Use/Land Cover (LULC) and Irrigated Area Mapping Using Continuous Streams of MODIS Data. *Remote Sensing of Environment*, 95 (3): 317–341.
169. Tingting, L., & Chuang, L. (2010). Study on extraction of crop information using time-series MODIS data in the Chao Phraya Basin of Thailand. *Advances in Space Research*, 45, 775-784
170. Ulaby, F. Radar response to vegetation. *IEEE Trans. Antennas Propag.* 1975, 23, 36–45.
171. United Nations. <https://www.un.org/development/desa/fr/news/population/world-population-prospects-2019.html>
172. Van Tricht, K., Gobin, A., Gilliams, S., & Piccard, I. (2018). Synergistic use of radar Sentinel-1 and optical Sentinel-2 imagery for crop mapping: a case study for Belgium. *Remote Sensing*, 10(10), 1642.
173. Vanonckelen, S., Lhermitte, S., Van Rompaey, A., 2013. The effect of atmospheric and topographic correction methods on land cover classification accuracy. *Int. J. Appl. Earth Obs. Geoinf.* 24, 9–21. <http://dx.doi.org/10.1016/j.jag.2013.02.003>.
174. Veloso, A.; Mermoz, S.; Bouvet, A.; Toan, T.L.; Planells, M.; Dejoux, J.F.; Ceschia, E. Understanding the temporal behavior of crops using Sentinel-1 and Sentinel-2-like data for agricultural applications. *Remote Sens. Environ.* 2017, 199, 415–426.

175. Volpi, M., Tuia, D., Bovolo, F., Kanevski, M., Bruzzone, L., 2013. Supervised change detection in VHR images using contextual information and support vector machines. *Int. J. Appl. Earth Obs. Geoinf.* 20, 77–85. <http://dx.doi.org/10.1016/j.jag.2011.10.013>.
176. Wang, Y., Guo, L., Liang, N., 2009. Improving the classification precision of spectral angle mapper algorithm. In: *Proceedings SPIE 7498, MIPPR 2009: Remote Sensing and GIS Data Processing and Other Applications*. <http://dx.doi.org/10.1117/12.832658>.
177. Waske, B., Fauvel, M., Benediktsson Jon, A., Chanussot, J., 2009. Machine learning techniques in remote sensing data analysis. In: *Camps-Valls, G., Bruzzone, L. (Eds.), Kernel Methods for Remote Sensing Data Analysis*, <http://dx.doi.org/10.1002/9780470748992.ch1>.
178. Watkins, B., & Van Niekerk, A. (2019). A comparison of object-based image analysis approaches for field boundary delineation using multi-temporal Sentinel-2 imagery. *Computers and Electronics in Agriculture*, 158, 294-302. <https://doi.org/10.1016/j.isprsjprs.2014.06.014>.
179. Whelen, T.; Siqueira, P. Time-series classification of Sentinel-1 agricultural data over North Dakota. *Remote Sens. Lett.* 2018, 9, 411–420.
180. Xiang, H., & Tian, L. (2011). Method for automatic georeferencing aerial remote sensing (RS) images from an unmanned aerial vehicle (UAV) platform. *Biosystems Engineering*, 108, 104-113.
181. Xu, L.; Zhang, H.; Wang, C.; Zhang, B.; Liu, M. Crop Classification Based on Temporal Information Using Sentinel-1 SAR Time-Series Data. *Remote Sens.* 2018
182. Yan, L., Roy, D., 2016. Conterminous United States crop field size quantification from multi-temporal Landsat data. *Remote Sens. Environ.* 172, 67–86.
183. Zhang, X., Friedl, M.A., Schaaf, C.B., Strahler, A.H., Hodges, J.C., Gao, F., Reed, B.C., & Huete, A. (2003). Monitoring vegetation phenology using MODIS. *Remote Sensing of Environment*, 84, 471-475.
184. Zhang, X., Li, P., 2014. Lithological mapping from hyperspectral data by improved use of spectral angle mapper. *Int. J. Appl. Earth Obs. Geoinf.* 31, 95–109. <http://dx.doi.org/10.1016/j.jag.2014.03.007>.
185. Zhang, Z., He, G., Wang, X., 2010. A practical DOS model-based atmospheric correction algorithm. *Int. J. Remote Sens.* 31, 2837–2852. <http://dx.doi.org/10.1080/01431160903124682>.
186. Zheng, B., Myint, S.W., Thenkabail, P.S., Aggarwal, R.M., 2015. A support vector machine to identify irrigated crop types using time-series Landsat NDVI data. *Int. J. Appl. Earth Obs. Geoinf.* 34, 103–112. <http://dx.doi.org/10.1016/j.jag.2014.07.002>.

187. Zhong, L., Gong, P., Biging, G.S., 2014. Efficient corn and soybean mapping with temporal extendability: a multi-year experiment using Landsat imagery. *Remote Sens. Environ.* 140, 1–13. <http://dx.doi.org/10.1016/j.rse.2013.08.023>.
188. Zhou, T., Pan, J., Zhang, P., Wei, S., Han, T., 2017. Mapping Winter Wheat with Multi-Temporal SAR and Optical Images in an Urban Agricultural Region. *Sensors (Switzerland)* 17 (6).