



**HAL**  
open science

# Apport des données satellitaires Sentinel-1 et Sentinel-2 pour la détection des surfaces irriguées et l'estimation des besoins et des consommations en eau des cultures d'été dans les zones tempérées

Yann Pageot

## ► To cite this version:

Yann Pageot. Apport des données satellitaires Sentinel-1 et Sentinel-2 pour la détection des surfaces irriguées et l'estimation des besoins et des consommations en eau des cultures d'été dans les zones tempérées. Hydrologie. Université Paul Sabatier - Toulouse III, 2021. Français. NNT : 2021TOU30281 . tel-04836728

**HAL Id: tel-04836728**

**<https://theses.hal.science/tel-04836728v1>**

Submitted on 13 Dec 2024

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

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



# THÈSE

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

Délivré par l'Université Toulouse 3 - Paul Sabatier

---

Présentée et soutenue par

**Yann PAGEOT**

Le 13 décembre 2021

**Apport des données satellitaires Sentinel-1 et Sentinel-2 pour la  
détection des surfaces irriguées et l'estimation des besoins et  
des consommations en eau des cultures d'été dans les zones  
tempérées.**

---

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

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

Unité de recherche :

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

Thèse dirigée par

**Valérie DEMAREZ**

Jury

**M. Gilles BELAUD**, Rapporteur

**Mme Agnès BEGUE**, Rapporteur

**Mme Valérie DEMAREZ**, Directrice de thèse

**M. Mehrez ZRIBI**, Président



## Résumé

L'eau est une ressource naturelle, qui depuis des millions d'années participe au cycle de la vie. Mais depuis peu, le changement climatique et les activités humaines remettent en cause l'équilibre du cycle de l'eau, alors même que les besoins en eau ne cessent d'augmenter. En effet, les besoins en eau de l'agriculture représentent 70% de l'utilisation de l'eau douce et ces besoins vont croître avec une population mondiale grandissante. Pour préserver cette ressource, il est nécessaire d'améliorer la connaissance sur les surfaces irriguées ainsi que les besoins et consommations en eau des cultures sur de grandes surfaces, mais elle n'est pas simple à appréhender à cause de la forte variabilité spatiale des sols, du climat et des pratiques agricoles. La télédétection a un rôle fondamental à jouer et plus particulièrement les données Sentinel-1 et Sentinel-2.

Dans ce contexte, ces travaux de thèse ont vocation à fournir des outils de diagnostics pour assurer une gestion optimale de la ressource en eau à l'échelle des bassins versants. Pour cela une approche cartographie des surfaces irriguées en zones tempérées à partir d'images satellites Sentinel-1 & 2 a été développée. Cette approche basée sur le couplage de données satellitaires (optique et radar) et un algorithme de classification supervisée (Random Forest) a permis de cartographier à l'échelle parcellaire les pratiques d'irrigation (présence / absence) des cultures d'été sur deux territoires du bassin versant de l'Adour - Garonne (Adour amont et Tarn aval). La méthodologie a pu être validée grâce aux données collectées par les partenaires, soit la CACG, et les chambres d'Agriculture Hautes-Pyrénéens et du Tarn. En parallèle, la méthode a été développée dans un but opérationnel, en prenant en compte les contraintes techniques que les gestionnaires de la ressource en eau peuvent rencontrer face à la quantité importante de données que représentent les images satellitaires. Pour cela, l'approche développée se base sur les cumuls mensuels d'indices de végétation et des polarisations radars. L'utilisation de ces cumuls permet de réduire l'utilisation de la ressource informatique, pour générer une carte, tout en conservant les performances de l'approche. Pour la modélisation des besoins et des consommations en eau du maïs irrigué, le modèle SAMIR a été utilisé. Ce modèle utilise des images satellites d'indice de végétation (NDVI et FCover) pour simuler le bilan hydrique de culture. Il a été appliqué à différentes échelles spatiales et sur différents jeux de données de validation. Le modèle a été calibré et validé sur la parcelle expérimentale de Lamothe pour laquelle nous disposons, depuis 2008, de mesures d'évapotranspiration réelle (ETR) acquises par la méthode d'Eddy-Covariance. Cette phase de calibration/validation a permis d'apporter des modifications sur l'estimation de l'évaporation du sol et sur le suivi du développement de la végétation. Les estimations des besoins en eau ont ensuite été validés sur un ensemble de parcelles ainsi que sur quatre périmètres irrigués (ASA) et deux périmètres élémentaires (BV Adour amont et Neste). Les résultats montrent que le modèle est capable de reproduire de façon satisfaisante les besoins en eau d'irrigation des parcelles des partenaires lorsque la réserve utile du sol (RU) est estimée à partir de données GlobalSoilMap et de la profondeur d'enracinement maximale estimée par le Référentiel Régional Pédologique. A l'échelle des ASA et des BV, le modèle a tendance à sous-estimer les volumes saisonniers. Les résultats illustrent la nécessité d'une bonne estimation de la RU, à une échelle compatible avec une approche de modélisation du bilan hydrique, c'est à dire à la parcelle pour pouvoir estimer correctement les irrigations saisonnières et les volumes. Ces conclusions sont toutefois dépendantes du jeu de données disponible, du modèle et de la méthode de calibration choisie et ce travail nécessiterait un jeu de données plus conséquent et probablement une analyse plus poussée.

## Abstract

Water is a natural resource that has been part of the life cycle for millions of years. But recently, climate change and human activities have challenged the balance of the water cycle, even as the need for water continues to grow. Indeed, agriculture accounts for 70% of freshwater use and this demand will grow with a growing world population. To preserve this resource, it is necessary to improve knowledge of irrigated areas and the water needs and consumption of crops over large areas, but this is not easy to understand because of the high spatial variability of soils, climate and cultivation practices. Remote sensing has a fundamental role to play and more particularly Sentinel-1 and Sentinel-2 data.

In this context, the aim of this thesis is to provide diagnostic tools to ensure optimal management of water resources at the watershed scale. To this end, a mapping approach of irrigated areas in temperate zones from Sentinel-1 & 2 satellite images was developed. This approach, based on the coupling of satellite data (optical and radar) and a supervised classification algorithm (Random Forest), made it possible to map the irrigation practices of summer crops on a parcel scale in two territories of the Adour-Garonne catchment area (Adour amont and Tarn aval). The methodology was validated thanks to the data collected by the partners, i.e. the CACG, and the Hautes-Pyrénées and Tarn chambers of agriculture. In parallel, the method was developed with an operational aim, taking into account the technical constraints that water resource managers may encounter when faced with the large amount of data represented by satellite images. To this end, the approach developed is based on the monthly aggregations of vegetation indices and radar polarisations. The use of these accumulations reduces the use of computer resources to generate a map, while maintaining the performance of the approach. The SAMIR model was used to model the water requirements and consumption of irrigated maize. This model uses satellite images of vegetation index (NDVI and FCover) to simulate the crop water balance. It was applied at different spatial scales and on different validation data sets. The model was calibrated and validated on the Lamothe experimental plot for which we have had real evapotranspiration (ETR) data since 2008, acquired by the Eddy-Covariance method. This calibration / validation phase allowed us to make modifications to the estimation of soil evaporation and to the monitoring of vegetation development. The estimates of water requirements were then validated on a set of plots as well as on 4 irrigated areas (ASA) and two elementary areas (BV Adour amont and Neste). The results show that the model is capable of satisfactorily reproducing the irrigation water needs of the partners plots when the available water content (AWC) is estimated from GlobalSoilMap data and the maximum rooting depth estimated by the Référentiel Régionale Pédologique. At the ASA and BV scale, the model tends to underestimate seasonal volumes. The results illustrate the need for a good estimation of the AWC, at a scale compatible with a water balance modelling approach at the plot level, in order to be able to correctly estimate seasonal irrigations and volumes. However, these conclusions are dependent on the dataset available and the model and calibration method chosen, and this work requires a larger dataset and further analysis

## Remerciements

*Je garderai un très bon souvenir de cette période de ma vie qui aura été particulièrement enrichissante tant sur le plan professionnel qu'humain. La thèse et les nombreux échanges m'auront permis de découvrir un domaine d'étude passionnant et stimulant que j'espère continuer d'explorer à l'avenir.*

*Je ne peux débiter ce manuscrit qu'en exprimant ma gratitude envers ma directrice de thèse Valérie Demarez, pour m'avoir offert la possibilité de réaliser ce projet. Dès mon stage de fin d'étude, tu m'as vite fait confiance et parce que tu as cru en moi, tu as fait en sorte que je puisse continuer cette aventure. Merci pour ta grande disponibilité, ton écoute et ton efficacité qui m'ont permis de garder le cap et de ne jamais me décourager ! Merci pour toutes ces discussions autour des sujets d'actualités, qui ces trois dernières années ont pas manqué de rebondissement. Tes grandes qualités humaines et scientifiques m'auront permis de mener à bien ce projet sereinement et pour tout cela, je te suis grandement reconnaissant. Je tiens également à remercier les membres du jury qui ont accepté de lire et de juger mon travail : le président du jury et directeur du CESBio, Mehrez Zribi, les rapporteurs Agnès Bégué et Gilles Belaud. Je remercie également les membres du jury pour avoir accepté de participer à mon oral et d'échanger sur mes travaux. Je voudrais aussi montrer ma reconnaissance aux institutions et aux personnes qui ont, par leur financement ou leur temps, rendu ce travail possible. Merci à l'AEAG, à la CAGC et au CNES d'avoir subventionné ces travaux de thèse.*

*Cette belle aventure n'aurait pu aboutir sans leur investissement et leur soutien. Merci à toutes les personnes avec qui j'ai eu le plaisir et la chance de travailler durant ces 3 années au CESBio. Parmi les collègues du CESBio, je tenais tout d'abord à remercier Tiphaine Tallec. Tu es celle qui, avec Valérie Demarez, m'a donné ma chance au CESBio, dans le cadre du projet de mon stage de fin d'étude. Ça a été le tremplin qui m'a donné l'envie de continuer cette aventure. Je me souviendrais toujours du moment où j'ai appris que ma candidature de thèse était retenu, devant un planimètre à mesure des feuilles de blé. Et oui, c'est aussi cela la science, pas que des lignes de codes.*

*Merci à l'équipe occupation du sol qui sans vous, ce travail n'aurait pas abouti. Merci à Jordi Inglada pour tes précieux conseils sur les méthodes de classification. Merci à Arthur Vincent et Benjamin Tardy pour votre aide sur l'utilisation de la chaîne Iota et merci Vincent Thierion pour tes précieux outils de traitement de données vectorielles. Merci également à l'équipe ModSpa et en particulier à Mireille Huc et Vincent Rivalland pour leur immense travail sur la plate-forme. Je remercie également les autres personnes qui ont travaillé sur cette plate-forme (Luis Olivera, Chloé Ollivier, Pierre Laluet et Vincent Simonneaux) pour la rendre plus modulaire et pour avoir participé aux nombreuses discussions sur le modèle et ces possibles améliorations.*

*Et merci bien sûr à toutes les personnes qui collectent et traitent les nombreuses données nécessaires à mon travail, sans qui rien n'aurait été possible : Aurore Brut, Bartosz Zawilski, Nicole Claverie, Franck Granouillac et bien d'autres. Merci aussi aux chambres d'agriculture et aux agriculteurs qui ont accepté de fournir leurs données.*

*Merci évidemment à tous les personnes du laboratoire qui ont rendu ces années plus que plaisantes avec qui ça a été un plaisir de manger, échanger, rigoler. Je ne pourrais pas commencer cette liste sans citer le bureau 200. Je tenais donc à remercier Edna Melo, Rémi Madelon, Simon Nativel, Micaël Lassalle, Ainhoa Herblot. Avec une mention spéciale pour Edna Melo et Ainhoa Herblot, qui m'ont permis de travailler sur autre chose que ma thèse pendant ces trois années. Ce bureau restera un des épisodes le plus marquant et agréable de cette thèse et je vous remercie grandement pour ça.*

*Et comme on dit, « le meilleur pour la fin », je tiens à remercier Ainhoa Herblot de m'avoir supporté pendant ces années lors des moments de frustrations, d'énervement, de déprime et de joie.*

<b>1</b>	<b>Introduction</b>	<b>7</b>
1.1	L'eau : ressource renouvelable, mais vulnérable . . . . .	7
1.1.1	Le changement climatique : Impact sur le cycle de l'eau . . . . .	7
1.1.2	Eau et l'agriculture . . . . .	8
1.2	État de l'art : Utilisation des données satellitaire pour la détection, l'estimation des besoins et des consommations en eau. . . . .	11
1.2.1	Cartographie et modélisation : Apport de la télédétection . . . . .	11
1.2.1.1	Cartographie-Classification . . . . .	11
1.2.1.2	Modélisation du bilan hydrique . . . . .	12
1.3	Démarche scientifique et Plan de thèse . . . . .	13
<b>2</b>	<b>Présentation des données</b>	<b>16</b>
2.1	Zone d'étude : Bassin versant et leurs enjeux . . . . .	16
2.2	Données satellitaires . . . . .	18
2.2.1	Constellation Sentinel . . . . .	18
2.2.1.1	Sentinel-1 . . . . .	18
2.2.1.2	Sentinel-2 . . . . .	19
2.2.1.3	Pré-traitement des données . . . . .	20
2.3	Données de forçage . . . . .	21
2.3.1	Registre Parcellaire Graphique . . . . .	21
2.3.2	Météo - SAFRAN . . . . .	22
2.3.3	Données sol . . . . .	22
2.3.3.1	Global Soil Maps : GSM . . . . .	22
2.3.3.2	Carte pédologique : Référentiel Régional Pédologique (RRP) . . . . .	22
2.3.3.3	Référentiel Régional Pédologique, avec spatialisation des UTS (RRP <sub>UTS</sub> ) . . . . .	22
2.3.3.4	Méthode d'extraction de la donnée RRP <sub>UTS</sub> . . . . .	24
2.4	Données des partenaires . . . . .	25
2.4.1	Données cartographiques . . . . .	25
2.4.1.1	Tournées terrain . . . . .	25
2.4.2	Données pour la modélisation . . . . .	26
2.4.2.1	Parcelle de référence . . . . .	26
2.4.2.2	Associations Syndicales Autorisées . . . . .	27
2.5	Données de la parcelle expérimentale . . . . .	28
2.5.1	Données Flux et Pédologique . . . . .	28
2.5.1.1	Flux . . . . .	28
2.5.1.2	Pédologique . . . . .	28
<b>3</b>	<b>Détection des surfaces irriguées</b>	<b>30</b>
3.1	Introduction . . . . .	30
3.1.1	Modèle de cartographie/classification . . . . .	31
3.1.1.1	Random Forest (RF) . . . . .	32
3.1.1.2	Procédure de classification automatisée . . . . .	32
3.1.1.3	Validation de la classification . . . . .	33
3.1.1.4	Carte de confiance . . . . .	34
3.2	Méthodologie de classification . . . . .	35

3.2.0.1	Pré-traitement des images	35
3.2.0.2	Dynamique spectrales des cultures étudiées	36
3.2.0.3	Calcul des cumuls	38
3.2.1	Classification	39
3.2.2	Post-Traitement et Validation	39
3.3	Publication – Résultats présentés	40
3.3.1	Scénarios	40
3.3.2	Performance globale pour chaque scénario	40
3.3.3	Fscore	42
3.3.4	Analyse de la confusion entre les classes	43
3.3.5	Carte de confiance	44
3.3.6	Statistiques régionales	46
3.4	Résultat et analyse complémentaire	46
3.4.1	Apport des cumuls d'indices	46
3.4.2	Cours de saison : Cas du bassin versant d'Adour Amont	49
3.4.3	Bassin Versant - Tarn Aval	51
3.4.3.1	Performance globale	51
3.4.3.2	Fscore	52
3.4.3.3	Confusion entre les classes	53
3.4.3.4	Statistiques régionales	54
3.5	Discussion	55
3.5.1	Optique et/ou Radar	55
3.5.2	Impact des indices cumulés mensuels	56
3.5.3	Contribution des données de précipitations	56
3.5.4	Cours de saison	56
3.6	Conclusion	57
<b>4</b>	<b>Estimation des besoins et consommation en eau du maïs irrigué</b>	<b>58</b>
4.1	Introduction	58
4.1.1	Calcul du bilan hydrique	60
4.1.2	La méthode FAO	60
4.2	Modèle SAMIR	62
4.2.1	Présentation du modèle	62
4.2.2	Approche méthodologique	66
4.2.2.1	Évaporation du sol nu	67
4.2.2.2	Initialisation de la RU : Quelle méthode ?	68
4.2.2.3	Apport du FCover satellitaire	68
4.2.2.4	Impact de de la profondeur d'enracinement maximale sur l'ETR et les volumes irrigués	68
4.2.2.5	Évaluation des pratiques d'irrigations : dates et doses d'irrigation	68
4.2.2.6	Spatialisation du modèle à l'échelle du bassin versant	68
4.2.2.7	Initialisation des paramètres d'entrée du modèle	68
4.3	Résultats et Discussion	70
4.3.1	Évaluation de l'évapotranspiration	70
4.3.1.1	Formalisme de Merlin et al vs FAO-56	70
4.3.1.2	Sensibilité du modèle aux valeurs d'initialisation de la Réserve Utile	72
4.3.1.3	Impact du FCover satellite sur l'estimation de l'ETR	75
4.3.1.4	Variation de l'enracinement maximal, impact sur l'irrigation	76
4.3.1.5	Évaluation des pratiques d'irrigations : doses d'irrigation	77
4.3.1.6	Conclusion de la calibration du modèle sur la parcelle expérimentale	80
4.3.2	Spatialisation du modèle	80
4.3.2.1	Parcelles des partenaires	80

4.3.2.2	Périmètres irrigués . . . . .	84
4.3.3	Spatialisation à l'échelle du bassin versant . . . . .	85
4.3.3.1	Cas du bassin versant d'Adour Amont . . . . .	85
4.3.3.2	Cas du bassin versant de Neste . . . . .	87
4.4	Conclusion . . . . .	90
<b>5</b>	<b>Conclusion &amp; Perspectives</b>	<b>91</b>
5.1	Synthèse des résultats . . . . .	91
5.2	Perspectives . . . . .	93
	<b>Bibliographie</b>	<b>96</b>
	<b>Liste des illustrations</b>	<b>109</b>
	<b>Annexes</b>	<b>115</b>



## 1.1 L'eau : ressource renouvelable, mais vulnérable

L'accès à la ressource en eau est une préoccupation majeure à l'échelle internationale avec 80% de la population mondiale confrontée à l'insécurité hydrique. Cette insécurité va s'aggraver avec le changement climatique [1] auquel se rajoute l'explosion démographique observée dans certaines régions du monde. En effet, Gerten et al [2], ont démontré qu'une augmentation de la température de 2°C, exposerait jusqu'à 500 millions de personnes à une nouvelle pénurie d'eau ou à une aggravation de la situation. Les populations vivantes dans les bassins fluviaux, en particulier au Moyen-Orient et au Proche-Orient, devraient être nouvellement exposées à une pénurie d'eau chronique, même si le réchauffement planétaire est limité à moins de 2°C. Selon le scénario démographique, SSP-2 (Shared Socio-Economic Pathway), environ 8 % de la population mondiale devrait subir une réduction sévère des ressources en eau avec une augmentation des températures de 1.7°C en 2021-2040, et augmenter à 14 % avec un réchauffement à + 2.7°C en 2040-2070 [3]. Cette situation contraint les pays à rechercher des solutions pour faire face aux risques présents et à venir.

### 1.1.1 Le changement climatique : Impact sur le cycle de l'eau

En novembre 2015, la COP 21 qui s'est tenue à Paris, a abouti à l'adoption du premier texte international de lutte contre le changement climatique, qui malgré la réticence de certains états, marque une avancée notable dans la prise de conscience des politiques face aux enjeux. Ce texte a ensuite été discuté et retravaillé lors des différentes conférences sur le climat (COP). La dernière COP s'est déroulée à Madrid en 2019 et aucune avancée sur les mesures à mettre en place pour limiter le réchauffement climatique n'a été voté par les états signataires des accords de Paris.

L'impact du changement climatique sur la ressource en eau a été évalué dans le dernier rapport du GIEC (2021) [4]. Les différents scénarios simulés par les modèles climatiques convergent et la plupart d'entre eux, prévoient que le réchauffement planétaire excédera 1,5°C au cours des prochaines décennies, entraînant la multiplication et l'intensification des vagues de chaleur, mais aussi l'augmentation des précipitations aux hautes latitudes, entraînant des inondations, alors qu'une baisse est projetée dans une grande partie des régions subtropicales [4].

Les impacts varient selon les régions du monde [1, 4]. Ils peuvent se traduire par des épisodes de chaleur extrême tel que celui de Lytton (Canada) en juillet 2021 où la température a atteint des niveaux extrêmes jamais enregistrés depuis 1937, avec 49.5°C. Un épisode équivalent, a été observé en Arctique, avec des températures dépassant les 30°C, soit 12°C au-dessus des normales saisonnières. Ces vagues de chaleur vont modifier le début et la fin des saisons de croissance des cultures, contribuer à des réductions de rendement, réduire la disponibilité en eau douce, et soumettre la biodiversité à un stress supplémentaire [4]. En parallèle de ces vagues de chaleur intenses, des épisodes de froid intense ont également été observés, comme dans le Sud des États-Unis, au Texas en 2021, où des températures extrêmes (25 °C en-dessous la normale), ont été enregistrées, à Dallas, la température de -19°C fut la plus froide depuis 1930. En plus des épisodes climatiques extrêmes, une modification du régime des pluies avec des risques accrus de sécheresses est observable dans certaines régions du monde. Ces événements météorologiques auront des effets dévastateurs pour les écosystèmes, l'agriculture et la santé humaine.

En France, le changement climatique devrait impacter différemment les régions. Sur le pourtour méditerranéen, un phénomène d'aridification sera observable, quant au Sud-Ouest de la France, il sera soumis au phénomène de « méditerranisation » [5]. Ces modifications climatiques impacteront l'ensemble des activités humaines dont notamment les activités agricoles fortement présentes dans ces régions. Selon les rapports Climator

et Climsec publiés respectivement par l'INRAE et Météo-France, une augmentation de l'évapotranspiration de l'ordre de 13% à 23% conduira « à une baisse sensible de l'humidité des sols » [6, 7]. Même si la France possède une grande capacité de stockage en eau douce grâce à son réseau hydrographique dense (270 000 km de linéaires) et à ces nombreux aquifères et retenues artificielles, la répartition spatiale et temporelle des pluies et du niveau des aquifères est inégale à l'échelle du territoire. Ces inégalités vont être accentuées par le réchauffement climatique. En effet, certains territoires ne possèdent pas de réservoirs naturels (aquifères) ou artificiels permettant d'assurer une redistribution de la ressource en eau pendant les périodes estivales [8]. C'est le cas de la Beauce et du Poitou Charente, qui ne disposent pas de nappes souterraines suffisantes pour subvenir aux différents usages de l'eau, notamment pour l'agriculture, nécessitant le recours à l'irrigation. Les Coteaux de Gascogne possèdent des aquifères, mais en nombre insuffisant nécessitant, en période estivale, le prélèvement des eaux de surfaces par l'intermédiaire de canaux dédiés à l'irrigation. Selon les scénarios du PNACC de 2018, les épisodes pluvieux seront moins nombreux lors des périodes estivales, ce qui entraînera une pression supplémentaire sur la ressource en eau, déjà importante dans ces régions. Depuis dix ans, chaque année, ces régions sont soumises à des restrictions d'eau pendant l'été. En 2019, les mesures de restriction des usages de l'eau s'appliquaient à 67 % du territoire métropolitain, avec 28 % concerné par des mesures de crise et 21 % par des mesures d'alerte renforcée (Figure 1.1).

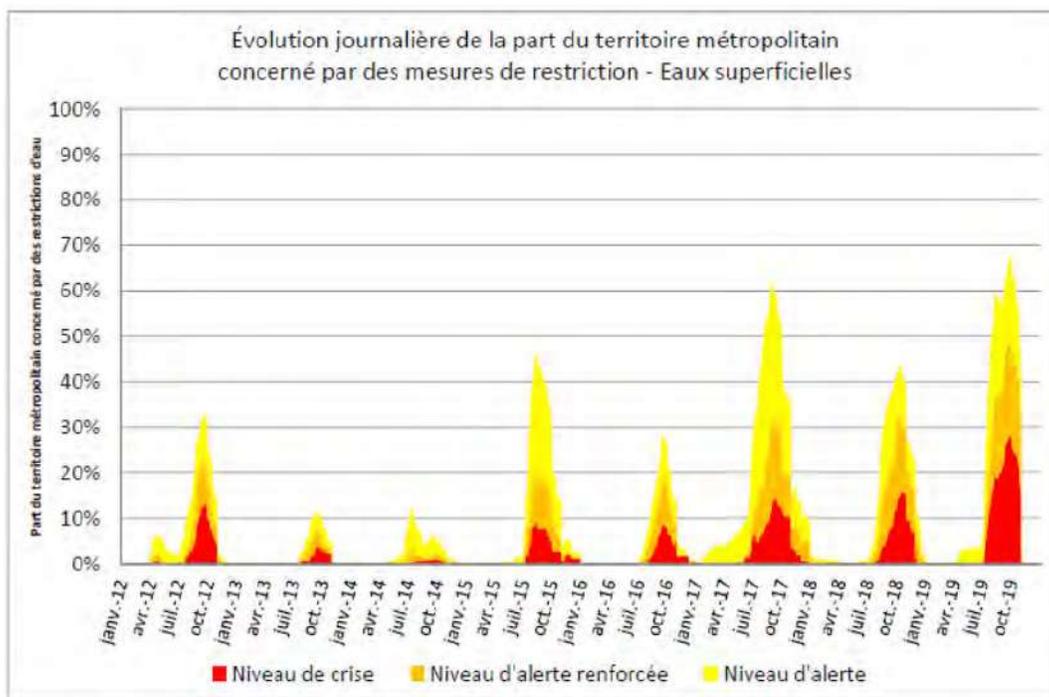


Figure 1.1 – Part du territoire français impacté par les mesures de restrictions des usages en eau sur la période de 2012 à 2019. Les zones en rouges illustrent la part du territoire confrontée à des mesures de crise, en orange à des mesures d'alerte renforcée et en jaune à des mesures d'alerte. source : CGEDD, 2019

### 1.1.2 Eau et l'agriculture

L'agriculture, est le secteur le plus consommateur en eau, il utilise 70 % de la ressource en eau douce disponible à l'échelle mondiale [9], et même plus de 80-90% dans les régions semi-arides et arides [10, 11]. Parmi les principaux usages de l'eau en agriculture, l'irrigation est la plus consommatrice avec 60% de l'eau prélevée. Cette consommation varie d'une année sur l'autre, en fonction des conditions météorologiques et du type de culture à irriguer.

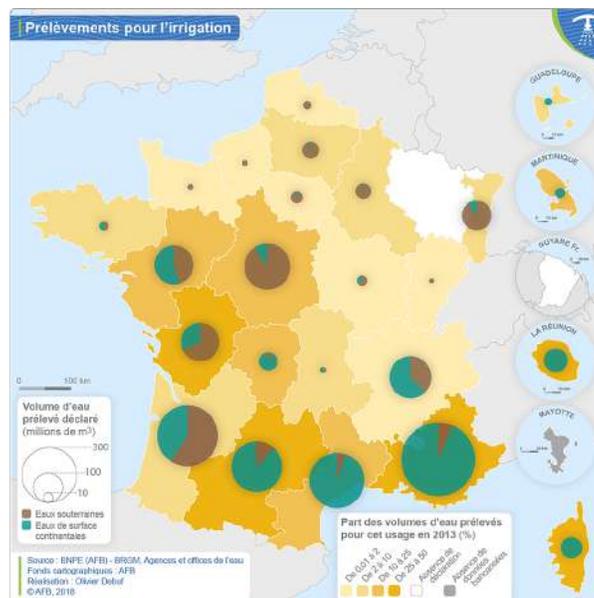
Aux cours des dernières décennies, la proportion des surfaces irriguées dans le monde a connu une augmenta-

tion importante du fait des nombreuses révolutions agricoles et de la demande alimentaire qui ne cesse de croître (184 millions d'ha en 1970, 406 millions d'ha en 2012). Actuellement 42 % des terres cultivées sont équipées d'un système d'irrigation selon la FAO [9].

La répartition à l'échelle globale des terres agricoles irriguées est essentiellement liée aux climats et au type de sol. Dans les régions arides et semi-arides les agriculteurs ont recours à l'irrigation afin d'obtenir une production permettant d'assurer l'auto-suffisance alimentaire. En Asie du Sud, les surfaces équipées d'un système irrigation ont quasiment doublé en 40 ans (111 millions d'ha en 1973, 194 millions d'ha en 2013), ce qui en fait le territoire, le plus irrigué au monde (environ 78 %), malgré que celui-ci ne possède peu de ressource en eau douce (seulement 6%) [9].

Dans les zones tempérées et plus particulièrement en Europe, les surfaces irriguées ont augmentées de 13.4 % passant de 8,6 millions d'ha en 1970 à 21,4 millions d'ha en 2013 [5, 12]. Cette augmentation des surfaces irriguées est encouragée par les organisations internationales telles que la FAO, qui considère que l'irrigation est l'une des stratégies d'adaptation à privilégier pour assurer les besoins alimentaires. En effet, la FAO estime que 80% des besoins alimentaires attendus en 2025, seront couverts par l'agriculture irriguée [13].

En France, l'irrigation s'est rapidement développée depuis les années 70 et est aujourd'hui considérée comme un soutien indispensable au secteur agricole [12, 14, 15]. Néanmoins depuis 2000, les surfaces irriguées en France (1,4 millions d'hectares) semblent s'être stabilisées du fait de la baisse de rentabilité des cultures irriguées, causé par un découplage des aides aux productions issues de la Politique Agricole Commune, en particulier la disparition de l'aide spécifique aux cultures irriguées [5, 16]. La stabilisation des surfaces irriguées, n'est pas généralisable à l'échelle du territoire français avec une forte progression des surfaces irriguées sur l'Ouest de la France (Aquitaine, Midi-Pyrénées, Poitou-Charentes, Pays de la Loire et Centre) qui regroupe actuellement plus de la moitié de la sole irriguée. Suite aux derniers chiffres du recensement agricole, datant de 2010, l'irrigation est présente sur l'ensemble du territoire mais est surtout concentrée dans quatre régions, le Centre Val de Loire, la Provence-Alpes-Côte d'Azur, la Nouvelle Aquitaine et l'Occitanie, qui totalisent près de la moitié de la surface irriguée (48,7%) et un peu plus d'un tiers des irrigants (35,9 %) (RA 2010) comme illustré sur la figure 1.2. En moyenne à l'échelle de la France, sur les années 2008-2012, les prélèvements pour l'irrigation représentent un peu plus de 10 % des prélèvements totaux en eau douce. Malgré une stabilisation des surfaces irriguées à l'échelle du territoire nationale, nous constatons une nette augmentation des volumes prélevés pour l'irrigation depuis quelques années. En 2016, selon l'office international de l'eau 3.2 milliards de m<sup>3</sup> d'eau prélevée était destiné à l'irrigation contre 2.8 millions de m<sup>3</sup> en 2013.



**Bassin Versant : Adour-Garonne :** L'agriculture est fortement développée sur le bassin Adour-Garonne, où elle représente 43% des volumes annuels prélevés (soit environ 900 millions de  $m^3$ ) et 69 % des prélèvements en période d'étiage. Si l'on raisonne en volumes consommés (= quantité d'eau non restituée au cycle de l'eau continentale), l'agriculture représente 88 % de la consommation d'eau [17]. Sur ce bassin, les surfaces irriguées sont estimées à environ 500 000 ha en 2020 [18], dont plus de la moitié est consacrée au maïs. Suivant les scénarios climatiques et sans un changement de date de semis, le besoin en irrigation du maïs augmenterait entre 24 mm et 83 mm [17].

Les importants volumes accordés à l'irrigation, entraînent donc une forte pression sur la ressource hydrique qui sera renforcée avec le changement climatique. Les différents scénarios prévoient sur ce bassin, une diminution annuelle moyenne des débits compris entre 20 et 40%, pouvant atteindre 50 % en période estivale, d'ici 2050 [17, 19–21]. La dynamique des écoulements pourrait être fortement modifiée en période d'étiage dans de nombreux sous-bassins versants où l'irrigation représente plus de 65% des volumes d'eau consommés par an (400 millions de  $m^3$  sur le bassin Adour-Garonne). Sans un changement radical et rapide des usages, les étiages seront plus précoces, plus sévères et plus longs, ce qui aura un impact catastrophique sur le fonctionnement des écosystèmes et les activités humaines et entraîneront des conflits d'accès à la ressource entre les acteurs du territoire.

De plus, si aucune décision n'est prise pour gérer collectivement les ressources en eau, une grande partie des masses d'eau risque de ne pas atteindre les objectifs environnementaux spécifiés par la Directive Cadre sur l'Eau (DCE, 2000) dans les prochaines décennies. Le déficit estimé, à ce jour, dans le bassin Adour-Garonne, à 250 millions de  $m^3$  [20]. L'impact du changement climatique devrait porter ce déficit à environ 1,2 milliard de  $m^3$  en 2050 si l'on ne modifie pas les usages actuels.

La DCE a permis de définir un cadre pour la gestion et la protection des eaux en Europe. La loi LEMA (Loi sur l'Eau et les Milieux Aquatiques) de 2006 permet de renforcer la protection des milieux aquatiques et de la ressource en eau, afin de réduire les divers conflits liés à l'utilisation de l'eau, fortement présents lors des épisodes de sécheresse. En 2009, la loi Grenelle 1, a permis de définir un cadre d'action et des moyens politiques pour lutter contre le changement climatique. Parmi les objectifs fixés par cette loi, la création des Plans Nationaux d'Adaptation au Changement Climatique (PNACC) a été prévue. Le premier plan national a permis de définir 211 recommandations. La principale recommandation concernant la pratique de l'irrigation est : « d'améliorer l'efficacité de l'eau dans les systèmes d'irrigation, dans le but de réduire de 20 % la consommation en eau » [22]. Suite à ce premier PNACC, un deuxième plan a été élaboré en 2016 afin de reconduire les objectifs non atteints et d'en renforcer d'autres tel que « le suivi des ressources en eau et des milieux aquatiques, ainsi que des prélèvements et consommations d'eau » [22]. Avec le deuxième volet du PNACC, les agences de l'eau ont établies un plan d'action visant à anticiper les besoins de divers secteurs d'activités à partir de scénario de modélisation climatique. En parallèle des plans d'action, le gouvernement français a mis en place les projets de territoire pour la gestion de l'eau (PTGE). Ces projets devraient permettre par le biais de la concertation entre les acteurs du territoire de rétablir l'équilibre entre besoins et ressources disponibles en respectant la bonne fonctionnalité des écosystèmes aquatiques, en proposant des leviers d'adaptation et d'atténuation face au changement climatique.

La loi LEMA a également introduit la notion de "volumes prélevables" maximum dont le respect doit permettre une meilleure gestion de la ressource en eau. Cette tâche a été confiée aux organismes uniques pour la gestion collective des prélèvements d'irrigation (OUGC) qui ont pour objectif de déterminer le volume prélevable par périmètres élémentaires (sous bassins), par usage et par période. L'objectif est de respecter les débits d'étiage (DOE) fixés par la loi, c'est-à-dire le volume global que le milieu est capable de fournir tout en garantissant le bon fonctionnement des milieux aquatiques et les besoins liés aux différents usages.

Pour répondre aux enjeux fixés par les pouvoirs publics, une gestion sobre et équitable de la ressource en eau est devenue nécessaire. Mais la plupart des méthodes actuelles utilisées pour connaître les besoins et les consommations en eau des cultures, sont principalement basées sur des connaissances souvent disparates, pas toujours fiables et souvent anciennes. Partant de ce constat, il apparaît nécessaire de proposer des outils et des méthodes permettant d'améliorer la connaissance des surfaces irriguées ainsi que des besoins et consommations en eau des cultures à l'échelle des territoires, ici les sous bassins versants. Pour cela, il faut être capable d'appréhender la variabilité spatiale des sols, du climat et des pratiques culturelles pouvant exister au sein des divers territoires. Cette connaissance peut être atteinte grâce une combinaison d'outils et d'approches s'appuyant sur la modélisation, l'exploitation de données de télédétection et la collecte de mesures in-situ. La modélisation permet de simuler le développement, la production et les besoins en eau de cultures à l'échelle parcellaire,

l'imagerie satellitaire apporte quant à elle des informations sur la variabilité spatio-temporelle du fonctionnement des cultures liée à des différences de pratiques agricoles, de conditions morpho-pédologiques et climatiques et permet donc de spatialiser les approches de modélisation. Il est également impératif de valider ces approches couplées, avec des données in-situ indispensables à la calibration et la validation. Ces données peuvent être obtenues via la mise en place de partenariats avec les acteurs du territoire.

## **1.2 État de l'art : Utilisation des données satellitaire pour la détection, l'estimation des besoins et des consommations en eau.**

### **1.2.1 Cartographie et modélisation : Apport de la télédétection**

Les images de télédétection offrent de nombreux avantages pour la surveillance agricole tels que la précision spatiale, temporelle, l'objectivité de l'information, ainsi qu'une vision globale du territoire étudié [23]. Ces images ont permis entre autre de cartographier les cultures et leurs rendements [24], dès 1987. Pour obtenir ces résultats, il est nécessaire de coupler les données de télédétection et les approches de modélisation.

#### **1.2.1.1 Cartographie-Classification**

De nombreuses études ont utilisé des images de télédétection multi-spectrales et multi-temporelles pour cartographier les zones irriguées [25–35]. Mais, la plupart ont été menées dans des zones semi-arides : [36–44]. Lorsque j'ai démarré ma thèse, il existait très peu de travaux sur la cartographie à haute résolution spatiale des cultures irriguées en zone tempérée. En climat tempéré, la détection des parcelles irriguées est plus difficile qu'en zone aride ou semi-aride en raison de la présence de pluies qui, selon les années, peuvent gommer les différences (phénologie) entre les cultures irriguées et non irriguées [45, 46]. S'intéresser à la cartographie des cultures irriguées en zone tempérée est donc un véritable défi. Néanmoins de nombreuses études ont démontré que l'utilisation des séries chronologiques optiques denses peuvent améliorer la cartographie des cultures en zone tempérée [47–51]. Toutefois comme l'imagerie optique est affectée par la couverture nuageuse, la performance de la cartographie des cultures avec ces données peut être réduite en particulier sur les zones tempérées ou tropicales [52].

Pour s'affranchir des limites liée à la nébulosité, certains auteurs ont proposé des approches de classifications basé sur des données micro-ondes, tel que les données Sentinel-1 et SMOS, SMAP [53–55]. Brocca et al [53] a mis au point une méthode pour quantifier les événements d'irrigation en combinant les produits d'humidité du sol issus des différents capteurs micro-ondes et un modèle de bilan hydrique. Ce travail a été appliqué sur diverses régions dans le monde mais n'a pas pu être évalué en raison de l'absence d'observations in-situ fiables de l'irrigation sur les périmètres irrigués correspondants. Une étude similaire a été menée sur les Etats-Unis par Zaussinger et al [54], dans laquelle ils ont combiné l'humidité du sol de surface récupérée par les capteurs micro-ondes spatiaux SMAP, AMSR2 et ASCAT avec l'humidité du sol modélisée par la ré-analyse MERRA-2 pour dériver la dynamique mensuelle de l'eau utilisée pour l'irrigation pour la période 2013-2016. La méthodologie repose sur l'hypothèse que le modèle MERRA-2 ne tient pas compte de l'irrigation, alors que les humidités du sol estimées par télédétection contiennent un signal d'irrigation. Les résultats agrégées à l'échelle des états, illustrent une bonne corrélation avec les prélèvements d'eau d'irrigation observée, mais les sous-estiment systématiquement. Cette divergence est attribuée à la résolution spatiale grossière des humidités du sol par satellite, qui ne permet pas de résoudre les pratiques d'irrigation locales. De la même manière, Bazzi et al [55], ont développé une méthodologie permettant de détecter les événements d'irrigations à l'échelle parcellaire à partir de données Sentinel-1 couplé aux données météorologiques. Cette nouvelle approche basée sur la détection des changements dans les coefficients de rétro-diffusion S1 a été appliqué sur divers territoires aux climats contrastés et permet d'obtenir, pour le maïs (en zone tempérée et semi-aride) et pour la luzerne et le blé en zone semi-aride, une fiabilité d'observation d'un événement d'irrigation de l'ordre de 84 %.

Malgré les bonnes performances des méthodes de classification basée uniquement sur les données micro-ondes, ces approches peuvent-être limitées par la résolution spatiale des produits d'humidité du sol et par des périodes de pluies soutenues entraînant une baisse de performance des modèles de classification. [43].

D'autres études [55–60] avaient montré que l'utilisation conjointe de données optiques et radars améliorait la robustesse des méthodes de cartographie. Demarez et al [58] ont démontré que l'utilisation conjointe des données optiques (Landsat-8) et d'imagerie SAR (Sentinel-1) permettent d'améliorer la détection des zones irriguées dans le Sud-Ouest de la France. Cependant, dans cette étude, le principal facteur limitant était la trop faible résolution temporelle des images Landsat-8. Bazzi et al [59], avaient également montré que l'utilisation combinée de séries temporelles Sentinel-1 et Sentinel-2 permettait de cartographier dans le sud-Ouest de la France, les surfaces agricoles (le maïs et le tournesol) avec une précision de 88 % pour les cultures pluviales et 94% les cultures irriguées.

Nous avons donc choisi d'évaluer dans la thèse, l'apport des données Sentinel optiques et radars utilisées en synergie pour la cartographie des cultures irriguées et non irriguées dans le Sud-Ouest de la France. Nous avons choisi de faire le focus sur les grandes cultures présentes majoritairement sur nos sites d'étude : le tournesol, le soja et le maïs, ces 2 dernières étant irriguées.

### 1.2.1.2 Modélisation du bilan hydrique

La seconde partie de ma thèse a été consacré à l'étude des besoins et des consommations en eau du maïs irrigué. Les modèles de culture ont été largement utilisés pour simuler le développement, la production et les besoins en eau des cultures à l'échelle parcellaire [61]. Parmi ces modèles, il est possible de distinguer trois grandes catégories selon leur niveau de complexité et leur aptitude à être spatialisés. Premièrement, les modèles que l'on pourrait qualifier d'«écophysiologiques» [62] qui simulent de façon mécaniste les principaux processus clés du fonctionnement des plantes (photosynthèse, respiration, bilan hydrique etc.). Parmi ces modèles, nous pouvons citer le modèle STICS, qui permet de modéliser de nombreuses cultures. Ce modèle nécessite en entrée plus de 200 paramètres relatifs aux caractéristiques de la plante, aux pratiques culturales ou aux propriétés de sol. De nombreux travaux de spatialisation ont été menés avec ce modèle [63–65], mais la principale limite de cette approche réside dans le manque de données in-situ nécessaires pour renseigner l'ensemble des paramètres permettant de configurer le modèle.

Il existe une autre catégorie de modèles dits "empiriques", qui permettent de calculer les besoins en eau des cultures à partir de l'équation de l'évapotranspiration proposée par Penmann et Monteith [66] et d'indices de végétation tels que le NDVI dérivés de données de télédétection. Ces modèles sont faciles à mettre en oeuvre mais les données in-situ utilisées pour leur calibration sont rarement représentatives de toute la gamme des variations possibles à l'échelle d'un territoire, ce qui limite leur application à de petites zones.

Face aux limitations des modèles empiriques et écophysiologiques, une troisième catégorie de modèles de culture a été développée : les modèles agro-météorologiques. Ces modèles combinent l'équation de Penmann-Monteith avec quelques processus majeurs permettant de prendre en compte le cycle de développement des plantes et le bilan hydrique du sol. Ils ont un nombre de formalismes et de paramètres restreints et, à l'instar des modèles « simples », ils sont adaptés à l'étude des grandes surfaces et spécifiquement conçus pour utiliser les données de télédétection [67,68]. Ces modèles permettent de simuler le fonctionnement des cultures à l'échelle locale (parcelle) avec un nombre de paramètres limités et leur utilisation conjointe avec l'imagerie satellitaire, permet d'étendre leurs simulations sur de grands territoires et ainsi de prendre en compte la variabilité spatiale et temporelle des cultures [69, 70].

Plusieurs modèles de ce type ont été proposés dans la littérature pour modéliser les besoins en eau des cultures (Pilote [71], SAFY [72–74], AquaCrop [75], PolyCrop [76], AqYield [77], HidroMORE [78, 79] et SAMIR [80]). Er-Raki et al [81], ont montré que l'on pouvait suivre le développement et estimer correctement les besoins en eau du blé dans le centre du Maroc en couplant un modèle agro-météorologique (FAO-2Kc), à des données SPOT et LANDSAT. De la même manière, Battude et al [74], ont estimé les besoins en eau du maïs en utilisant le modèle SAFYE combiné à des données SPOT, Formosat et LANDSAT. Olivera et al [82], ont également démontré le potentiel des données satellitaires couplées au modèle agro-météorologique de la FAO-56 pour estimer les composantes du bilan hydrique sur du blé en zone semi-aride. Chen et al [83], ont proposé une approche différente pour détecter le moment de l'irrigation à partir de données LANDSAT. La méthode s'est montrée prometteuse pour la détection des événements d'irrigation. Cependant, elle n'était applicable que pendant la première moitié de la saison de croissance et ne permet pas d'estimer les quantités d'irrigation.

Dans ma thèse, nous avons choisi d'utiliser le modèle SAMIR (Satellite Monitoring of IRrigation), développé

par Simmoneaux et al [80] pour plusieurs raisons : (1) il repose sur la méthode FAO-56, qui est très utilisée dans la communauté scientifique mais aussi par les acteurs du territoire (CACG, Chambre d'agriculture) du fait du faible nombre de paramètres utilisés en entrée. (2) Il a été initialement conçu et développé pour être piloté par des données de télédétection et a fourni des résultats encourageants dans les travaux précédents [80, 84, 85]. Cependant, dans Saadi et al [85], les limites du modèle ont été mises en évidence comme (1) l'incertitude liées à l'initialisation et l'estimation de l'humidité du sol au début de la saison d'irrigation et (2) la capacité du module d'irrigation automatique à estimer les volumes irrigués du maïs en climat tempéré. Ce module d'irrigation automatique basé sur le développement phénologique a été proposé par Saadi [85] pour pallier au manque d'information in-situ sur les pratiques d'irrigations. Nous avons donc cherché à évaluer la validité du module d'irrigation automatique sur nos sites d'études.

Le seuil de déclenchement des irrigations dépend également du contenu en eau dans le sol et plus particulièrement la Réserve d'eau Utilisable par la plante (RU). Cette propriété dépend des propriétés hydrodynamiques du sol et des propriétés écophysologiques de la plante. Elle est mesurée par l'écart entre deux points d'humidité : l'humidité à la « capacité au champ du sol » et celle au « point de flétrissement de la plante ». Ces deux points d'humidité peuvent être estimés à partir de fonctions dites de pédo-transfert [86–88]. Toutefois le domaine de validité de ces fonctions sont restreint aux types de sols pour lesquels elles ont été établies. Certains auteurs ont démontré qu'une incertitude sur la RU pouvait avoir une influence sur les dates de début et de fin d'irrigation et également modifier la fréquence et la quantité des doses d'irrigation à apporter. Ces incertitudes sont encore fortes pour les sols peu profonds et lorsque les conditions climatiques présentent un déficit hydrique [89, 90]. Pour pallier, à ce manque d'information spatialisée, le programme GlobalSoilMap de l'International Soil Reference and Information Centre (ISRIC), a lancé en 2009, un programme de recherche qui a abouti à la production d'une carte des sols à l'échelle mondiale à une résolution spatiale de 90 m, possédant les informations nécessaires pour estimer la Réserve Utile sur de large territoire. En parallèle de ce programme international, l'INRAE fourni sur la France, la carte du RRP (Référentiel Régional Pédologique) au 1/250 000 <sup>ième</sup> couplée à la base de données Done Sol. Dans le cadre de mes travaux, nous avons évalué ces cartes pédologiques (GSM et RRP), pour l'estimation des consommations en eau du maïs irrigué.

### 1.3 Démarche scientifique et Plan de thèse

L'objectif de mes travaux de thèse visent à diagnostiquer les surfaces irriguées et à mieux comprendre et modéliser les besoins et consommations en eau des cultures d'été à une échelle compatible avec les prises de décision des gestionnaires, c'est-à-dire, le sous bassin-versant (BV) (= périmètre élémentaire pour les OUGC). Pour répondre à mon objectif, nous avons retenu 3 sites d'études. Il s'agit de trois BV caractérisés par une forte activité agricole ayant recours à l'irrigation et une forte pression sur la ressource en eau, comme illustré sur la figure 1.3 : Neste (7600 km<sup>2</sup>), Tarn-Aval (3000 km<sup>2</sup>) et Adour-Amont (1500 km<sup>2</sup>), situés dans le bassin Adour-Garonne (Région Occitanie). Sur cette carte 1.3 les BV ayant leurs contours en rouge correspondent aux territoires étudiés.

Cette thèse a été réalisée en partenariat avec la Compagnie d'Aménagement des Coteaux de Gascogne (CACG), l'Agence de l'eau Adour-Garonne et le CNES qui ont également cofinancé la thèse. La CACG est le gestionnaire depuis plus de 20 ans du BV de la Neste. J'ai été également accompagné, pendant toute la durée de la thèse, par les chambres d'agriculture des Hautes-Pyrénées (CA 65) et du Tarn (CA 81). La CA 81 anime l'OUGC pour le BV Tarn Aval et la CA 65 anime l'OUGC Irrigadour par désignation du Préfet. Ce partenariat m'a permis de bénéficier de l'expertise sur la gestion de l'eau propre à chaque territoire ainsi que d'un important jeu de données de mesure in-situ indispensable à nos travaux de modélisation.

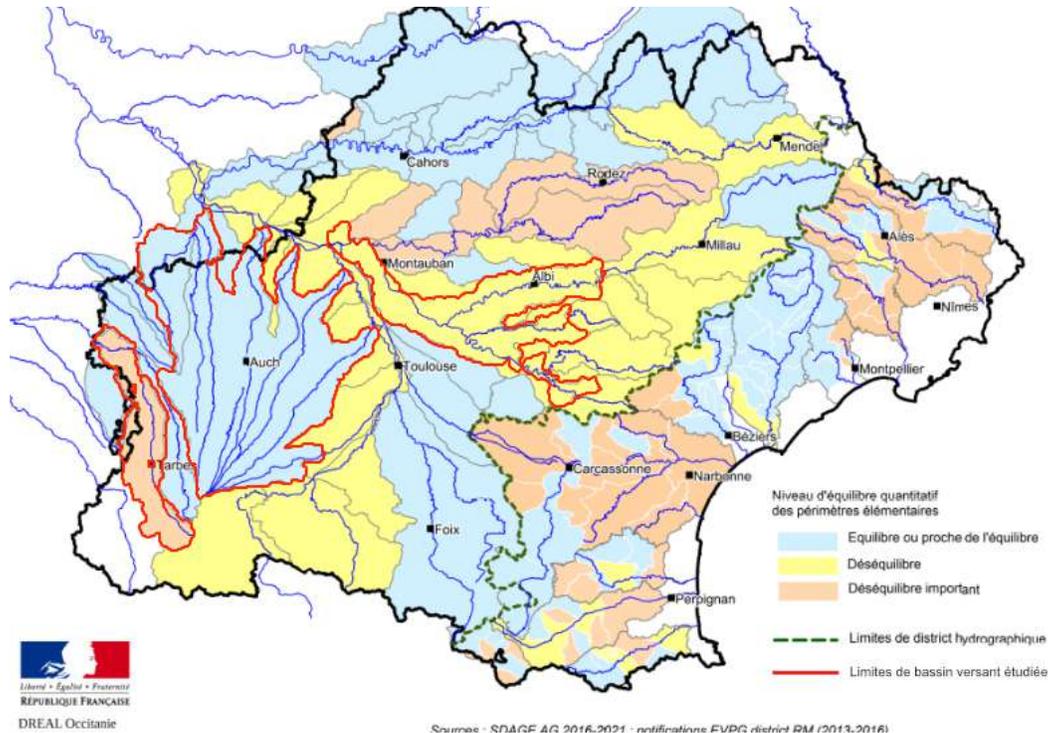


Figure 1.3 – Carte du déséquilibre quantitatif en eau à l'échelle des périmètres élémentaires du bassin versant Adour-Garonne, Extrait du SDAGE Adour Garonne 2016-2021

La carte 1.3 illustre l'état du déséquilibre quantitatif en eau des périmètres élémentaires. Elle est issue de la comparaison entre le volume prélevé maximum et le volume prélevable sur la ressource en eau. Cette carte a permis d'identifier les périmètres élémentaires à fort enjeu à l'échelle du BV Adour Garonne. Toutefois cette échelle est trop large pour répondre aux besoins des gestionnaires qui ont des spécificités (usages, climat, type de sol et de pratiques) locales à prendre en compte si l'on veut apporter des réponses adaptées à leur territoire.

Ainsi quelques projets de recherche ont été menés sur ces territoires à des échelles plus fines, tel que le projet MAISEO (2012-2017) en collaboration avec la CACG notamment, et le projet Simult'Eau (2014-2017) avec Arvalis, le laboratoire AGIR, les Chambres d'Agriculture du Tarn et des Hautes-Pyrénées et la CACG. Dans ces projets, l'apport des images satellitaires, issus de capteurs optiques, à haute résolution spatiale (entre 20 et 30 m) ont été évalués pour la cartographie des surfaces irriguées et l'estimation des besoins et des consommations en eau des cultures à l'échelle des périmètres irrigués. Les résultats obtenus étaient encourageants mais restaient entachés d'incertitude. Une part des incertitudes observées était due à la faible périodicité (1 images par mois) des capteurs utilisés (LANDSAT 5,7,8 et SPOT 4,5) pouvant conduire à de longues périodes (jusqu'à 2 mois) sans images exploitables dû à la présence de nuages. Or une haute répétitivité temporelle est indispensable pour réaliser un suivi précis du cycle de développement des cultures et modéliser leur fonctionnement. Une autre source d'incertitude identifiée était liée à l'estimation de la réserve utile des sols.

Pour pallier à ces limitations nous avons décidé d'évaluer, dans le cadre de ma thèse, le potentiel des récentes données satellitaires à haute résolution spatiale et temporelle (Sentinel) et de cartes des sols mieux résolues pour la détection de surfaces irriguées et l'estimation des besoins et des consommations en eau du maïs irrigué. Le récent programme spatial Copernicus fournit des images optiques et radars acquises tous les 5 jours, sur l'ensemble du globe avec une résolution spatiale d'environ 10 m et en libre accès. Cette nouvelle génération d'images permet des avancées significatives pour le suivi des surfaces agricoles à l'échelle des territoires [91–96].

Mon travail de thèse a donc consisté à proposer une démarche visant à fournir et évaluer une méthode d'estimation des surfaces irriguées, des besoins et des consommations en eau des cultures d'été à l'échelle des territoires (périmètres irrigués). Pour réaliser ce travail, j'ai dans un premier temps, cartographié les surfaces

irriguées et pluviales à partir d'un modèle de classification supervisée. Dans un second temps, j'ai utilisé le modèle SAMIR développé au CESBio qui permet de simuler les besoins et consommation en eau.

La cartographie des surfaces irriguées a été évaluée à partir de mesures terrains effectuées par les partenaires de la thèse. Cette cartographie a permis de spatialiser le modèle SAMIR et d'estimer des indicateurs essentiels pour optimiser la gestion de la ressource en eau. Ces indicateurs sont : la superficie de culture irriguée à l'échelle des périmètres élémentaires et la localisation des parcelles ayant recours à l'irrigation en cours et fin de saison.

Pour la modélisation des besoins et des consommations en eau des cultures irriguées, le focus a été fait sur la culture du maïs, qui est majoritaire sur nos territoires d'étude. La validation du modèle a été possible grâce aux mesures d'évapotranspiration et aux dates et doses d'irrigations recueillies sur diverses parcelles. Le module d'irrigation automatique développé par Saadi et al [85], a également été évalué.

Une réflexion a également été menée sur la calibration avec comme objectif de limiter au maximum le recours aux données in-situ et aux formalismes empiriques. Pour cela, nous avons évalué l'apport des données FCover estimées à partir des données satellitaires (Sentinel-2), l'apport du formalisme de Merlin et al, basé sur les propriétés de sol pour estimer le coefficient réducteur de l'évaporation du sol et l'apport des données pédologiques pour estimer la Réserve utile maximale.

La quantité importante de mesures in situ et d'images satellitaires mises à ma disposition ont constitué un atout majeur pour mener à bien ce travail. En effet, j'ai pu bénéficier de nombreuses mesures in-situ issues de plusieurs années de campagne de mesures. Le programme spatial Copernicus m'a également permis de disposer de nombreuses images optiques et radars. La CACG et les Chambres d'agriculture m'ont également fourni des données précieuses notamment celles relatives à l'irrigation provenant de la CACG. Les données collectées ont permis de valider les modèles à différentes échelles : l'échelle bassin versant qui constitue l'objectif final de ce travail, mais aussi l'échelle parcellaire, étape préliminaire nécessaire pour s'assurer de la cohérence des sorties des modèles dans différentes situations.

Le chapitre 1 est dédié à la description de la zone d'étude et des données utilisées. Le travail sur la cartographie des cultures irriguées est présenté dans le chapitre 2. Il s'appuie sur l'utilisation des images Sentinel (Sentinel-1, Sentinel-2) et de l'utilisation d'une chaîne de traitement (iota<sup>2</sup>). La méthode que nous avons développée permet d'identifier le type de culture et la pratique (irriguée ou non) [97]. Nous avons évalué deux échelles de temps : la cartographie en cours et en fin de saison.

La modélisation du bilan hydrique du maïs irrigué avec le modèle SAMIR est présentée dans le chapitre 3. Ce chapitre présente les résultats de la modélisation du bilan hydrique à différentes échelles : la parcelle expérimentale du CESBio (ferme de Lamothe), les parcelles de référence, les périmètres irrigués et les bassins versants de Neste, Adour-amont.

Enfin, une conclusion générale reprend les principaux résultats, éléments de discussion et perspectives de ce travail.

Mon travail a permis d'apporter des éléments de réponse aux questions suivantes :

*Quelles méthodes et outils utilisées pour cartographier de façon robuste (dans le temps et l'espace) les surfaces irriguées ? Quelles données utiliser pour calibrer nos modèles et valider nos résultats ? Quel est la robustesse du modèle de bilan hydrique pour estimer les besoins et les consommations en eau à différentes échelles spatiales ? Quelles données pédologiques utiliser pour spatialiser les besoins en eau d'irrigations ? Quelle est la précision des résultats obtenus ?*



## 2.1 Zone d'étude : Bassin versant et leurs enjeux

La zone d'étude (Figure 2.1) est localisée en région Occitanie, dans le bassin Adour Garonne. Trois territoires ont été étudiés : les BV de la Neste (7600 km<sup>2</sup>), d'Adour-Amont (1500 km<sup>2</sup>) et du Tarn-Aval (2900 km<sup>2</sup>).

Ces trois sous-bassins hydrographiques présentent une forte tension sur la ressource en eau lors de la saison estivale et une forte présence de l'activité agricole sur ces territoires. En effet, l'activité agricole est prédominante sur ces trois BV, avec environ plus de 50 % de terres cultivées, le reste étant couvert par des forêts, des prairies ou du bâti. Les différents assolements agricoles sont : cultures d'hiver (blé, colza, etc.) et cultures d'été (maïs, sorgho, tournesol, soja) irriguées ou pluviales.

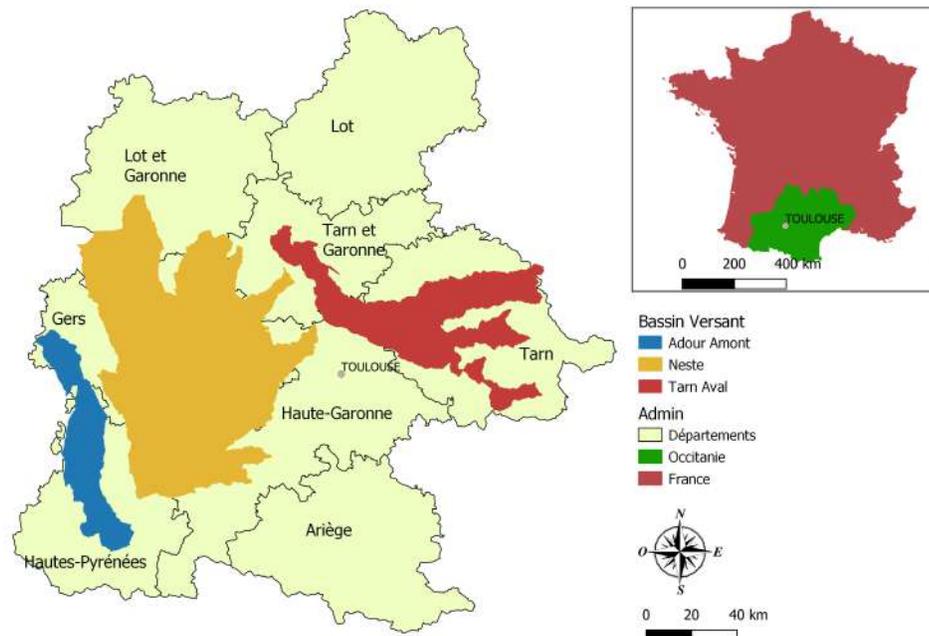


Figure 2.1 – **Localisation des zones d'études**, Les bassins versants étudiés d'Adour-Amont en bleu, Neste en orange et Tarn Aval en rouge

Parmi, les cultures d'été majoritaires sur le territoire du BV d'Adour Amont, nous retrouvons le maïs, le soja et le tournesol représentant respectivement 82 %, 9 % et 8 % (Figure 2.1a), selon le Registre parcellaire graphique (RPG) de l'Agence des services et des paiements français publié en 2018. La période de croissance des cultures d'été s'étend d'avril à novembre. Seul le maïs et le soja sont irrigués et leurs besoins en eau d'irrigation représentent 30 millions de m<sup>3</sup> sur la saison. Sur le BV de la Neste et du Tarn Aval, nous constatons que le tournesol représente 46% et 43% des cultures cultivées, le maïs représentent respectivement 28 % et 38% et le soja 16 % et 10% . Deux autres cultures sont plus faiblement représentées : le pois (6%) et le sorgho (3.6%) (Figure 2.1b et 2.1c).

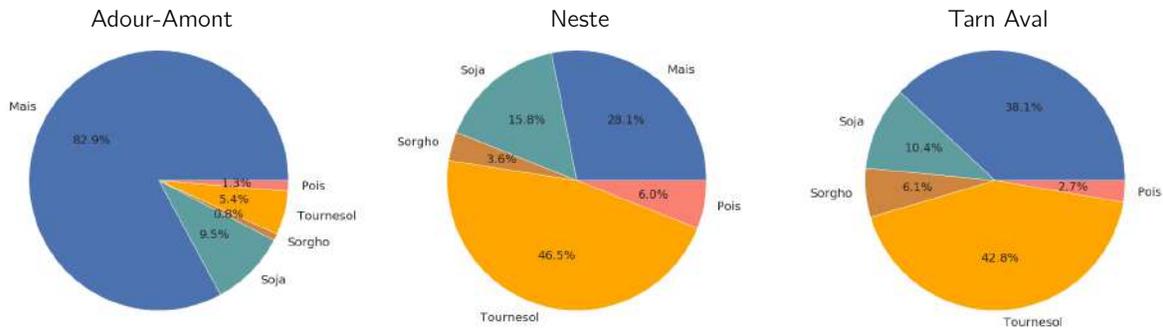


Figure 2.2 – Répartition des occupations du sol agricole en été sur les bassins versants, données issues du Registre parcellaire Graphique

### Climat

Le climat de la zone est tempéré, soumis à une influence atlantique et pyrénéenne, conduisant à des températures moyennes estivales comprises entre 20 et 25°C. Le printemps est humide avec une pluviométrie mensuelle de l'ordre de 90 mm sur le BV d'Adour Amont et 70 mm sur les deux autres BV. Les mois de décembre, janvier et mai sont les plus pluvieux, avec des épisodes très intenses, comme illustrés sur la figure 2.3. Les précipitations mensuelles de ces mois sont supérieures à 90 mm en 2017 et 120 mm en 2018. Les précipitations sont minimales entre juin et octobre, ce qui explique le recours à l'irrigation. Concernant les températures, celles-ci varient entre 5°C et 25°C, tout au long de l'année, avec les plus fortes températures relevées au mois de juillet et août et des maxima locaux pouvant atteindre 30°C.

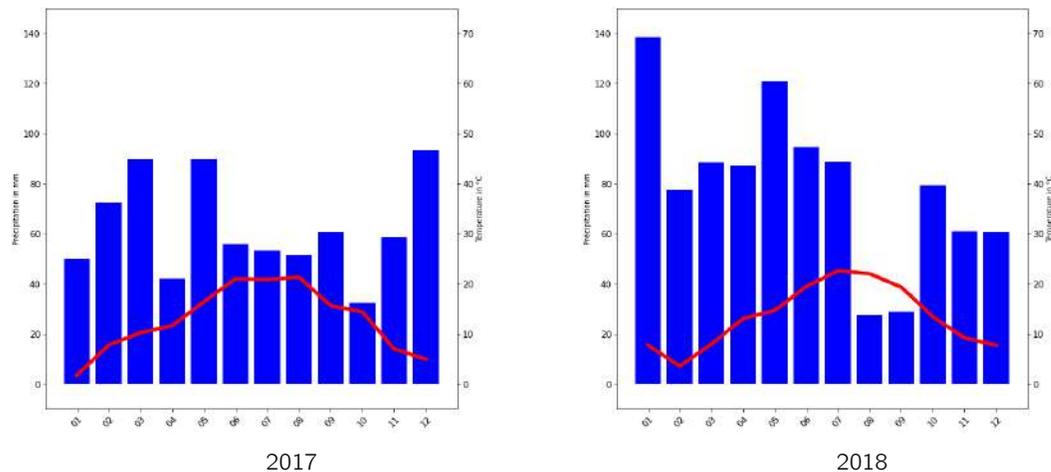


Figure 2.3 – Diagramme ombrothermique de la zone d'étude Figure 3.17a illustre l'année 2017 et la figure 3.17b correspond à 2018. Pluviométrie mensuelle (en bleu) et température moyenne mensuelle (en rouge) issues de la base de données SAFRAN

### Déficit hydrique

Le climat des trois BV étudiés implique, pour maintenir un rendement optimal des cultures d'été, la pratique de l'irrigation durant la période estivale qui est marquée par des faibles précipitations (inférieures à 50 mm /mois). Selon les OUGC et les services de l'état, le BV d'Adour Amont, est un secteur en déséquilibre hydrique depuis de nombreuses années. Le Débit d'Objectif d'Étiage (DOE) fixé à  $4.3 \text{ m}^3 \cdot \text{s}^{-1}$  n'est pas atteint 2 à 3 années sur 10. Le BV Tarn Aval, est aussi qualifié en déséquilibre hydrique. Le Volume Prélévable Autorisé (VPA) sur ce BV, en période d'étiage est de  $59.16 \text{ hm}^3$  dans les cours d'eau et nappes d'accompagnement, afin d'irriguer 6% de la SAU du bassin versant, selon l'état des lieux de 2019 réalisé par le DRAAF [98]. Ce même état des lieux indique que 22 % du périmètre de l'OUGC est en pression significative de prélèvement irrigation (Figure 2.4).

Pour la Neste, la situation hydrique du BV est différente de celles des deux autres BV. Ce BV est défini comme étant en équilibre hydrique, grâce à son système de ré-alimentation des cours d'eau (Système Neste). Ce système construit au 19<sup>ème</sup> siècle permet de maintenir le niveau d'eau des rivières en conciliant de nombreux usages tels que l'alimentation en eau potable des villes du Gers, l'agriculture, l'industrie et ceux tout au long de l'année. Actuellement, le système Neste permet à 70% d'assurer un débit suffisant dans les rivières ré alimentées et à 30 % d'assurer l'alimentation en eau des activités humaines, telles que l'approvisionnement en eau potable et l'agriculture. Le VPA en période d'étiage est de 148.33 hm<sup>3</sup> dans les cours d'eau et nappes d'accompagnement, afin d'irriguer selon l'état des lieux de 2019 réalisé par le DRAAF, 13 % de la SAU (69 629 ha) du bassin versant. Ce même état des lieux indique que 63 % du périmètre de l'OUGC est en pression significative de prélèvement irrigation (Figure 2.4) [98].

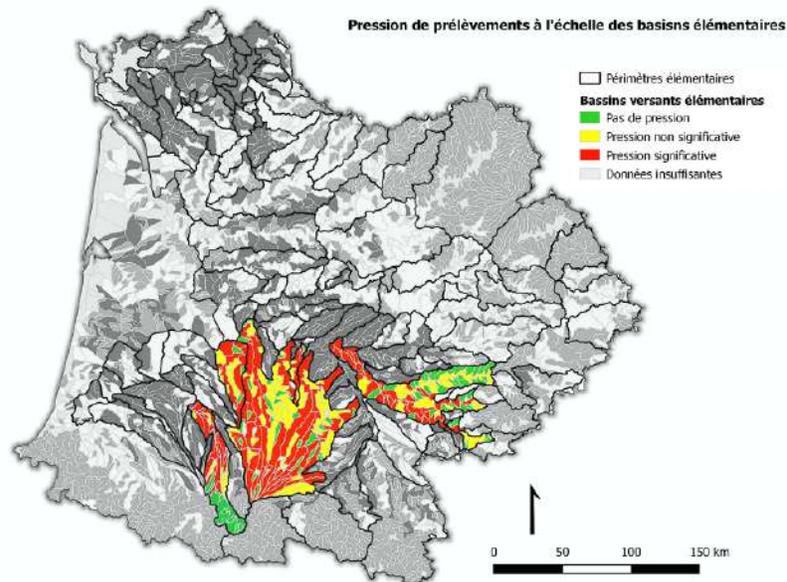


Figure 2.4 – **Carte de la pression de prélèvement pour l'irrigation ; source DRAAF 2019**, les bassins versants colorés correspondent aux trois zones étudiées.

## 2.2 Données satellitaires

Les images utilisées au cours de mes travaux de thèse sont issues de la constellation Sentinel.

### 2.2.1 Constellation Sentinel

Les satellites de la constellation Sentinel, sont issus du programme européen Copernicus. L'objectif de ce programme est d'offrir des produits issus de satellites d'observation de la Terre et de données in-situ.

Dans ma thèse, j'ai utilisé les données issues des missions Sentinel-1 & Sentinel-2.

#### 2.2.1.1 Sentinel-1

La mission Sentinel-1 est composée de deux satellites, SENTINEL-1A et SENTINEL-1B, qui partagent le même plan orbital et qui ont été lancés respectivement en 2014 et 2016 par l'Agence Spatiale Européenne (ESA). Les deux satellites fournissent des images en bande C fonctionnant dans quatre modes d'imagerie avec une résolution spatiale allant jusqu'à 5 m et une couverture d'environ 400 km. Ils offrent une capacité de double polarisation, un temps de revisite très court, de l'ordre de 6 jours sur la zone d'étude. Le système d'imagerie

embarqué sur les satellites est un radar à ouverture synthétique (SAR) qui a l'avantage de fonctionner à des longueurs d'onde qui ne sont pas perturbées par la couverture nuageuse ou par un manque de luminosité la nuit. Lors de mes travaux, nous avons choisi d'utiliser les images issues du mode IW (Interferometric Wide), fournies à une résolution spatiale de 20 m, sur une fauchée de 250 km. Ce mode d'acquisition IW capture trois sous-bandes par rétro-diffusion du signal avec balayage progressif de la scène (Figure 2.5). Ces images ont été téléchargées sur la plate-forme PEPS [<https://peps.cnes.fr/>]. Seule l'orbite ascendante (orbite n°30) a été utilisée afin de limiter l'impact de la rosée matinale et de la rosée givrante, qui peuvent entraîner des artefacts dans le signal SAR [99, 100], ce qui fait un total de 179 images (79 en 2017 et 100 en 2018).

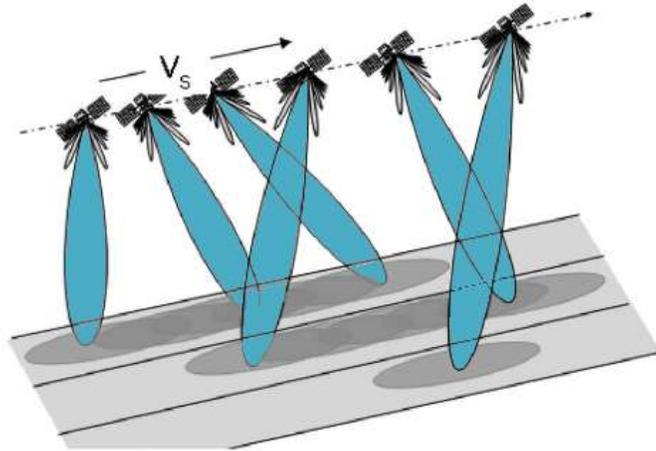


Figure 2.5 – Schéma du procédé d'acquisition des images S1 mode IW

### 2.2.1.2 Sentinel-2

Les satellites Sentinel-2A et Sentinel-2B ont été lancés en 2015 et 2017 respectivement par l'Agence Spatiale Européenne (ESA). Les images acquises ont des résolutions spatiales variant de 10 à 60 m selon les bandes spectrales qui sont au nombre de 13. Le domaine spectral couvert s'étend du visible, au moyen infrarouge comme illustré par le tableau 2.1. La combinaison des deux satellites permet d'obtenir une période de revisite de 5 jours.

Table 2.1 – Principales caractéristiques des bandes spectrales des satellites Sentinel-2 (A & B)

Bandes spectrales (Sentinel-2)	Longueur d'onde (nm)	Résolution spatiale (m)
B1 - Aérosol	442	60
B2 - Bleu	492	10
B3 - Vert	559	10
B4 - Rouge	664	10
B5 - Végétation Red-Edge	704	20
B6 - Végétation Red-Edge	740	20
B7 - Végétation Red-Edge	782	20
B8 - Proche infra Rouge	832	10
B8A - Proche infra Rouge	864	20
B9 - Vapeur d'eau	945	60
B10 - Moyen Infra Rouge (Cirrus)	1373	60
B11 - Moyen infra Rouge	1613	20
B12 - Moyen infra Rouge	2202	20

### 2.2.1.3 Pré-traitement des données

Les images que j'ai utilisées ont été pré-traitées : ortho-rectifiées, corrigées des effets radiométriques et atmosphériques. Ces traitements ont été réalisés à l'aide de deux chaînes de traitement automatique développées par le CESBio : S1-tiling et MAJA [101]

**S1-Tiling** S1-Tiling a été développé au sein du service radar du CNES, en collaboration avec le CESBio, pour générer des séries temporelles d'images Sentinel-1 calibrées, ortho-rectifiées et filtrées, sur n'importe quelle région terrestre de la Terre. La chaîne de traitement utilise l'application d'ortho-rectification d'images radars de la librairie Orfeo Tool Box (OTB). Les images obtenues sont superposables aux images optiques Sentinel-2, car elles utilisent le même référentiel géographique MGRS. La procédure de traitement des images est illustrée par la figure 2.6 [<https://labo.obs-mip.fr/multitemp/>]. Dans le cadre de mes travaux, nous avons appliqué une calibration sigma0 sur les images, ainsi qu'un filtrage multi-temporel sur une fenêtre de  $2 \times 2$ , afin de supprimer les effets de speckle. La calibration sigma0 permet de normaliser les images, acquises à des dates différentes en convertissant l'intensité du signal en un coefficient de rétrodiffusion exploitable.

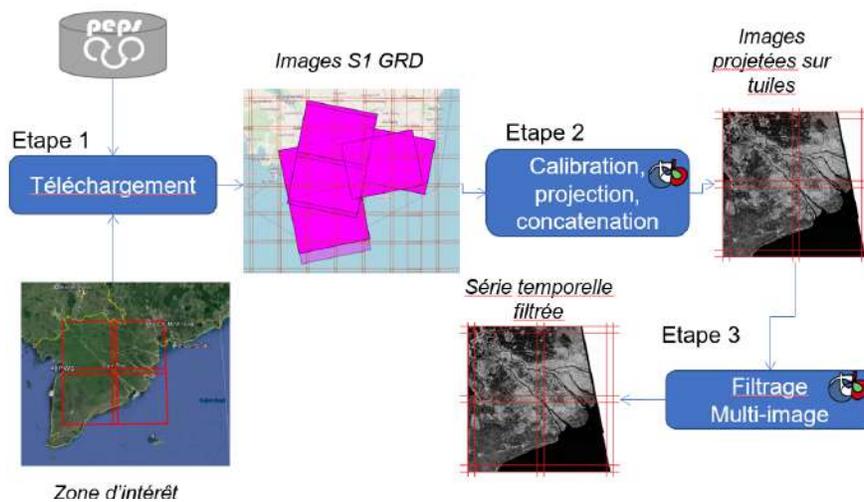


Figure 2.6 – Chaîne de traitement S1-tiling pour le traitement des données Sentinel-1, par Thierry Koleck

**MAJA** MAJA (MACCS-ATCOR Joint Algorithm) est une chaîne de détection de nuages et de correction atmosphérique. Elle est adaptée au traitement des séries temporelles d'images à haute résolution, acquises sous des angles de vue constants ou quasi constants. Elle permet notamment de traiter les données issues de LANDSAT et Sentinel-2. Elle se base sur la chaîne MACCS (Multi-sensor Atmospheric Correction and Cloud Screening) développée par le CNES et le CESBio depuis 2008, et incorpore progressivement depuis 2016 des méthodes issues de la chaîne ATCOR du DLR. Sa particularité est d'utiliser l'information multi-temporelle contenue dans les images pour détecter les nuages et leurs ombres, estimer le contenu atmosphérique en aérosols et en vapeur d'eau, et corriger les effets atmosphériques (en prenant en compte les effets d'environnement et les effets du relief). Les images pré-traitées sont téléchargeables sur la plate-forme Theia [<https://theia.cnes.fr/>]. J'ai utilisé pour mes travaux, 4 tuiles Sentinel-2 comme illustré dans la figure 2.7.

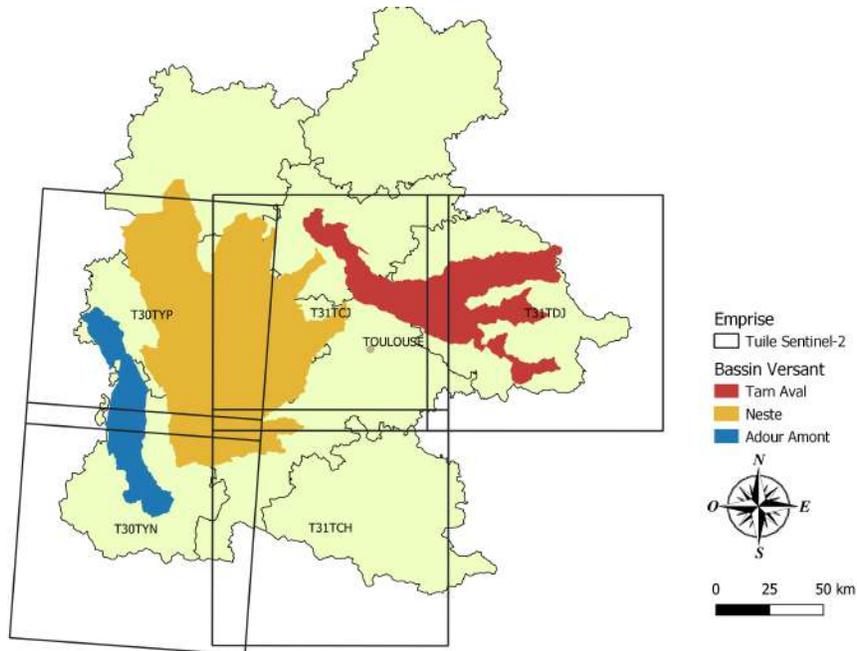


Figure 2.7 – Localisation des zones d'étude, selon les emprises des tuiles Sentinel-2 issues de la plate-forme Theia

La Figure 2.8 correspond au calendrier des acquisitions des images Sentinel-2 sur l'année 2017 et 2018. Nous avons utilisé au total 224 images avec un taux de nuage inférieur à 20%. Le nombre d'image disponible est supérieur en 2018 grâce à la mise en service du satellite Sentinel-2B.

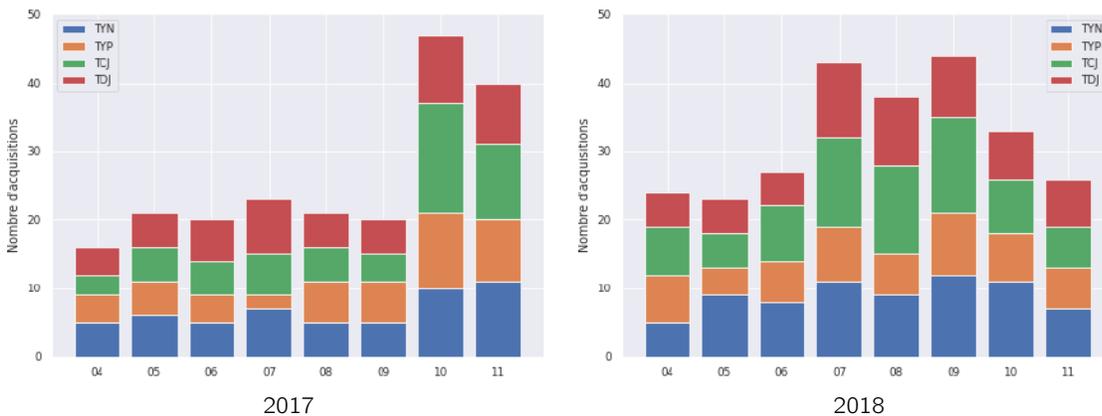


Figure 2.8 – Calendrier d'acquisition des images Sentinel-2 sur les années 2017 et 2018, en fonction des tuiles utilisées

## 2.3 Données de forçage

### 2.3.1 Registre Parcellaire Graphique

Le Registre Parcellaire Graphique (RPG) disponible depuis 2006 est une base de données non exhaustive de l'occupation du sol agricole couvrant le territoire français. Il est produit et fourni par l'ASP (Agence de

Service et de Paiements) chaque année dans le cadre de la politique de la PAC (Politique Agricole Commune). Il s'agit d'une cartographie de l'ensemble des parcelles agricoles bénéficiant des aides PAC. Les parcelles non subventionnées n'apparaissent donc pas dans ce document, ce qui représente 4 % des parcelles agricoles totale (29 millions ha selon les statistiques Agricole annuelles (SAA) de 2020), avec majoritairement des parcelles viticoles. La description des parcelles est basée sur de nombreuses informations, telles que le contour parcellaire, la localisation, le type de culture. Cependant les informations relatives à la pratique de l'irrigation n'y figurent pas.

Vingt-huit types de cultures sont identifiées et parmi celles-ci, 3 sont utilisées dans ma thèse : le maïs et ces déclinaisons (Maïs Semence (MIS), Maïs Doux (MID) et Maïs ensilage (MIE)), le soja (SOJ) et le tournesol (TRN).

### 2.3.2 Météo - SAFRAN

Les données météorologiques utilisées pour les travaux de modélisation sont issues du Système d'analyse atmosphérique à méso-échelle (SAFRAN) [102] développé par Météo-France. Ces données comprennent l'évapotranspiration de référence ( $ET_0$ ) et les précipitations (P). Les données sont disponibles au pas de temps hexa horaire sur une grille de 8 km de résolution. Pour mes travaux, je les ai moyennées à la journée.

### 2.3.3 Données sol

#### 2.3.3.1 Global Soil Maps : GSM

Le consortium GlobalSoilMap a été créé en 2010 dans le but de produire une carte numérique des sols à une résolution de 90 m pour le monde entier [103, 104]. Cette carte s'appuie sur la cartographie numérique des sols et utilisation de la détection proximale, de la télédétection, de l'exploration de données et les bases de données spatiales [105]. Elle vise à fournir des propriétés fonctionnelles des sols [106]. La production de cette carte a été confiée à l'unité InfoSol d'INRAE. Cette carte permet d'estimer la réserve utile du sol à l'échelle nationale [107].

#### 2.3.3.2 Carte pédologique : Référentiel Régional Pédologique (RRP)

Le référentiel Régional Pédologique (RRP) est une base de données géographique régionale ou départementale au 1/250 000<sup>ème</sup> issu du programme IGCS (Inventaire, Gestion et Conservation des Sols) du GisSol. Depuis août 2016, plus de 90% du territoire est couvert par cette base de données numérique, l'ensemble des départements sont aujourd'hui engagés dans la démarche de numérisation des cartes pédologiques, initialement au format papier. Les informations spatiales sont au format vecteur. Elles sont associées à la BD attributaire DoneSol. La représentation cartographique du RRP est divisée en Unités Cartographiques de Sol (UCS, information spatialisée), elles-mêmes constituées d'une ou plusieurs Unités Typologique de Sol (UTS, non spatialisé) associées à une description pédologique (ensemble de strates). Cette base de données fournit, notamment, la profondeur du sol, la texture (pourcentage d'argile, de limon et de sable) de chaque strate des UTS. Les données fournies dans les différentes tables de la base, sont issues de mesures terrains et d'analyse en laboratoire. Ces deux niveaux de mesure permettent de fournir pour chaque variable de sol, une gamme de valeur possible soit une valeur médiane, minimale et maximale.

#### 2.3.3.3 Référentiel Régional Pédologique, avec spatialisation des UTS (RRP<sub>UTS</sub>)

Une version plus précise du RRP a été mise à jour sur le département du Gers, dans le cadre du projet MAISEO. Cette mise à jour réalisée par Laurent Rigou, pédologue à ASUP (Atelier Sols, Urbanisme et Paysages), a consisté à cartographier les UTS et ainsi d'atteindre une échelle de 1/25 000<sup>ème</sup> compatible avec l'échelle parcellaire. Suite à ce changement d'échelle, les informations vectorielles contenues dans la carte initiale du RRP, ne cartographie plus les UCS, mais les UTS, comme illustré dans la figure 2.9.

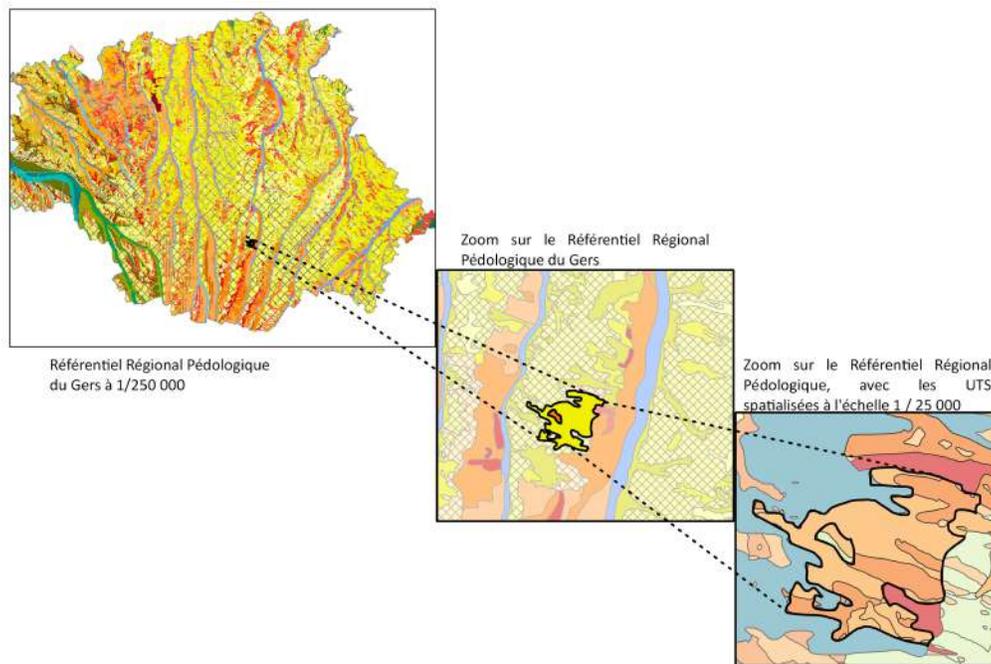


Figure 2.9 – **Imbrication des données pédologiques entre les données du RRP et celles avec la spatialisation des UTS**

En plus d'une cartographie plus précise des propriétés de sol, cette carte propose une profondeur maximale d'enracinement (figure 2.10a) et une estimation de la Réserve Utile (RU) (Figure 2.10b). La Ru est estimée en utilisant les fonctions de pédo-transfert de Bruand et al [88]. Cependant les fonctions pédo-transfert utilisées, ne tiennent pas compte de la présence d'éléments grossiers, ni des variations de densité apparente des horizons. Ces informations sont données en mm d'eau par cm de sol.

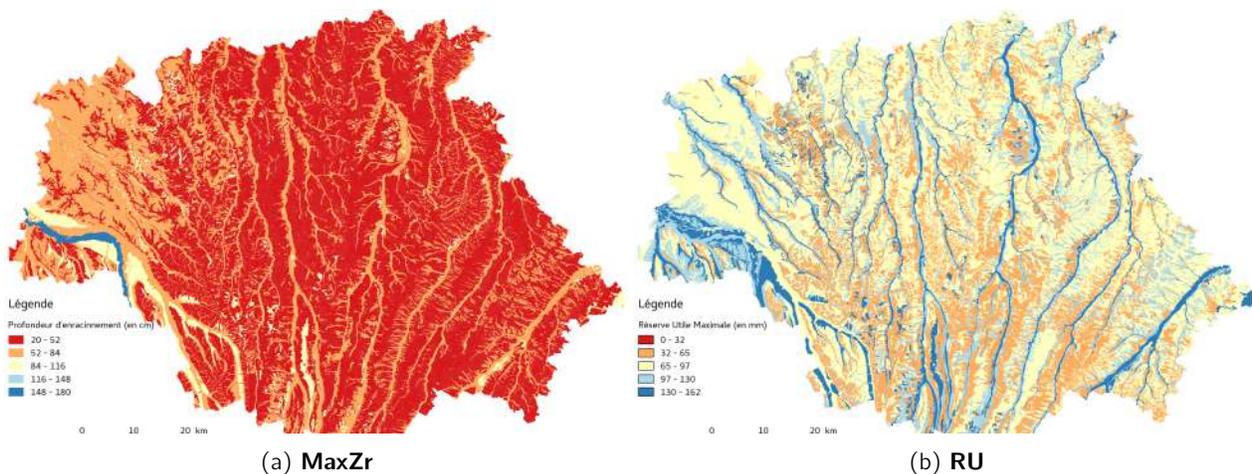


Figure 2.10 – **Carte des profondeurs maximale d'enracinement et de réserve utile, sur le département du Gers, carte produite à partir de la spatialisation des UTS.**

**Inter-comparaison des produits pédologiques disponibles** Les informations contenues dans ces cartes doivent être exploitées avec précaution. En observant les figures 2.11, représentant la distribution des types de sol des

parcelles de références, nous constatons que la variabilité des textures de sol, est nettement moins importante pour GSM que pour le  $RRP_{UTS}$ . Pour les données RRP, nous observons une stratification des propriétés de sol causée par le format de la donnée, transmises sous forme de classe. Cette stratification entraîne au sein d'une même classe de sol, une perte de variabilité, comme l'illustre le nombre de parcelle pour chaque point de la figure 2.11a, avec pour un seul point 12 parcelles présentant les mêmes caractéristiques de sol.

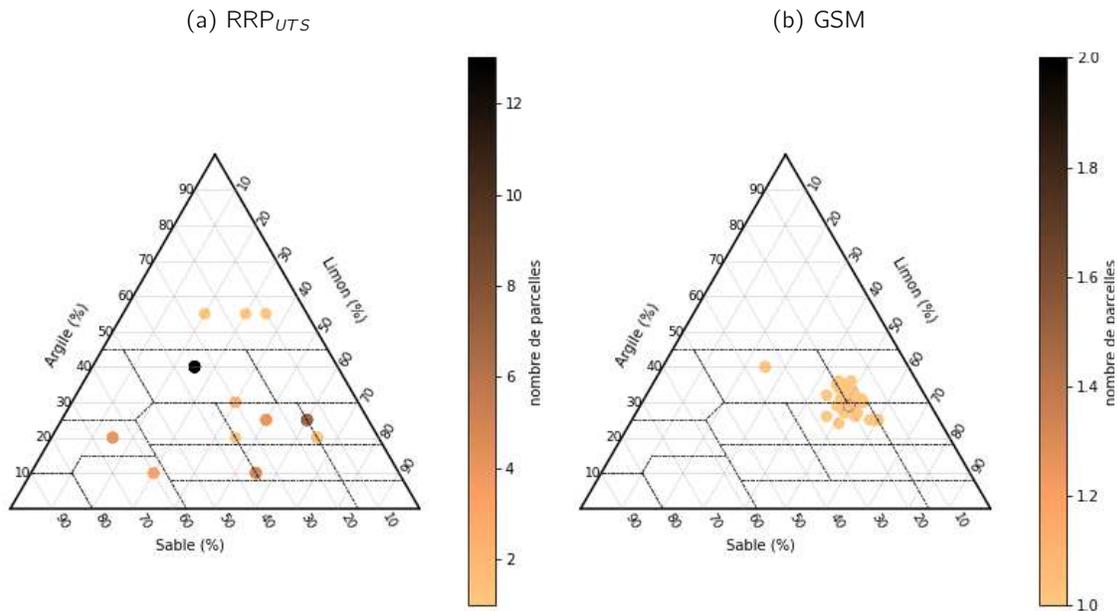


Figure 2.11 – Distribution des types de sols dérivés des produits pédologiques, avec la carte des UTS (à gauche), et GSM (à droite) basés sur le système de classification du triangle de l'Aisne. La couleur des cercles correspond aux nombres de parcelles ayant les mêmes caractéristiques pédologiques.

#### 2.3.3.4 Méthode d'extraction de la donnée $RRP_{UTS}$

La méthode de calcul de la RU à partir de la carte  $RRP_{UTS}$  est illustrée dans la figure 2.12. Étant donné, qu'une parcelle peut recouvrir plusieurs UTS, nous avons conservé pour cette parcelle, l'UTS majoritaire et les strates qui la composent. Le taux d'argile, de limon et de sable ont été pondérés par l'épaisseur de chaque strate. Ces différents taux sont utilisés pour estimer la texture à partir du triangle de « l'Aisne » [86,108]. La capacité volumique à la capacité au champ (pF 2.0) et au point de flétrissement (pF 4.2) sont ensuite estimées en utilisant les tables de référence proposées par Bruand [88].

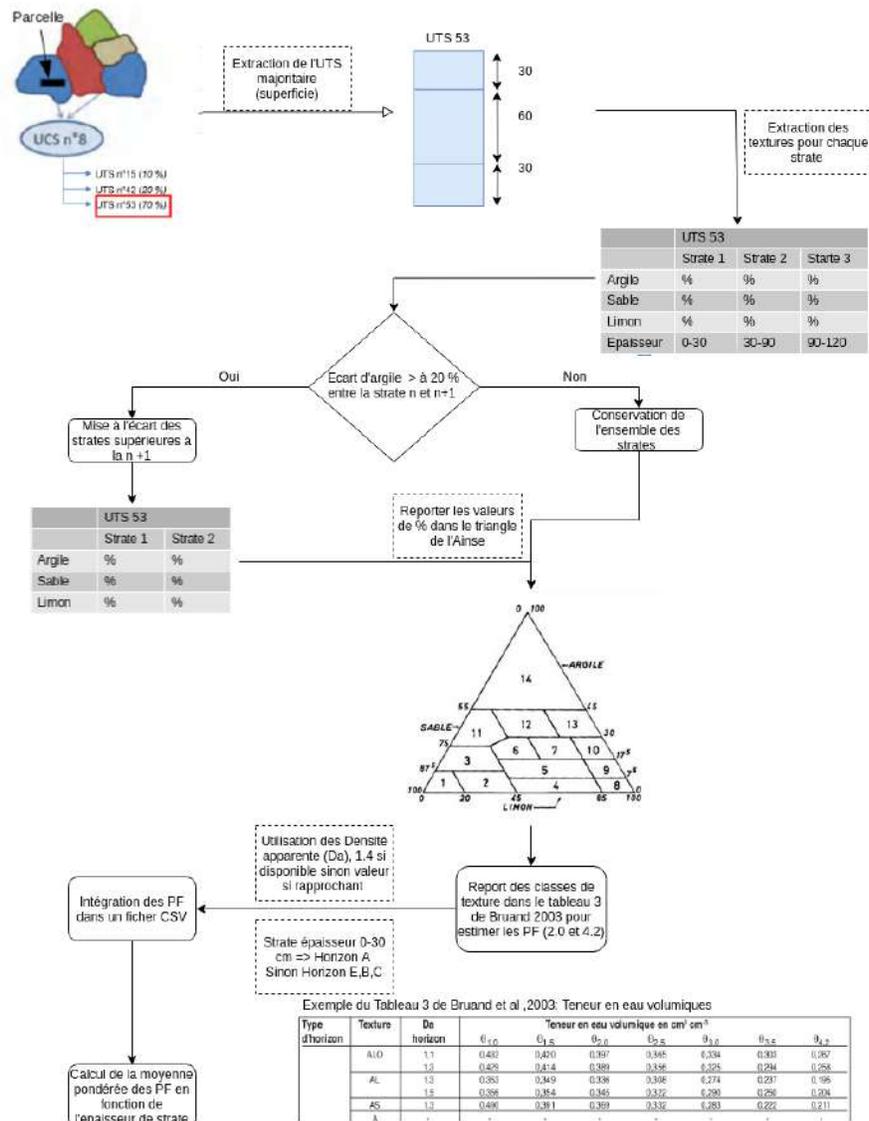


Figure 2.12 – Méthodologie d'extraction de la donnée pédologique

## 2.4 Données des partenaires

### 2.4.1 Données cartographiques

#### 2.4.1.1 Tournées terrain

Les données de références utilisées lors de mes travaux, ont été fournies par les différents partenaires de la thèse sur les deux territoires d'études (Adour Amont et Tarn Aval). Les informations relevées sur les parcelles agricoles sont :

- Présence ou absence de matériel d'irrigation
- Occupation du sol
- Coordonnées des parcelles

J'ai intégré les informations issues des campagnes terrain dans un logiciel de SIG, afin de spatialiser l'information

et récupérer le contour des parcelles en effectuant la correspondance avec le RPG. Les relevés terrains sont réalisés au cours de la saison de croissance des cultures entre le semis (mai) et la floraison (juillet).

**Adour Amont** Le jeu de données de référence comprend 832 parcelles en 2017 (557 irriguées et 275 en culture pluviale) et 942 parcelles en 2018 (680 irriguées et 262 en culture pluviale) comme l'illustre le tableau 2.2. Le maïs irrigué est la culture la plus représentée avec 60 % des parcelles échantillonnées en 2017 et 48 % en 2018. Le soja irrigué est la culture la moins représentée avec seulement 3 % en 2017 et 5,6 % des parcelles échantillonnées en 2018. Ce faible échantillonnage de soja irrigué et pluvial s'explique par la faible représentativité de cette culture sur le territoire (< 10 %). Selon le RPG, la répartition des différentes cultures d'été entre les deux années, augmente légèrement pour le maïs et le soja, mais diminue légèrement pour le tournesol. Les données récoltées représentent 5 % de la superficie totale des cultures d'été sur le territoire. (Voir Annexe : 1).

Table 2.2 – Distribution du jeu de données de référence sur le bassin Adour Amont en 2017 et 2018

Label des classes	Nombre de parcelles		Surface total (en ha)		Répartition (%)		RPG (%)	
	2017	2018	2017	2018	2017	2018	2017	2018
Mais Irrigué	526	639	943	727	60	48.1	82.8	84
Mais Pluvial	198	175	302	500	19.2	33.1		
Soja Irrigué	31	41	54	85	3.4	5.6	8.2	9.6
Soja Pluvial	27	38	77	151	4.9	10		
Tournesol	50	49	120	40	7.6	2.7	8.6	5.5

**Tarn Aval** Sur le Tarn Aval, les deux campagnes terrains ont permis d'échantillonner 357 parcelles en 2017 et 526 en 2018. Le maïs est la culture irriguée la plus représentée avec 40 % des parcelles échantillonnées en 2017 et 28 % en 2018. Le soja pluvial est la culture la moins représentée, avec 5 % en 2017 et 2018. Ce faible échantillonnage de soja irrigué et pluvial s'explique par la faible représentativité de cette culture sur le territoire (< 15 %, selon le RPG), contrairement au maïs qui représente 44 % des parcelles agricoles cultivées en cultures d'été en 2017 et 42 % en 2018. Selon Le RPG, nous constatons sur ce territoire une légère diminution de cultures d'été entre les années 2017 et 2018. Cette diminution est de l'ordre de 2 % pour le maïs et le soja, et de 6 % pour le tournesol. (Voir Annexe : 1)

Table 2.3 – Distribution du jeu de données de référence sur le bassin Tarn Aval en 2017 et 2018

Label des classes	Nombre de parcelles		Surface total (en ha)		Répartition (%)		RPG (%)	
	2017	2018	2017	2018	2017	2018	2017	2018
Mais Irrigué	152	169	530	474	40	28	44	42
Mais Pluvial	29	53	149	279	11	17		
Soja Irrigué	55	93	80	151	6	9	13	11
Soja Pluvial	25	25	65	80	5	5		
Tournesol	96	186	491	700	37	42	53	47

Pour les deux BV, nous constatons que l'échantillonnage réalisé par les partenaires est représentatif de chaque territoire. En effet, la répartition des données terrain en fonction du type de culture est similaire à celle du RPG.

## 2.4.2 Données pour la modélisation

### 2.4.2.1 Parcelle de référence

Une partie des parcelles des partenaires dites de "référence" sont issues du réseau de parcelle suivi par les Chambres d'agriculture. Ce réseau est mis en place par les agences de l'eau et géré par les chambres d'agriculture.

L'objectif de ce réseau est de suivre un certain nombre de parcelles considérées comme représentatives des pratiques agricoles du territoire. Environ 10 parcelles sont sélectionnées, par département. Les données récoltées sur ces parcelles sont les stades phénologiques (épiaison, stade foliaire, floraison, sénescence), la pluviométrie ainsi que l'itinéraire technique (date de semis, dates et doses d'irrigation, travail du sol). Ces données permettent au gestionnaire d'estimer les besoins en irrigation et d'anticiper les potentielles restrictions en eau pour la saison à venir, sur le territoire.

L'autre partie des parcelles de références sont issues de tournées et d'enquêtes terrain réalisées dans le cadre de l'élaboration de la base de données Terres labourables (TerLab). Cette enquête a pour objectif d'estimer les rendements des principales cultures issues de terres labourables (dites aussi "grands cultures") aux niveaux départemental, régional et national. L'enquête est réalisée par sondage auprès d'exploitants agricoles. L'interrogation porte sur la surface et le rendement de l'ensemble des grandes cultures présentes sur l'exploitation, sur la quantité d'eau pour l'irrigation du maïs.

Dans le cadre de mes travaux, nous disposons des données sur le département du Gers (Bassin versant de la Neste), soit un total de 85 parcelles pour l'année 2017 (Figure 2.13).

#### 2.4.2.2 Associations Syndicales Autorisées

Les associations syndicales autorisées (ASA) sont des groupements de propriétaires qui contribuent à l'exercice de diverses missions d'utilité publique, mais aussi privée. Il existe en France de nombreuses ASA pour la plupart liées à l'agriculture. Ces associations réglementées depuis 1865 constituent des piliers essentiels de la politique française en matière de développement de l'irrigation. Les données fournies par ces associations sont agrégées à l'échelle du périmètre irrigué.

Quatre périmètres irrigués ont été étudiés sur le département du Gers : les ASA de Miradoux, de Sainte Marie, de Biran et Saint-Sauvy. Ces ASA étant couverts par les images du satellite Sentinel-2, nous avons pu exploiter 2 années de données, 2017 à 2018 (Figure 2.13).

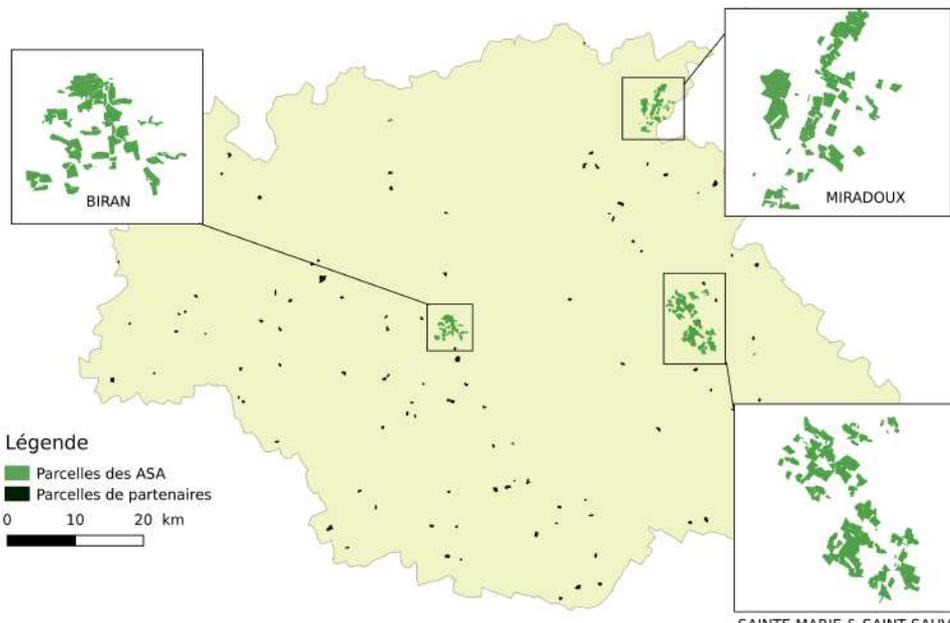


Figure 2.13 – Localisation des différents jeux de données dans le Gers. Les polygones bleus indiquent les parcelles de référence suivies par la CACG. Les limites des parcelles enquêtées sont en noir et les périmètres irrigués (ASA) en vert.

## 2.5 Données de la parcelle expérimentale

### 2.5.1 Données Flux et Pédologique

#### 2.5.1.1 Flux

Une partie des données utilisées dans ma thèse provient de la parcelle expérimentale de Lamothe (LAM). Cette parcelle d'une superficie de 32.3 ha est instrumentée depuis juillet 2004 pour le suivi de la végétation et l'étude des flux turbulents et de la dynamique de l'eau dans le sol. Elle est située au Sud-Ouest de Toulouse, sur la plaine alluviale de la Garonne en bordure du Touch, Elle est situé sur domaine de Lamothe qui est une ferme expérimentale de l'école d'ingénieurs de Purpan (ESAP). Elle appartient au réseau ICOS (Integrated Carbon Observation System) et à l'OSR (Observatoire Spatial Régional) Midi-Pyrénées. Le maïs est cultivé en 2008, 2010, 2012, 2014, 2015 et 2019. Il s'agit de maïs ensilage destiné à l'alimentation de bétail. Il est récolté vert. Les données d'irrigations disponibles sur cette parcelle expérimentale n'ont pas été utilisées pour valider le modèle, car elles sont peu représentatives de celles observées dans la région.

Les instruments mis en place sur la parcelle permettent la mesure de variables météorologiques et micro-météorologiques. Le système permettant de mesurer les fluctuations turbulentes est composé d'un anémomètre sonique 3D (CSAT3) et un analyseur de gaz infrarouge haute fréquence (LI-7500, 20 Hz). Les fluctuations turbulentes de  $CO_2$ , de vapeur d'eau (ETR pour l'évapotranspiration et LE pour le flux de chaleur latente) et de chaleur sensible (H) sont mesurées de façon continue par la méthode d'Eddy-Covariance [109–111]. Les flux sont ensuite calculés avec le logiciel EDIRE (Robert Clement, © 1999, University of Edinburgh, UK). Le calcul des flux, le filtrage, la vérification de la qualité des flux et l'estimation des données manquantes et/ou filtrées sont effectués selon les recommandations de CarboEurope-IP.

Les flux et les données météorologiques sont pré-traités au CESBIO par Aurore Brut (MdC UPS-CESBIO), et fournis à un pas de temps semi-horaire [[https://osr-cesbio.ups-tlse.fr/relevés\\_de\\_terrain.php](https://osr-cesbio.ups-tlse.fr/relevés_de_terrain.php)]. Les données utilisées dans ma thèse sont les flux d'évapotranspiration calculés à partir du flux de chaleur Latente (LE) qui a été moyenné à la journée.

Nous avons également appliqué une correction, par le biais du ratio de Bowen [Équation 2.1]. Cette correction permet d'assurer la fermeture du bilan d'énergie en améliorant l'estimation du flux de chaleur latente (LE), qui a tendance à être sous-estimé par le système d'acquisition eddy-covariance [112, 113].

$$\beta = H/\lambda E \quad (2.1)$$

où

$$\lambda E = (R_n - G_s)/(1 + \beta)$$

Avec  $R_n$ , le rayonnement net en  $W m^{-2}$ ; H, le flux de chaleur sensible en  $W m^{-2}$ ;  $\lambda E$ , le flux de chaleur latente d'évaporation en  $W m^{-2}$ ;  $G_s$ , le flux de chaleur dans le sol en  $W m^{-2}$ .

#### 2.5.1.2 Pédologique

Des mesures d'humidité de sol sont disponibles depuis 2008. Elles sont réalisées à différentes profondeurs (5 cm, 10 cm et 30 cm) avec des sondes CS615 et CS616 de Campbell. Un changement de système de mesure a été effectué en septembre 2011 avec l'installation de nouvelles sondes (ThetaProbe ML2X). Ces sondes ont été installées dans 4 fosses situées à proximité du mât de mesure Eddy-covariance et à six profondeurs : 0-5 cm, 5 cm, 10 cm, 30 cm, 50 cm et 1 m, comme illustré par la figure 2.14.

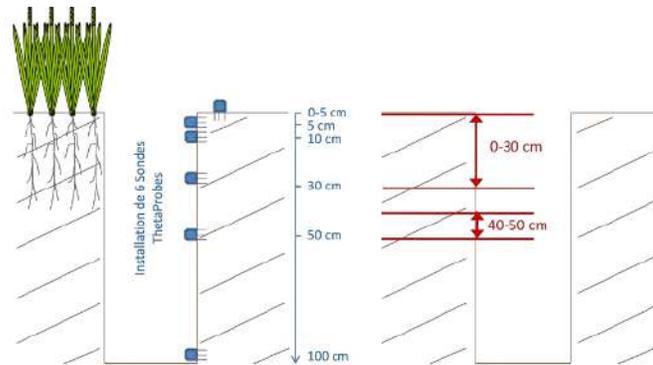


Figure 2.14 – **Dispositif de mesure de l'humidité du sol depuis 2012 (en bleu) et profondeur de prélèvement (en rouge)** (source : Tiphaine Tallec)

Des prélèvements de sol ont été effectués sur 0- 30 cm et 40 -50 cm, afin de caractériser la texture et les propriétés hydriques du sol. La parcelle est caractérisée par un sol profond (environ 1.5 m), argileux (environ 50% d'argile) et peu perméable. Les propriétés hydriques du sol sont présentées dans le tableau 2.4.

Table 2.4 – **Propriétés hydriques du site expérimental de Lamothe à 2 profondeurs**

Profondeur (en mm)	Argile (%)	Limon (%)	Sable (%)	$H_{sat}$ ( $mm^3.mm^{-3}$ )	$H_{fc}$ ( $mm^3.mm^{-3}$ )	$H_{wp}$ ( $mm^3.mm^{-3}$ )
0 - 300	50	36	11	0.558	0.373	0.175
400 - 500	48	35	15	0.531	0.354	0.169

Une étude avait également été menée par l'école de Purpan afin de cartographier la profondeur d'enracinement sur le domaine de la ferme de Lamothe. Cette étude révèle que la parcelle expérimentale présente une profondeur d'enracinement potentielle comprise entre 1 m et 1.5 m (Figure 2.15).

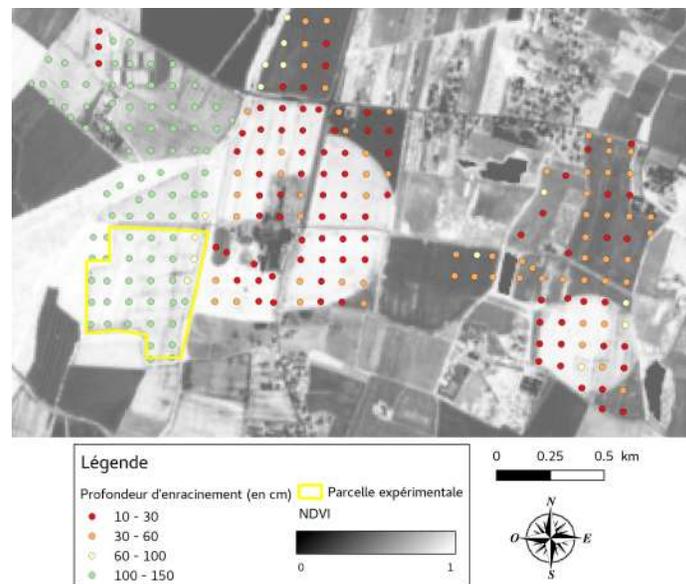


Figure 2.15 – **Carte des mesures de profondeur d'enracinement sur la parcelle expérimentale de Lamothe, relevé effectué par l'ESA Purpan**, Le contour de la parcelle coloré en jaune.

### 3.1 Introduction

La première partie de mon travail de thèse consistait à proposer une approche pour l'estimation des surfaces irriguées sur de grands territoires.

Ce travail avait déjà été initié par Demarez et al, [58] qui ont démontré l'intérêt de coupler les données optique et radar pour la détection des surfaces irriguées en zones tempérées, mais les limites liées à la résolution temporelle et spatiale du capteur utilisé (LANDSAT-8) ont été mises en évidence. Dans le cadre de mes travaux, j'ai donc cherché à améliorer les performances des classifications en couplant des données Sentinel-1 et Sentinel-2, ainsi que de données météorologiques, issue de la base de données SAFRAN [102]. En effet, l'utilisation de données pluviométriques couplées à la donnée de télédétection semble être pertinent pour augmenter les performances des modèles de classification, comme démontré par Peña-Arancibia et al [45] et Chen et al [114]. Cependant, l'utilisation d'images multi-spectrales (optiques et radar) et multi-temporelles conduit à une augmentation du nombre d'images à traiter et, par conséquent, augmente la redondance de l'information spectrale et du temps de calcul. Pour pallier a ces effets, nous avons choisi d'utiliser des indices de végétation et les polarisations SAR que nous avons cumulé mensuellement. L'utilisation des indices cumulés nous a semblé pertinente, car ils sont liés au fonctionnement de la plante, comme démontré par Dong et al, [115] et Keeling et al, [116], et permettent de conserver l'information spectrale, essentielle pour détecter le type d'assolement, soit dans notre cas les cultures d'été : le tournesol, le soja et le maïs, ces 2 dernières étant irriguées. La détection du type d'assolement est essentielle en zones tempérées car les besoins en eau des cultures sont différents, et qu'une même culture peut-être à la fois irriguée ou non, ce qui représente l'un des défis pour cartographier les surfaces irriguées sur ces zones climatiques.

Mon travail a donc consisté à proposer une méthodologie de détection des surfaces irriguées en appuyant sur une méthode de classification robuste et sur le développement phénologique du couvert végétal comme variable explicative. En effet, nous supposons que la vitesse et l'amplitude du développement des cultures diffèrent entre les cultures irriguées et les cultures pluviales. Cette différence phénologique peut s'expliquer par plusieurs événements d'irrigations (4 à 5 irrigations), qui impacte le développement des cultures. Cette différence peut-être ainsi capturée en utilisant les indices cumulatifs sur la saison de croissance.

Une fois la méthode élaborée, celle-ci a été évaluée à deux échelles de temps : le cours de saison et la fin de saison culturale. S'intéresser à ces deux échelles est essentiel pour assurer une gestion optimale de la ressource en eau à l'échelle de territoire. En effet, disposer d'une cartographie des surfaces irriguées en fin de saison permet d'établir un diagnostic et d'identifier les zones sous pression et à fort enjeu. En cours de saison, cette cartographie permet d'estimer la superficie totale de parcelles ayant recours à l'irrigation au cours de la campagne d'irrigation et donc d'estimer au mieux les besoins en eau pour l'agriculture durant les périodes critiques.

Pour valider cette approche, nous avons bénéficié de 2 années (2017 et 2018) de données terrain ayant des conditions climatiques contrastés sur le territoire de l'Adour-Amont. Les performances du modèle de classification ont été évaluées en fonction des différentes source d'information spectrale, par l'intermédiaire des différentes configurations, nommé scénario dans la suite du chapitre. Ce travail a fait l'objet d'une publication [97], incluse dans ce chapitre.

Des travaux complémentaires à ceux de la publication sont également présentés, notamment la validation sur un autre bassin versant (Tarn Aval).

La première partie du chapitre présente les méthodes de classification dédiées à la cartographie de l'occupation du sol sur des larges territoires. Dans cette partie, nous nous sommes focalisés sur les méthodes de classifications supervisées avec une brève présentation de l'algorithme Random Forest. La seconde partie présente la méthode

appliquée au cours de mes travaux avec la présentation de la chaîne de traitement automatique (lota<sup>2</sup>), ainsi que la méthodologie de détection des surfaces irriguées que nous avons développée. La troisième partie, présente les résultats publiés dans MDPI *remote sensing*, qui se sont focalisés sur l'évaluation de la méthode sur le bassin versant Adour Amont et ceux sur deux années. Enfin, la dernière partie du chapitre présente des résultats sur le potentiel de la méthodologie pour détecter les surfaces irriguées en cours de saison, ainsi que sur l'autre bassin versant (Tarn Aval).

### 3.1.1 Modèle de cartographie/classification

Les méthodes de classification couplées à d'images satellitaires permettent de cartographier l'état de surface à un instant donné. L'objectif d'une méthode de classification est de construire un modèle capable de prédire pour chaque pixel de l'image une étiquette, telle qu'une classe d'occupation du sol, de manière automatique à partir de données sans en expliciter les règles. Ces méthodes peuvent être divisées en deux catégories : non-supervisée et supervisée.

**Les méthodes non supervisées** Ces méthodes permettent de regrouper les échantillons similaires au sein d'une même classe sans intervention de données de référence (approche non dirigée). Ces groupes d'échantillons sont communément appelés "clusters" et sont constitués d'échantillons similaires. Le nombre de clusters est fixé en amont par l'utilisateur. Une classe (ou un label) est ensuite affectée a posteriori à chaque cluster par le biais de l'utilisateur. Ces méthodes nécessitent une connaissance experte de la zone d'étude, car l'attribution d'une classe à un cluster est bien souvent une question complexe et fastidieuse. De plus, ces méthodes demandent régulièrement une phase de post-traitement telle que la fusion et/ou la division de clusters, avant de pouvoir attribuer une classe à ce(s) dernier(s). Dans le cadre de la production de cartes d'occupation du sol, les approches non supervisées ont rapidement montré leurs limites [117], du fait d'un nombre de classes trop important et d'une faible différenciation spectrale entre elles, rendant l'interprétation des produits cartographiques difficile et peu fiable.

Ces méthodes ne seront pas utilisées lors de mes travaux.

**Les méthodes supervisées** Ces méthodes consistent à réaliser l'apprentissage d'un modèle à partir d'échantillons (= données de référence) appartenant aux classes que l'on souhaite cartographier (approche dirigée). Les échantillons contenus dans la donnée de référence sont divisés au cours de l'étape d'échantillonnage en deux sous-ensembles : les échantillons d'apprentissage utilisés comme connaissance a priori sur l'occupation des sols et pour établir le modèle de classification et les échantillons de validation servant à évaluer la validité du modèle.

Il existe un grand nombre de méthodes supervisées, les plus communément utilisées pour la cartographie des surfaces irriguées sont : le Support Vector Machine (SVM) [118], la détection de changement [119] et le Random Forest [120]. Les performances de ces dernières varient en fonction de la qualité et de la quantité de données in-situ disponibles. Brocca et al [53] ont proposé une méthode de classification basée sur la détection de changement, mais celle-ci n'a pas pu être validée à une échelle fine, à cause d'un manque de données de validation. La méthode de détection de changement utilisée par Brocca et al [53] et Bazzi et al [55], permet d'obtenir des résultats satisfaisants car elles reposent sur l'utilisation conjointe de données spectrales et météorologiques (pluviométrie / humidité du sol). Néanmoins la basse résolution des données météorologiques entraînant une baisse de performance du modèle lors des périodes de pluies soutenues [43] et une sous-estimation systématique des surfaces irriguées, qui est attribuée à la résolution spatiale grossière des humidités du sol par satellite, qui ne permet pas de résoudre les pratiques d'irrigation locales [54].

Dans le cadre de mes travaux, nous avons choisi de retenir la méthode du Random Forest, car celle-ci présentant de bonnes performances et est robuste, face au manque de données in-situ et à leurs faibles fiabilités [121, 122]. En effet, certains auteurs ont comparé les performances de différentes méthodes de classification pour détecter les surfaces irriguées et les résultats de ces études illustrent d'excellentes performances pour le Random Forest par rapport aux autres méthodes. Gao et al [42], ont comparé le SVM et le RF sur le Nord de l'Espagne et ils ont démontré que le RF avait une précision de bonne classification de 82 % contre 81 % pour le SVM. De la même manière Bazzi et al [59], ont comparé des approches de classification basées sur les réseaux

de neurones (CNN) et le RF pour la détection des surfaces irriguées en climat semi-aride et ils obtiennent des résultats avec le Random Forest du taux de bonne classification de 90 % pour les surfaces irriguées.

En plus de sa fiabilité, de nombreux auteurs ont utilisé cette méthode pour cartographier les surfaces irriguées sous différentes latitudes. Parmi ces auteurs, Ferrant et al [57], qui ont cartographié les surfaces irriguées dans le sud de l'Inde, et ont obtenu des bons résultats, avec un taux de bonne classification de 87% pour le maïs irrigué. Ketchum et al [123], ont utilisé le Random Forest pour cartographier les surfaces irriguées dans l'Ouest des États-Unis et les résultats obtenus par leur approche IrrMapper permet d'obtenir une précision globale de 97,8 %. De la même manière, Zurqani et al [124], ont cartographié les cultures irriguées à partir d'images satellitaires et de l'algorithme Random Forest sur l'est des États-unis. Les résultats obtenues sont de l'ordre de 85 % de précision globale et ceux pour les trois années qu'ils ont étudiées.

### 3.1.1.1 Random Forest (RF)

Le RF proposé par Breiman, [120], est un algorithme de classification supervisé basé sur un ensemble d'arbres de décision indépendants, permettant de construire une règle de décision générique et robuste. Cette méthode permet de réduire la variance des pertitions d'un seul arbre grâce à la combinaison de nombreux arbres de décision dans une approche de type bagging [125, 126]. Le bagging est une technique permettant d'améliorer la stabilité et la précision des algorithmes de classification en minimisant simultanément le biais et la variance des prédictions. La minimisation des deux variables permet de limiter les effets de sur-apprentissage lié à une variance élevée et de sous-apprentissage lié à un biais élevé.

Concrètement, chaque arbre est entraîné sur un sous-ensemble aléatoire de données de référence selon le principe du bagging , avec un sous ensemble aléatoire de primitives, qui sont des images satellitaires dans notre cas, selon le principe de la sélection aléatoire des primitives (*random feature selection*). Les prédictions sont ensuite utilisées pour effectuer un vote majoritaire. Les données de référence non sélectionnées pour l'apprentissage peuvent-être utilisées pour calculer l'erreur Out Of Bag (OOB). Cette erreur permet de comptabiliser le nombre d'erreurs de prédiction commis par le modèle et est un excellent indicateur pour mesurer la capacité de généralisation des algorithmes de classification. Dans l'implémentation utilisée (Shark), la construction des arbres est arrêtée grâce au critère : profondeur maximale  $max_{depth}$ , que nous avons fixé à 25, car cela permet de réduire le sur-apprentissage des arbres, et la complexité algorithmique.

### 3.1.1.2 Procédure de classification automatisée

L'apprentissage du modèle de classification et l'application de celui-ci ne sont que deux étapes parmi le processus de production de carte. En effet, pour faciliter la production de carte à grande échelle, avec un grand nombre de données satellitaires, nous avons utilisé une chaîne de traitement automatisant un maximum d'étape. Cette chaîne de traitement (*Iota*<sup>2</sup> Infrastructure pour l'Occupation des sols par Traitement Automatique Incorporant les Orfeo Toolbox Applications) a été développée au laboratoire CESBio et est disponible sous forme de logiciel gratuit [<https://framagit.org/iota2-project/iota2.git>]. Les étapes incorporées dans la chaîne de traitement sont illustrées en figure 3.1. À ce stade, nous considérons également que les images de télédétection sont prêtes à être utilisées. Ces éléments constituent la base de données Images (images pré-traitées par MAJA). Les données de référence sont également prêtes à l'emploi.

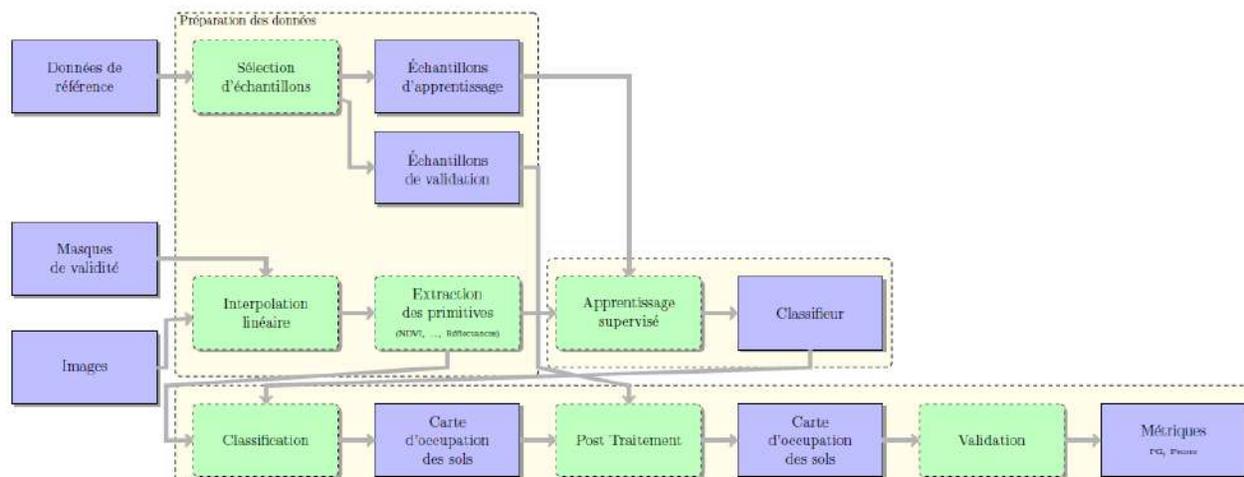


Figure 3.1 – **Diagramme de la chaîne de traitement (IOTA<sup>2</sup>)**. Les carrés bleus illustrent les entrées et sorties des différents algorithmes, et les carrés verts illustrent les différents algorithmes utilisés au cours du processus [illustration d'origine : [Inglada et al. [47]]

La production de carte à partir d'une méthode supervisée, peut-être divisées en deux catégories : 1) Préparation des données satellitaires et de références, 2) Production de la carte. Pour la préparation des données, la première étape consiste à séparer les données de référence en deux lots (Apprentissage et Validation), composés chacun de 50 % des données de référence. Pour les images, les profils temporels sont reconstruits par interpolation linéaire.

Une fois cette préparation des données terminée, l'extraction des échantillons d'apprentissage est réalisée. Au cours de cette étape, chaque échantillon se voit attribuer l'étiquette correspondante issue de la donnée de référence. Cette étape permet de réduire le volume de données à manipuler lors de l'apprentissage, en ne traitant que les échantillons étiquetés. Le choix des échantillons d'apprentissage au sein du lot d'apprentissage se fait, de manière aléatoire. Après l'extraction des échantillons, la phase d'apprentissage permet d'entraîner le classifieur supervisé et de produire un modèle de classification. La phase de production de la carte débute lorsque le modèle est appliqué sur la série temporelle des images interpolées. Les étapes suivantes consistent à appliquer divers algorithmes de post-traitement, tels que de la régularisation, du lissage ou encore l'application d'un masque de culture. Cette carte est alors validée par l'exploitation des données issues du lot de validation qui sont comparées aux décisions du classifieur. Cette comparaison permet de calculer des métriques, qui seront présentées dans la section 3.1.1.3. La validation désigne l'évaluation quantitative des décisions prises par un classifieur. En plus de la carte issue de l'application du modèle de classification, l'algorithme fournit une carte de confiance.

Afin de mesurer la stabilité des méthodes, mais aussi la différence significative entre deux approches, et ainsi définir une marge de performances, nous avons utilisé les différents tirages aléatoires de données de référence, pour calculer des intervalles de confiance à 95 %. Un intervalle de confiance est centré sur la moyenne des valeurs mesurées, et indique les limites maximales entre lesquelles 95 % des mesures sont représentées.

### 3.1.1.3 Validation de la classification

**Matrice de confusion** La validation des méthodes de classification est présentée sous la forme d'une matrice de confusion [127]. Une matrice de confusion confronte les prédictions du classifieur (en colonne) avec la réalité connue sur les échantillons de référence (en ligne), ce qui donne la représentation telle que présentée dans la figure 3.2. À partir de cette matrice, plusieurs métriques peuvent être calculées.

		Prédite		
Réelle		2	1	0
		0	3	1
		1	1	2

Figure 3.2 – **Matrice de confusion théorique issue de Pelletier et al [128]**, Les couleurs correspondent aux classes labellisées et classées. Les nombres indiqués sur la diagonale correspondent au nombre de pixels correctement classés. Les autres nombres en dehors de la diagonale expriment les confusions entre les classes.

**Validation globale** Les métriques utilisées pour évaluer la précision de la classification sont : la précision globale (Overall Accuracy en anglais) et le Coefficient Kappa. La précision globale (OA), est le nombre total de pixels correctement classés par rapport au nombre total de pixels de référence [127]. Le coefficient Kappa (Équation 3.1), correspond à une réduction proportionnelle de l'erreur obtenue par une classification  $P_o$ , comparée à l'erreur obtenue par une classification aléatoire,  $P_e$ . Un Kappa de 0,75 signifie que 75 % de la classification ne sont pas dus au hasard [129, 130]. Les indices globaux (OA et Kappa) sont sensibles aux déséquilibres entre les classes, en particulier pour les classes majoritaires qui ont un poids plus important dans le calcul de la précision globale. Pour éviter, un éventuel biais introduit par les classes majoritaires, il est important d'analyser les performances de la classification pour chaque classe.

$$Kappa = \frac{P_o - P_e}{1 - P_e} \quad (3.1)$$

$$\text{avec } P_o = \frac{1}{n} \sum_{i=1}^r n_{ii} \text{ et } P_e = \frac{1}{n^2} \sum_{i=1}^r n_i n_i,$$

**Validation par classe** Pour cela, deux métriques sont utilisées : le rappel et la précision. Le rappel représente le nombre de pixels affectés par le classifieur à la classe  $i$  par rapport au nombre de pixels de référence appartenant à la classe  $i$ .

$$Rappel = \frac{n_{ii}}{\sum_{j=1}^N n_{ij}} \quad (3.2)$$

La précision d'une classe représente le pourcentage de pixels d'une classe correctement classé par le modèle par rapport à l'ensemble des prédictions réalisées pour cette classe :

$$Precision = \frac{n_{ii}}{\sum_{j=1}^N n_{ji}} \quad (3.3)$$

J'ai également utilisé le Fscore par classe. Cette métrique correspond à la moyenne harmonique de ces deux indices :

$$Fscore = 2 \times \frac{Precision \times Rappel}{Precision + Rappel} \quad (3.4)$$

#### 3.1.1.4 Carte de confiance

Le modèle génère également une cartographie illustrant la fiabilité de la décision prise par l'algorithme pour chaque pixel de l'image. Cette fiabilité est estimée à partir de la distribution des probabilités de chaque classe pour chaque pixel. Étant donné que l'attribution d'une étiquette est effectuée par vote majoritaire, nous pouvons estimer la fiabilité de la décision en utilisant la probabilité de la classe majoritaire. Inglada et al [131] ont illustré la corrélation entre confiance et la qualité de la classification et leurs conclusions sont que des valeurs de confiance supérieures à 60 % illustrent une forte probabilité d'obtenir une estimation correcte et lorsque la confiance est

supérieure à 80 %, la probabilité d'une estimation correcte est 20 fois supérieure à une estimation erronée. Ces mêmes auteurs ont décrit la méthode d'estimation de la carte de confiance.

## 3.2 Méthodologie de classification

La figure 3.3 illustre la démarche méthodologique utilisée au cours de mes travaux. Celle-ci est composée de 4 étapes : (1) pré-traitement des images, qui permet le calcul d'indices mensuels cumulés à partir de séries temporelles, (2) classification des pixels basée sur les indices mensuels cumulés, (3) post-traitement des classifications, dans le but de supprimer les pixels isolés, et (4) validation des cartographies des surfaces irriguées et pluviales à partir des différentes métriques, présentées dans la section 3.1.1.3.

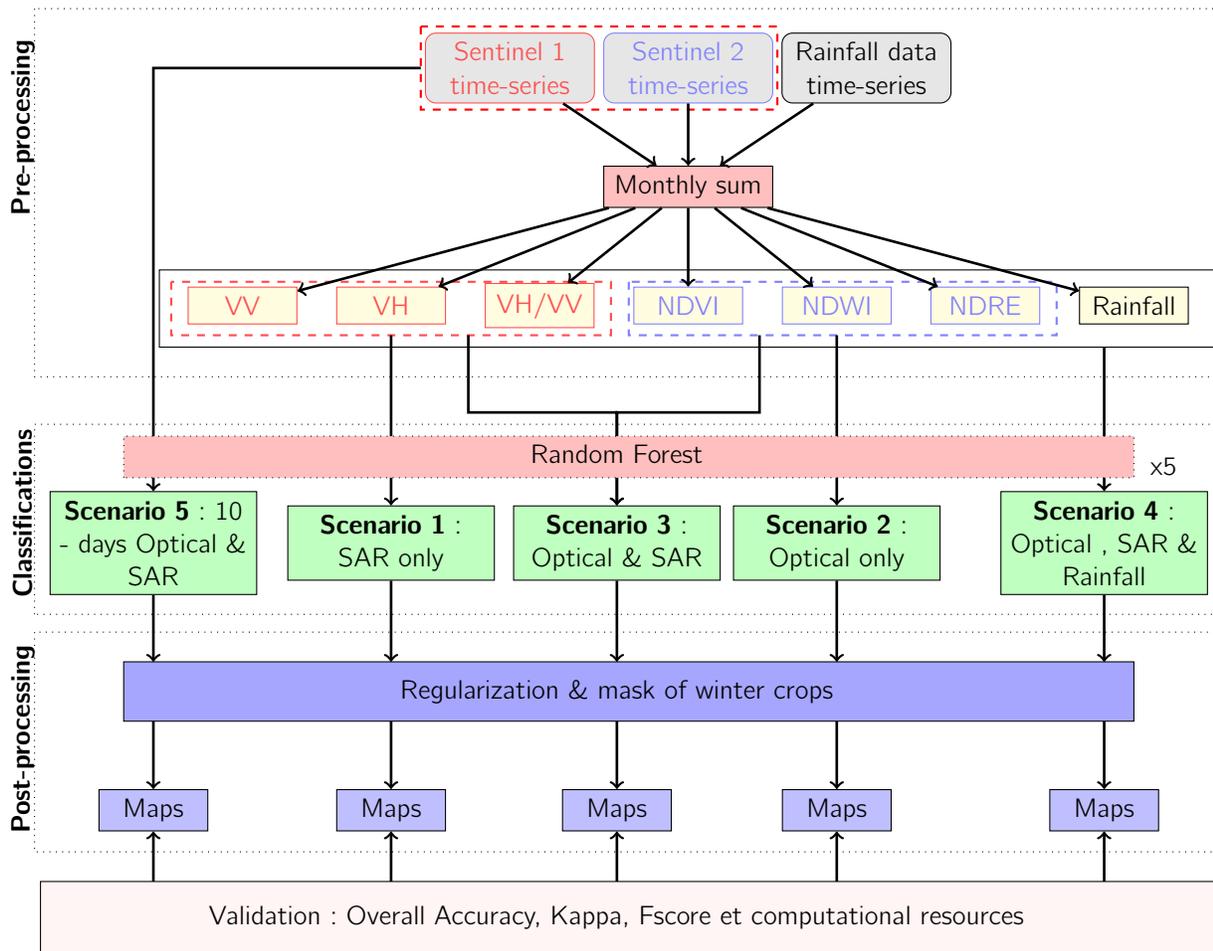


Figure 3.3 – **Organigramme de la méthodologie.** Les carrés gris représentent les données initiales. Les carrés jaunes sont les images des indices cumulés mensuellement après traitement par l'algorithme, qui est représenté par un carré rouge. Les carrés verts correspondent aux différents scénarios testés. Les carrés bleus représentent les différentes cartes des classificateurs, c'est-à-dire les classifications et les cartes de confiance.

### 3.2.0.1 Pré-traitement des images

Les images Sentinel 1 & 2 sont, dans un premier temps, corrigées des effets atmosphériques par la chaîne MAJA et S1-tilling, présenté dans la section 2.2.1.3. Suite à cette correction, les images sont interpolées linéairement via l'algorithme "Gapfilling" de la librairie d'Orfeo Toolbox 6.7 [132]. Ce ré-échantillonnage temporel

repose sur une interpolation linéaire pondérée en fonction de la distance des dates d'acquisition claires des satellites optiques en tenant compte des masques des nuages et d'ombres des nuages. Ce ré-échantillonnage temporel est nécessaire pour étudier de très grandes zones, car il limite l'impact des fauchées des satellites, des nuages et de leurs ombres. [47, 131]. Cette interpolation linéaire a été évaluée et validée sur 12 sites à travers le monde par Inglada et al, [47]. Cette étude a démontré qu'aucune différence statistiquement significative n'est observable sur les résultats des classifications lorsque l'on interpole linéairement les données satellitaires. Une fois l'ensemble des images interpolées à un pas régulier de 10 jours, nous avons procédé au choix et au calcul des indices de végétation optiques et des polarisations SAR.

### 3.2.0.2 Dynamique spectrales des cultures étudiées

**Optique** Le choix des indices spectraux est basé sur la littérature. Ceux retenus sont le "Normalized Difference Vegetation Index" (NDVI), le "Normalized Difference Water Index" (NDWI) et le "Normalized Difference Red-Edge" (NDRE). Ces indices ont été retenus, car ce sont les plus couramment utilisés et présentent de bonnes performances dans les études de cartographie des couverts agricoles [131, 133, 134]. De plus, ils permettent de caractériser le développement végétal avec une sensibilité à la fraction du couvert végétal vert [135, 136], à la teneur en eau des plantes [137] et aux pigments foliaires [138, 139]. La figure 3.4 illustre la dynamique du couvert végétal pour chaque culture étudiée. Une différence significative est observée au moment de la croissance maximale, ( $NDVI > 0.8$  et  $NDWI < -0.40$ ). Elle diminue dans la phase de sénescence. Le cycle de croissance est assez synchrone pour toutes les cultures, comme le montre le tableau 3.1. Pour le tournesol, le cycle de croissance est différent de celui des autres cultures, avec des pics de croissance plus faible qui s'explique par le fait que cette culture n'est pas irriguée.

Table 3.1 – **Calendrier théorique des cultures d'été étudiées**, Les carrés verts illustrent la période théorique où la culture est semée, et les carrés bruns la période où la culture est récoltée.

Année de culture												
	Jan.	Fév.	Mars	Avril	Mai	Juin	Jul.	Août.	Sept.	Oct.	Nov.	Déc.
Maïs												
Soja												
Tournesol												

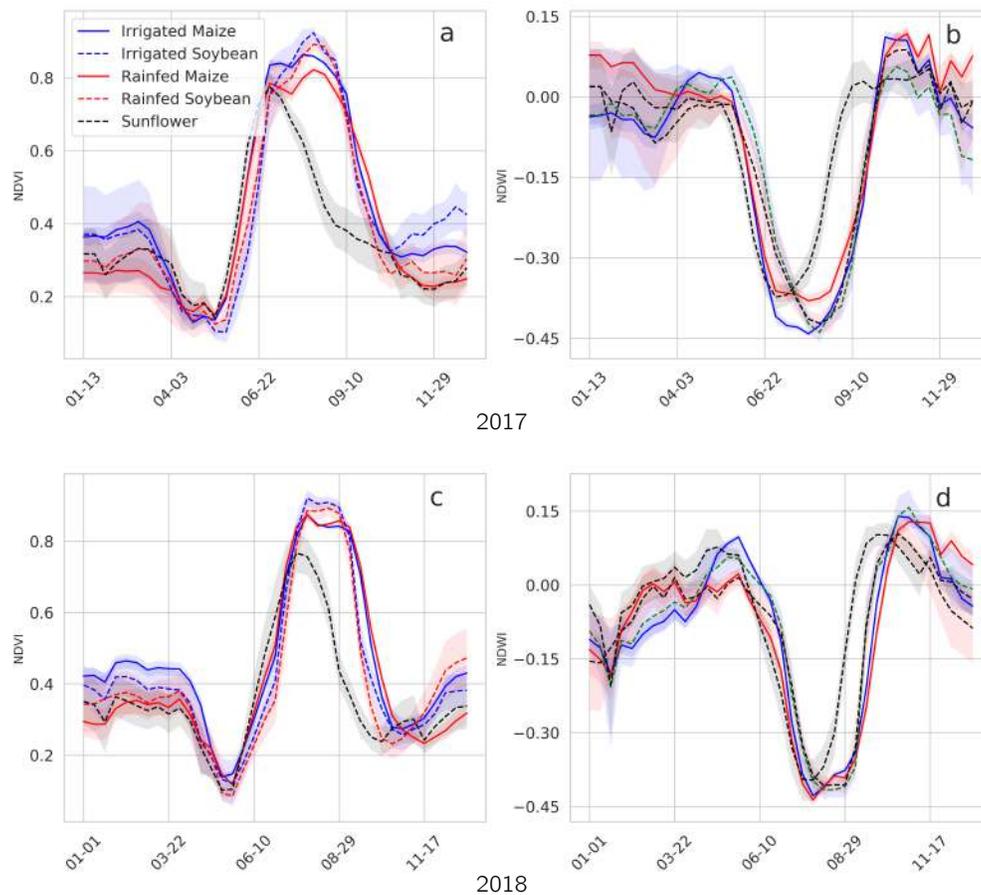


Figure 3.4 – **Dynamique des indices optiques (NDVI [a et c] et NDWI [b et d]) pour les cultures de maïs, de soja et de tournesol**, Les courbes en trait plein représentent le maïs, la ligne pointillée représente le soja, avec le bleu irrigué et le rouge pluvial pour les deux cultures. La courbe noire représente le tournesol. L'enveloppe autour des courbes correspond à l'intervalle de confiance à 95 %.

**Radars - SAR bande C** Les polarisations SAR (VV et VH), ont été utilisées dans la classification, car elles sont respectivement sensibles à l'humidité du sol en surface [140–142] et au volume de la végétation [140, 143]. Comme les profils temporels de rétro-diffusion du SAR dans les deux polarisations sont bruités par des facteurs environnementaux, tels que la pluviométrie, la rugosité du sol, nous avons utilisé le rapport VV/VH qui lisse partiellement ces effets. La dynamique des polarisations SAR diffère entre les cultures pluviales et irriguées, comme le montre la figure 3.5. Cette différence est plus marquée tout au long de la saison que pour les indices optiques. Des fortes variations du signal observable en début d'année (janvier jusqu'à mars), sont principalement causées par le travail du sol et les précipitations. Fin mai, une forte diminution du signal est observable sur les deux polarisations, cette chute est liée à la mise en place de la culture, soit le début de développement foliaire, et s'explique principalement par une modification de la géométrie du couvert [144]. Une fois le couvert développé, des différences significatives sont observables entre les cultures et cela avec les deux polarisations. En effet, comparé aux indices optiques, la dynamique des polarisations SAR, n'est pas synchrone entre les cultures, avec une faible variation du signal pour le maïs et une forte augmentation du signal VV et VH pour le soja lors de la phase de croissance de la culture. Pour le tournesol, nous observons que le cycle de croissance est différent de celui des autres cultures, avec un décalage temporel du pic de croissance et une amplitude plus importante, observable sur le signal VH. Concernant, la distinction des pratiques agricoles au sein d'une même culture, nous constatons quelques différences entre les deux pratiques lorsqu'il n'y a pas d'événements pluvieux, mais ces différences ne semblent pas être significatives pour le maïs. En effet, la polarisation VV sensible à l'humidité

du sol, ne permet pas d'identifier nettement si la culture est irriguée ou non, malgré de faibles précipitations, comme illustré sur la figure 3.5a, où les précipitations sont quasi nulles au mois de juillet. En revanche pour le soja, cette distinction semble être possible avec la polarisation VV en fin de croissance. Pour la dynamique du ratio des deux polarisations SAR (VV/VH), celle-ci est similaire aux deux autres polarisations et est observable en annexe 2.

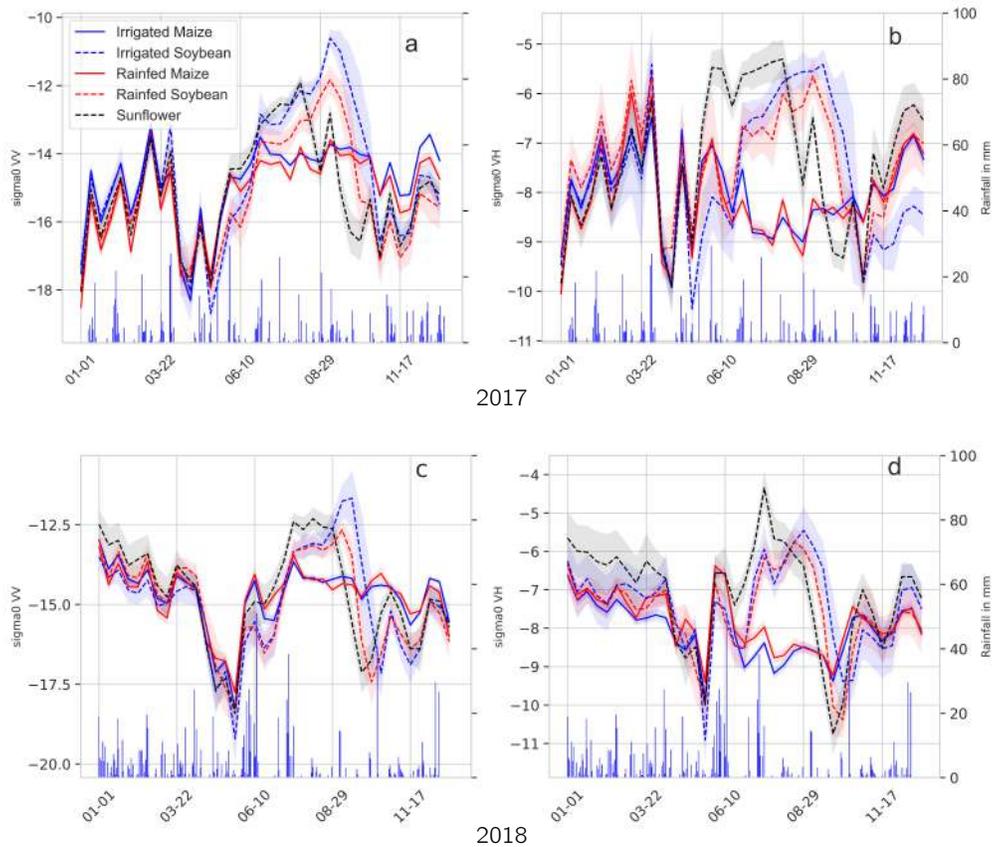


Figure 3.5 – **Dynamique des polarisations SAR (VV [a et c] et VH [c et d]) pour les cultures de maïs, de soja et de tournesol.** Les courbes en trait plein représentent le maïs, la ligne pointillée représente le soja, avec le bleu irriguée et le rouge pluviale pour les deux cultures. La courbe noire représente le tournesol. L'enveloppe autour des courbes correspond à l'intervalle de confiance à 95 %.

### 3.2.0.3 Calcul des cumuls

Lorsque les indices spectraux sont calculés pour chaque image interpolée, un cumul (=somme) mensuel est effectué. La figure 3.6 illustre la dynamique temporelle des indices de végétation NDVI, NDWI et des polarisations SAR (VV et VH) cumulées pour l'ensemble des cultures étudiées. Nous observons sur les indices optiques que la dynamique cumulée du tournesol est significativement différente des autres cultures, avec pour le NDWI, l'apparition d'un plateau au mois d'août, ce qui illustre l'arrêt de la croissance du couvert et le début de sénescence. Pour les autres cultures, la séparation des classes via les indices optiques n'est pas significative, seul le maïs irrigué possède une dynamique plus importante que les 3 autres cultures. Pour assurer la séparation des cultures et des pratiques, les polarisations SAR cumulées semble être intéressantes. En effet, le soja (ligne noire et verte) possède des valeurs plus importantes que le maïs dès le mois de juin pour VV. Et pour VH, nous constatons que le soja irrigué possède une dynamique cumulée supérieure aux autres cultures mais cette différence n'est pas significative. Cette différence semble venir de l'irrigation et de la géométrie du couvert (structure plus dense que le maïs). Pour l'année 2018, les dynamiques cumulées sont observables en annexe 3.

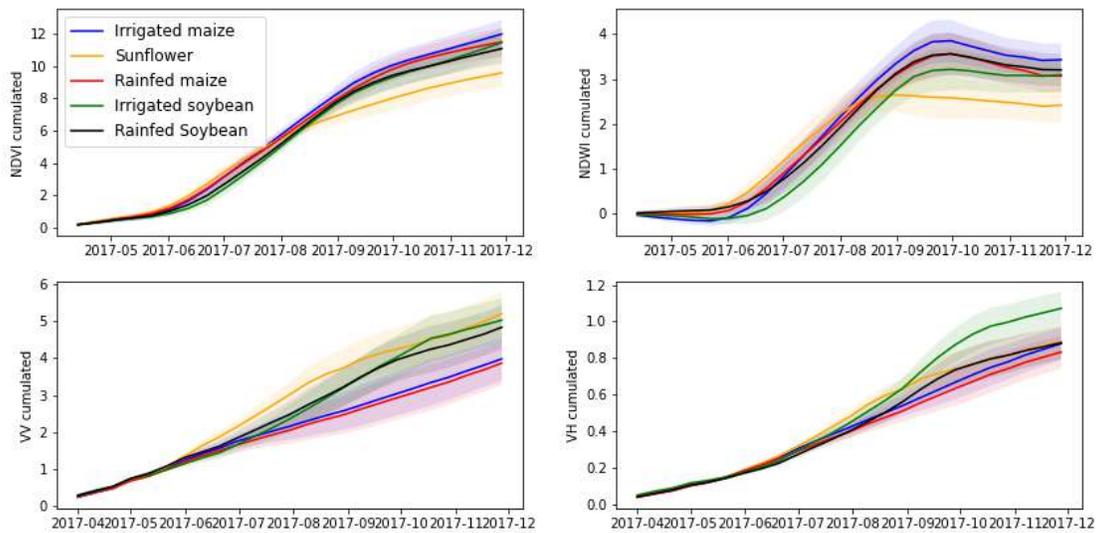


Figure 3.6 – **Dynamique temporelle des indices cumulés (NDVI, NDWI, VV, et VH) pour toutes les cultures en 2017.** La courbe bleue illustre la dynamique du maïs irrigué, celle en jaune du tournesol. Le maïs pluvial est représenté par une courbe rouge, le soja irrigué par une courbe verte et le soja pluvial par courbe noire

### 3.2.1 Classification

Pour produire l'ensemble des résultats, le classifieur Random Forest a été utilisé via la chaîne de traitement *IOTA*<sup>2</sup>, mentionné dans la section 3.1.1.2. La bibliothèque Random Forest utilisée est celle fournie par Shark [145] disponible via le cadre de classification supervisée de Orfeo Toolbox 6.7 [132]. Le classifieur a été paramétré en fonction de la littérature, avec un nombre d'arbres fixé à 100, la profondeur maximale à 25 et les caractéristiques maximales à  $\sqrt{\text{nombre de caractéristiques}}$ . Afin d'obtenir des résultats comparables, chaque classification a été évaluée en utilisant les données de référence, qui ont été divisées de manière aléatoire en deux lots : 50 % des parcelles ont été utilisées pour la phase d'apprentissage et 50 % ont été utilisées pour la validation. Cette division en deux lots permet une estimation optimiste de la performance de la classification, car elle garantit que les pixels d'une même parcelle ne seront pas utilisés pour l'entraînement et la validation. Cette séparation en deux lots est effectuée pour chaque classification, mais reste identique. Les classificateurs RF peuvent avoir de mauvaises performances lorsque le nombre de pixels d'entraînement pour chaque classe n'est pas équilibré. Pour remédier à ce problème, le nombre maximum de pixels d'entraînement par classe a été limité à 10 000. La limitation du nombre maximum de pixels réduit également le temps d'entraînement du classificateur. Pour les classes où le nombre de pixels disponibles était inférieur, tous les pixels d'apprentissage ont été utilisés. Dans notre cas, les classes de soja (irrigué et pluvial) avaient moins de 10 000 pixels d'apprentissage, car cette culture est peu présente sur le territoire.

### 3.2.2 Post-Traitement et Validation

Une régularisation a été appliquée à la classification finale afin de supprimer les pixels isolés. Cette procédure permet de filtrer l'image classifiée en utilisant le vote majoritaire dans une fenêtre de  $3 \times 3$ . Le vote majoritaire prend la valeur la plus représentée au sein de la fenêtre et attribue celle-ci au pixel central [132]. Les cultures d'hiver ont également été masquées en utilisant le RPG de l'année étudiée. Suite à cette étape de post-traitement, les classifications ont été validées grâce aux différentes métriques présentées dans la section 3.1.1.3. La section suivante illustre les performances de la classification basée sur les cumuls mensuels d'indices spectraux et de données météorologiques sur le bassin versant Adour Amont.

Pour les deux autres bassins versants étudiés, nous n'avons pas assez de données de référence pour évaluer

de manière robuste notre méthode de classification. Néanmoins nous avons effectué une classification sur le bassin versant du Tarn Aval, afin d'évaluer la robustesse de la méthode face au manque de données de référence et sur un autre territoire. Pour le bassin de la Neste, aucune classification n'a été effectuée car les données de référence transmises par les partenaires ne possédaient pas l'information irriguée ou pluviale à la parcelle, et donc ces données ne pouvaient pas être utilisées dans une méthode supervisée dont l'objectif est d'identifier les parcelles irriguées et pluviales.

### 3.3 Publication – Résultats présentés

#### 3.3.1 Scénarios

Plusieurs scénarios ont été évalués :

- Scénario 1 : avec des primitives SAR cumulées mensuelles uniquement (VH, VV, VH/VV) référencées comme "SAR" dans la figure 3.3,
- Scénario 2 : avec les primitives cumulées mensuelles de Sentinel 2 uniquement (NDVI, NDRE, NDWI) référencées comme "Optical" dans la figure 3.3,
- Scénario 3 : avec les primitives optiques et SAR cumulées mensuellement référencées comme "Optical & SAR" dans la figure 3.3,
- Scénario 4 : scénario 3 avec en plus les précipitations cumulées référencées comme "Optique, SAR & Rainfall" dans la figure 3.3,
- Scénario 5 : avec les primitives Optique & SAR toutes les 10 jours, caractéristiques référencées comme "10- days Optical & SAR" dans la figure 3.3.

Le nombre total de primitives sur toute la période d'étude de chaque scénario est indiqué dans le tableau 3.2.

Table 3.2 – **Résumé des différents scénarios testés, avec le nombre de primitives sur la période d'avril à novembre.**

	ID	Scénario	Nombre de primitives
Cumulé	1	SAR seul	24
	2	Optique seul	24
	3	Optique et SAR	48
	4	Optique , SAR et Pluie	56
Non cumulé	5	10- jours Optique & SAR	385

Le temps de traitement sur le processeur d'un ordinateur ou Central Processing Unit (CPU) et la mémoire vive (RAM) allouée ont également été analysés afin de définir un compromis entre la performance du classificateur et l'utilisation des ressources de calcul. Cette évaluation a été réalisée pour les deux étapes du processus de classification : l'apprentissage du modèle et l'étape de classification, soit l'application du modèle sur la série temporelle.

#### 3.3.2 Performance globale pour chaque scénario

Les performances globales des classifications sont présentées dans la figure 3.7. Les meilleurs résultats sont obtenus avec le scénario de 10 jours, suivi du scénario cumulé utilisant les primitives optiques, SAR et les précipitations. Les scénarios utilisant une seule source de données (Optique seul et SAR seul) conduisent à des performances globales faibles par rapport aux autres scénarios, en particulier celui basé uniquement sur les

Table 3.3 – Nombre de pixels pour l'apprentissage et la validation du modèle, pour chaque classe et pour chaque année

Classe	2017		2018	
	Apprentissage	Validation	Apprentissage	Validation
Mais Irrigué	10000	51731	10000	33651
Mais Pluvial	10000	12606	10000	24899
Soja Irrigué	3388	2173	3844	4973
Soja Pluvial	3461	4437	7319	7464
Tournesol	6502	4853	2173	1662

données SAR, avec une précision globale inférieure à 0.65. et un Kappa < 0.4. Cependant, nous devons noter que les valeurs Kappa ( $\approx 0,6$ ) sont assez faibles même pour la meilleure configuration.

Au vu des performances du scénario 10 jours, l'utilisation des cumuls ne semble pas être pertinente. Cependant, les classifications avec indices cumulés conduisent certes à des performances globales plus faibles, mais elles permettent de réduire significativement l'utilisation de la RAM et le temps CPU, comme le montre le tableau 3.7. La RAM est réduite d'un facteur 2 pour la phase d'apprentissage. Le temps CPU est réduit d'un facteur 2 pour l'étape d'apprentissage et d'un facteur 4 pour l'étape de classification. Par conséquent, ce scénario peut être considéré comme un bon compromis entre la précision et les ressources de calcul.

Pour la suite de l'analyse, nous avons retenu les scénarios combinant les caractéristiques optiques et SAR (scénarios 3, 4 et 5), qui étaient censés être plus robustes aux diverses conditions météorologiques.

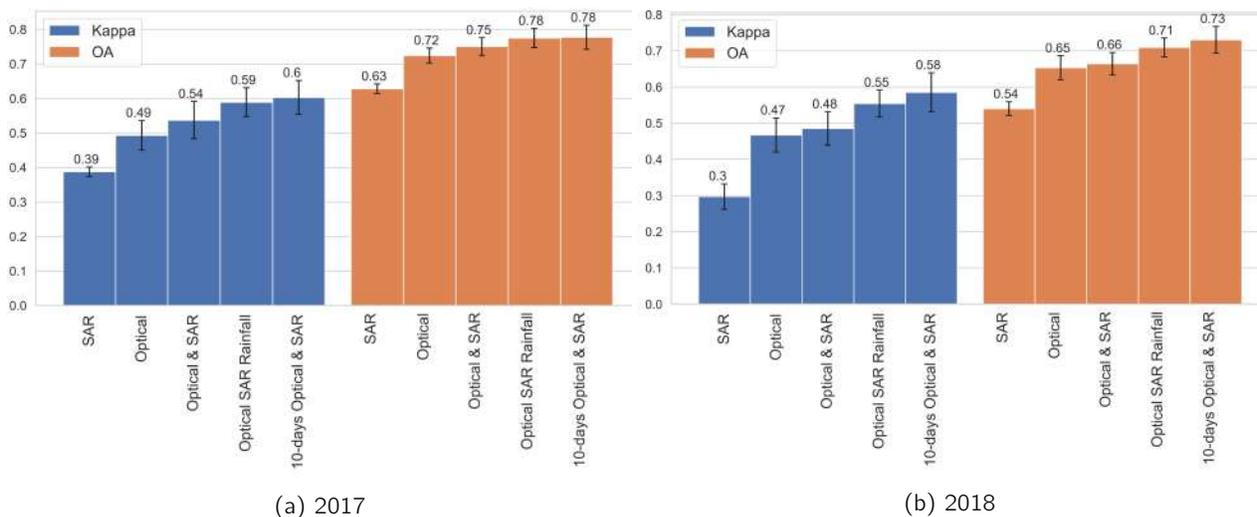


Figure 3.7 – Performance globale pour chaque scénario. Les barres orange et bleu correspondent respectivement à la précision globale et au Kappa. La figure 3.17a illustre les résultats obtenus en 2017 et la figure 3.17b correspond à ceux obtenus en 2018 sur l'Adour Amont.

Table 3.4 – **Ressources informatiques pour les étapes d'apprentissage et de classification, pour chaque scénario.** Le temps CPU correspond au temps de calcul sur un processeur nécessaire pour produire le résultat. La RAM exprimée en Gigabites correspond à la quantité de mémoire vive nécessaire pour obtenir le résultat.

Scénario	ID	Nb. de primitives	Temps CPU (en heures)		RAM (en GB)	
			App. du modèle	Classif.	App. du modèle	Classif.
SAR	1	24	4.5	176	0.21	19
Optique	2	24	2.2	150	0.14	19
Optique & SAR	3	48	4.5	181	0.23	21
Optique SAR et Pluie	4	54	3.5	164	0.22	21
10-jours Optique & SAR	5	385	6.6	739	0.57	22

### 3.3.3 Fscore

La figure 3.8 montre les Fscores pour les 3 scénarios. Les meilleures performances sont observées pour le tournesol pour les deux années (Fscore > 0,9), le maïs irrigué en 2017 (Fscore > 0,85) et le soja irrigué en 2018 (Fscore > 0,68). Les scores les plus bas sont observés pour le soja irrigué en 2017 ( $0,28 < \text{Fscore} < 0,4$ ). Des scores intermédiaires (0,4 à 0,8) sont observés pour le maïs pluvial et le soja pluvial. Nous observons en 2018, une augmentation des performances pour les cultures pluviales et une baisse de celles-ci pour les cultures irriguées. Cette tendance est significative pour le maïs irrigué et le soja. Concernant l'ajout des précipitations, nous constatons une légère augmentation des Fscores pour toutes les classes, mais celle-ci n'est pas significative. Excepté pour le tournesol, l'ajout des précipitations dans la méthode cumulative (scénarios 3 et 4) n'améliore pas le Fscore, néanmoins les performances sont comparables au scénario de 10 jours (scénario 5). L'annexe 4 illustre le résultat cartographique des classifications pour les deux années étudiées.

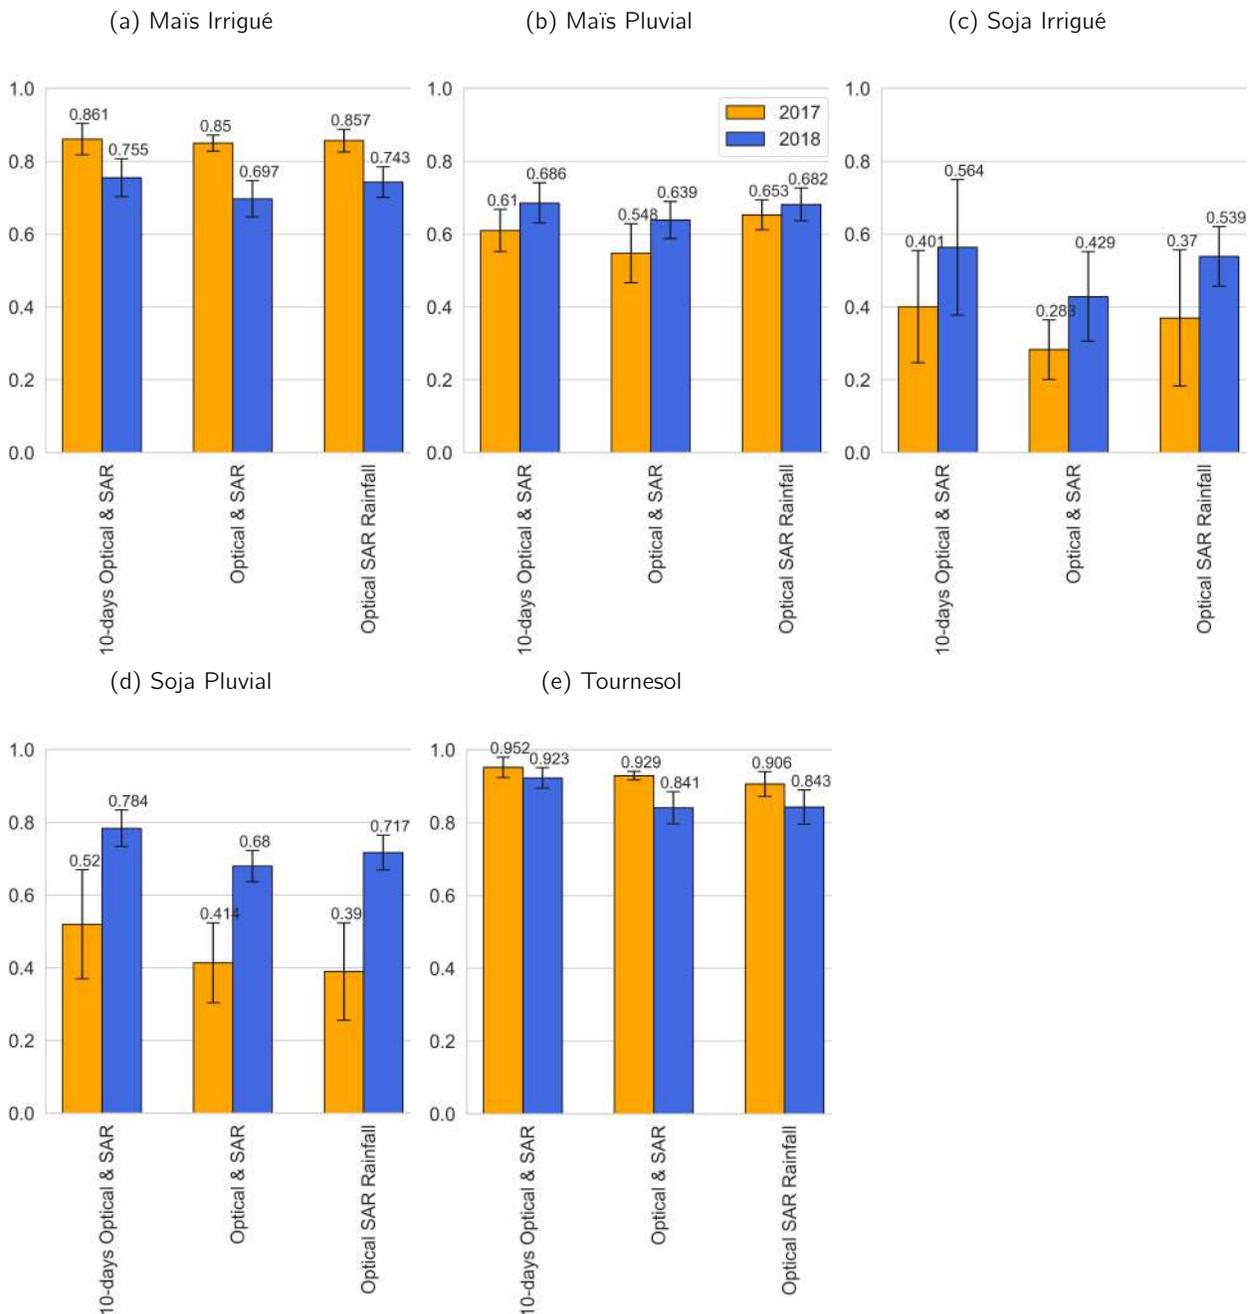


Figure 3.8 – Fscore par classe en fonction des 3 scénarios , Les barres orange et bleu correspondant respectivement aux années 2017 et 2018

### 3.3.4 Analyse de la confusion entre les classes

La confusion entre les classes a été analysée pour les 3 scénarios. La figure 3.9 illustre le pourcentage de confusion entre les classes pour les deux années, c'est-à-dire le pourcentage d'erreur de prédiction commis par le modèle de classification.

Pour les deux années et quel que soit le scénario, on observe une confusion entre les pratiques (irriguées et pluviales) au sein d'une même culture. Les confusions les plus fortes (30 à 50%) sont observées en 2017 entre le soja irrigué et le soja pluvial (Figure 3.9b et 3.9d) comme on l'observe sur les valeurs de Fscore (Figure 3.8). Les

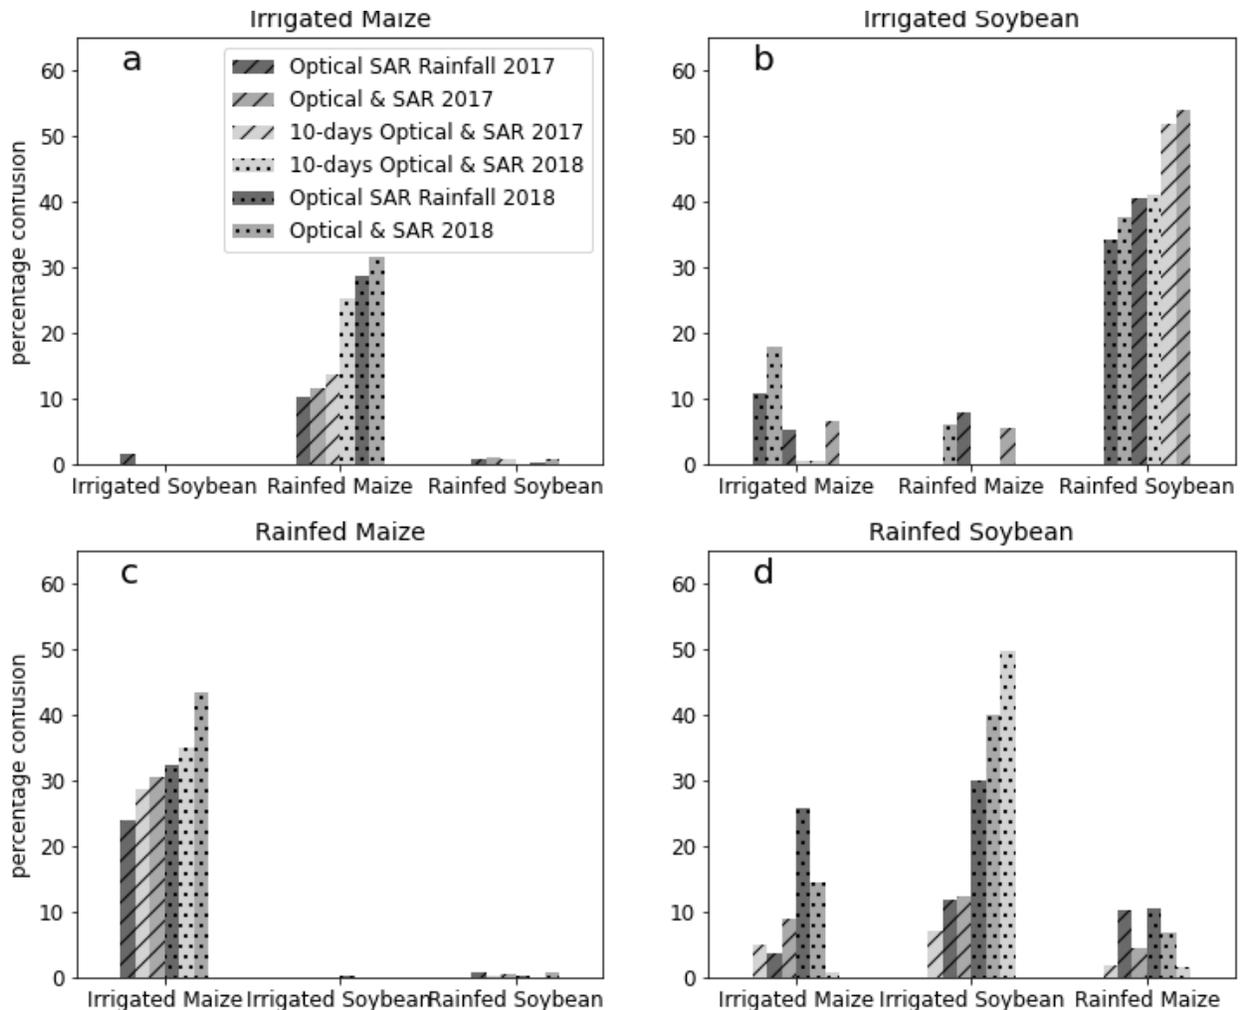


Figure 3.9 – **Confusion selon les scénarios.** Le titre de chaque sous-graphe correspond à la classe réelle et les étiquettes de l'axe horizontal font référence aux classes prédites.

confusions les plus faibles sont observées entre le maïs irrigué et le maïs pluvial, pour les deux années, avec des pourcentages de confusion variant de 10 à 30 %, (Figure 3.9a et 3.9c). L'utilisation des données pluviométriques permet de réduire ces confusions et ceux pour toutes les cultures. En effet, les pourcentages de confusion sont presque systématiquement inférieurs pour le scénario 4 par rapport à ceux obtenus pour le scénario 3.

### 3.3.5 Carte de confiance

La figure 3.10 montre l'indice de confiance pour chaque pixel pour les scénarios 3 (figure a) et 4 (figure b) en 2017 (voir annexe 5 pour 2018). Le meilleur indice de confiance pour toutes les classes combinées est celui du scénario 4 pour les deux années. En effet, la confiance moyenne est de 69,5%  $\pm$ 8% pour le scénario 4 contre 63%  $\pm$ 10% pour le scénario 3 en 2017 et 63%  $\pm$ 10% et 72,10%  $\pm$ 7% pour les scénarios 3 et 4 respectivement en 2018. Nous voyons également dans la figure 3.10 que certaines régions, comme le Nord-est, ont encore un faible niveau de confiance malgré l'ajout des précipitations. Ces zones restent difficiles à classer pour le modèle. Le tableau 3.5 indique le pourcentage moyen de confiance pour chaque classe. Le maïs (irrigué et pluvial) a le niveau de confiance le plus élevé pour les deux années. Le soja irrigué et le soja pluvial ont le niveau de confiance le plus faible pour les deux années étudiées. Pour le tournesol, une diminution de la confiance est observée entre les années 2017 et 2018. Cette diminution de la confiance est due à une chute significative des Fscores entre ces

deux années, comme illustré dans la section 3.3.3 et à une diminution du nombre d'échantillons de référence.

Table 3.5 – **Confiance moyenne pour les années 2017 et 2018, avec les écarts types associés, exprimés en %**

Classe	2017		2018	
	Scénario 3	Scénario 4	Scénario 3	Scénario 4
Maïs irrigué	73 ± 10	84 ± 8	70 ± 10	84 ± 7
Maïs pluvial	70 ± 11	78 ± 9	62 ± 10	72 ± 11
Soja irrigué	55 ± 11	61 ± 11	64 ± 12	65 ± 12
Soja pluvial	53 ± 12	62 ± 14	56 ± 11	59 ± 9
Tournesol	89 ± 8	92 ± 4	56 ± 13	74 ± 12

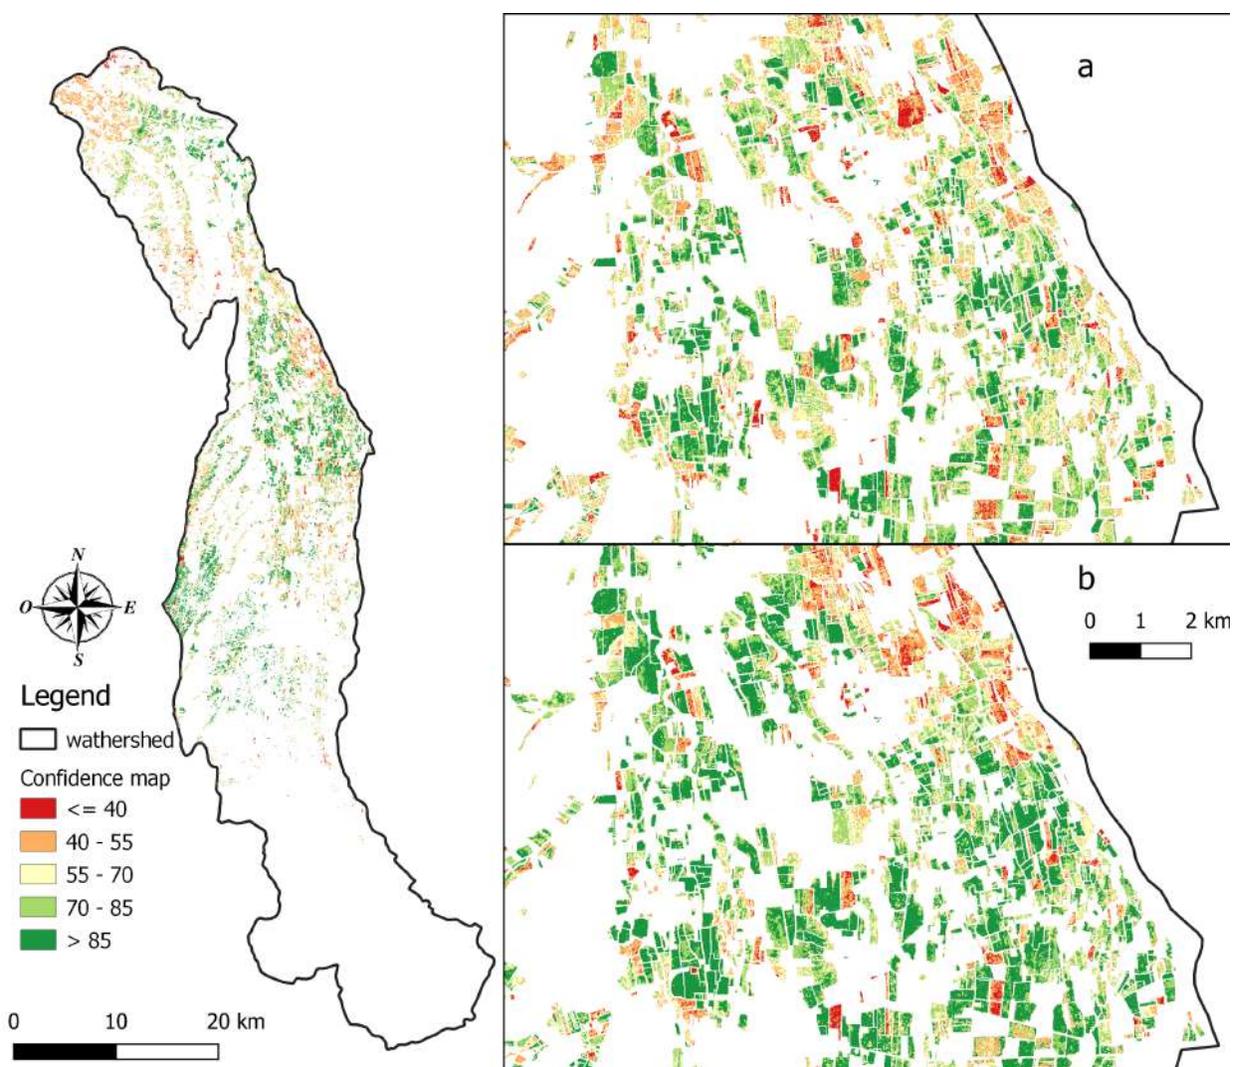


Figure 3.10 – **Carte de confiance pour l'année 2017. La figure (a) illustre le scénario 3 et la figure (b) illustre le scénario 4.**

### 3.3.6 Statistiques régionales

Le tableau 3.6 indique les superficies totales par culture fournies par les scénarios 4 & 5 et comparées à celles du RPG pour l'ensemble du bassin versant. En 2018, les superficies estimées étaient similaires à celles du RPG, avec des erreurs moyennes par classe ne dépassant pas 8 % pour les deux scénarios, pour les cultures majoritaires (maïs, tournesol). Par contre, en 2017, l'erreur atteint 39 % pour le soja avec le scénario 4 contre 6% avec le scénario 5. Ce résultat révèle que l'utilisation d'un nombre important de primitives permet de mieux classer les classes faiblement représentées. La culture la mieux classée est le maïs.

Table 3.6 – **Résumé des surfaces par classe pour les scénarios 4, 5 et le RPG pour les années 2017 et 2018.** Elles sont exprimées en hectares. Le terme diff. fait référence à la différence entre la superficie du scénario et celle du RPG. Il est exprimé en pourcentage

Classe	2017					2018				
	RPG	Scénario 4	diff.	Scénario 5	diff.	RPG	Scénario 4	diff.	Scénario 5	diff.
Maïs	20 987	21 479	+2 %	20 601	-2%	20 242	20 695	+2%	20 149	-1%
Tournesol	2210	1973	-11%	2183	-1%	1242	1131	-9%	1339	+8%
Soja	2301	1402	-39%	2445	+6%	2326	2001	+2%	2339	0%
Total	25 498	24 854	-3%	25 229	-1%	23 811	23 827	0%	23 827	0%

#### Ce qu'il faut retenir

- **Performance globale pour chaque scénario :** Le scénario cumulé (Optique, SAR et précipitations) permet d'obtenir des performances équivalentes au scénario non cumulé. Les scénarios mono-source ont des performances globales peu convaincantes.
- **Fscore :** Les classes de maïs irrigué et tournesol ont les meilleurs Fscores pour l'ensemble de scénarios. Les classes de soja, sous-échantillonné possèdent des Fscores inférieurs à 0.4.
- **Analyse de la confusion entre les classes :** Les confusions ont lieu entre les pratiques (irriguées et pluviales) au sein d'une même culture, avec de fortes confusions entre le soja irrigué et le pluvial et les plus faibles entre le maïs irrigué et le maïs pluvial.
- **Carte de confiance :** Les résultats du scénario 4 ont de meilleurs niveaux de fiabilité par rapport au scénario 3.
- **Statistiques régionale :** Les résultats des classifications illustrent une bonne estimation des surfaces de tournesol et de maïs. En revanche, le soja est sous-estimé avec le scénario 4.

## 3.4 Résultat et analyse complémentaire

Cette partie présente des analyses complémentaires non présentées dans la publication ainsi que de nouveaux résultats obtenus depuis la publication de l'article.

### 3.4.1 Apport des cumuls d'indices

Les figures 3.11 & 3.12 illustrent les performances des classifications avec et sans les cumuls mensuels des indices de végétations pour les années 2017 et 2018. Les classifications n'utilisant pas les cumuls mensuels apportent les meilleurs résultats pour l'ensemble des cultures et pour les deux années. Nous constatons une plus forte différence de performance entre les deux méthodologies, lorsque le classifieur utilise une seule source de

données (optique ou radar). En effet, les résultats du scénario utilisant uniquement des données SAR ont diminué de l'ordre de 10 à 30 % pour le maïs irrigué et le tournesol. En revanche, l'utilisation des données optiques seule, n'impacte pas de manière significative les Fscores de ces classes et ceux pour les deux méthodes étudiées. Pour les classes minoritaires, l'effet inverse est observable avec un plus faible impact sur les performances avec des données SAR seules et un fort impact avec des données optiques seules.

Nous observons également que l'utilisation conjointe des données optiques et radar, permet une amélioration significative des performances pour les classes présentant des Fscores inférieurs à 0.6 lorsqu'elles sont classées avec un seul type de données. Pour le maïs irrigué et le tournesol, ayant des Fscores supérieurs à 0.7, l'utilisation combinée des données optiques et radars, n'améliore pas les performances des classifications.

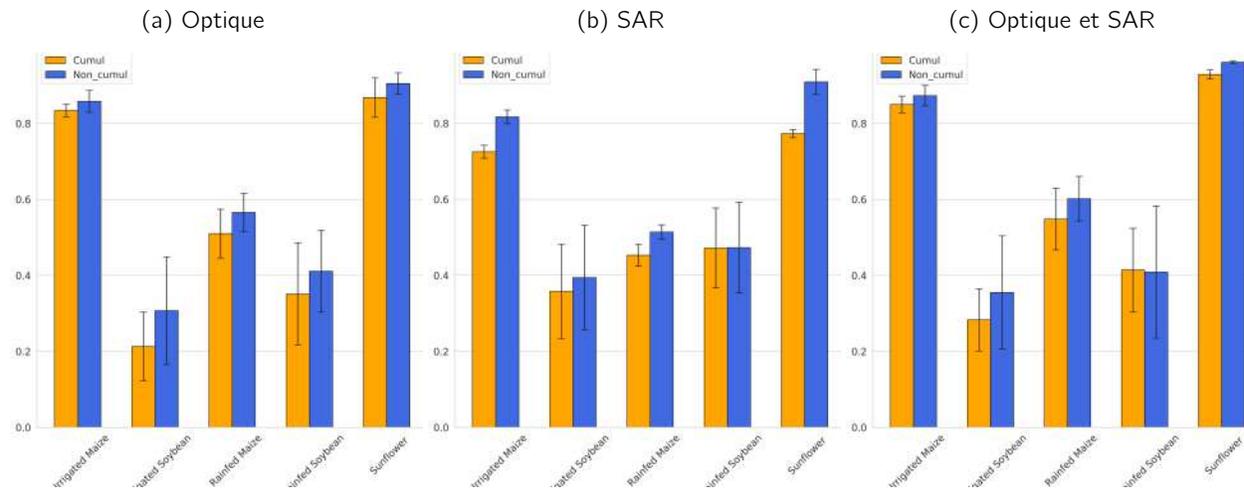


Figure 3.11 – **Fscore par classe en fonction de la méthodologie pour l'année 2017**, les barres orange correspondent à la méthodologie avec cumul mensuels, et les barres bleues illustrent les résultats par classe pour la méthodologie sans les cumuls

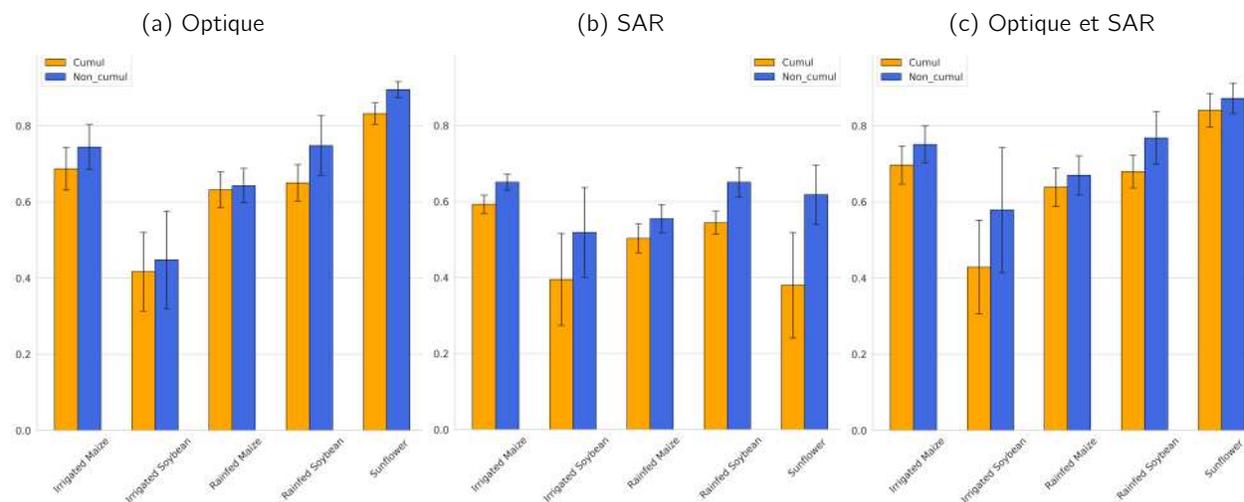


Figure 3.12 – **Fscore par classe en fonction de la méthodologie pour l'année 2018**, les barres orange correspondent à la méthodologie avec cumul mensuels, et les barres bleues illustrent les résultats par classe pour la méthodologie sans les cumuls

Au niveau de l'utilisation de la ressource informatique, nous constatons que la méthodologie utilisant les cumuls présente une plus faible consommation des ressources informatiques (mémoire vive et temps de calcul)

pour la phase d'apprentissage par rapport aux scénarios n'utilisant pas les cumuls. En revanche, la phase de classification est plus coûteuse en temps de calcul pour les scénarios cumulés, avec 30 à 40 heures de plus de calcul que pour les scénarios non cumulés. Cette augmentation du temps de calcul est due à la complexité du modèle de classification, c'est-à-dire que pour chaque pixel, le modèle met plus de temps à attribuer une classe à celui-ci. Cette complexité peut-être illustrée via les cartes de confiances, car si le modèle de classification est complexe, la confiance sera faible. La figure 3.13 illustre la carte de confiance entre le scénario optique & SAR cumulé et optique & SAR non cumulé. La moyenne globale de la confiance du scénario optique & SAR non cumulé est de 65 % contre 63 % pour son homologue cumulé. Sur cette figure, nous remarquons que sur certaines zones du bassin Adour Amont, le nombre de pixels ayant une confiance inférieure à 40% est plus important pour le scénario cumulé. En effet, le nombre total de pixels ayant une valeur de confiance inférieure ou égale à 40 % est nettement supérieur pour le scénario cumulé, avec 369 000 pixels contre 260 000 pixels pour le scénario non cumulé. Néanmoins, le nombre de pixels jugés correctement classés selon la carte de confiance (valeur  $\geq 85\%$ ) est similaire entre les deux méthodes, avec plus de 500 000 pixels.

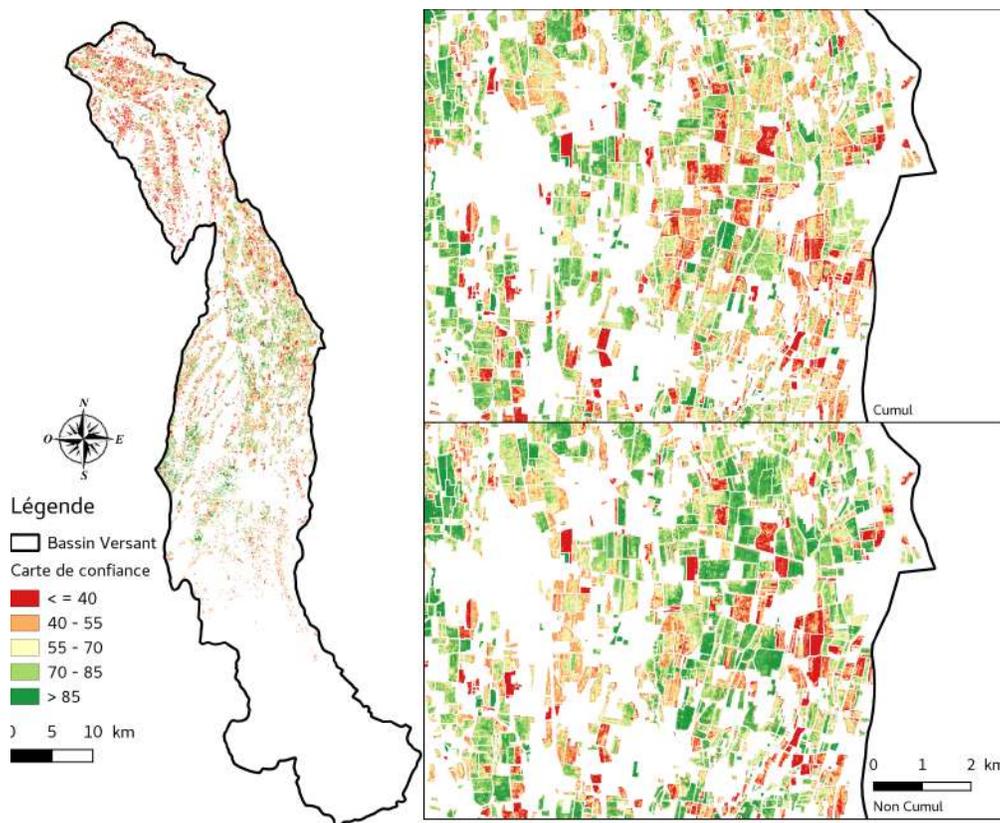


Figure 3.13 – Carte de confiance pour les scénarios optique & SAR cumulés et non cumulés en 2017

Table 3.7 – **Utilisation de la ressource informatique en fonction des différents scénarios cumulés et non cumulés en 2017.** Le temps CPU correspond au temps de calcul sur un processeur nécessaire pour produire le résultat. La RAM exprimée en Gigabites correspond à la quantité de mémoire vive nécessaire pour obtenir le résultat.

Scénario	Nb. primitives	Temps CPU (en heure)		RAM (en GB)	
		Appr. modèle	Classification	Appr. modèle	Classification
SAR cumulé	24	4.5	176	0.21	19
SAR non cumulé	73	5.2	158	0.19	23
Optique cumulé	24	2.2	150	0.14	19
Optique non cumulé	108	2.89	105	0.19	23
Optique & SAR cumulé	48	4.5	181	0.23	21
Optique & SAR non cumulés	181	5.3	142	0.27	23

### 3.4.2 Cours de saison : Cas du bassin versant d'Adour Amont

Afin d'évaluer notre méthodologie, les classifications en cours de saison sur le bassin d'Adour Amont ont été lancées. Le scénario basé sur les cumuls apportant les meilleures performances a été retenu pour cette évaluation. Pour obtenir ces résultats, nous avons lancé 5 classifications en ajoutant un ensemble de données spectrales mensualisées, de manière incrémentale. La figure 3.14 montre les performances globales des classifications en cours de saison sur le bassin versant d'Adour Amont. Une augmentation significative des performances est observable sur les premiers mois (jusqu'à juillet), où l'on obtient une précision globale de 0.7 et un kappa de 0.46. Ensuite, l'ajout de données ne permet pas d'améliorer significativement les performances, avec un gain de seulement 0.4 % sur la précision globale au mois d'août et de 0.2% au mois de septembre.

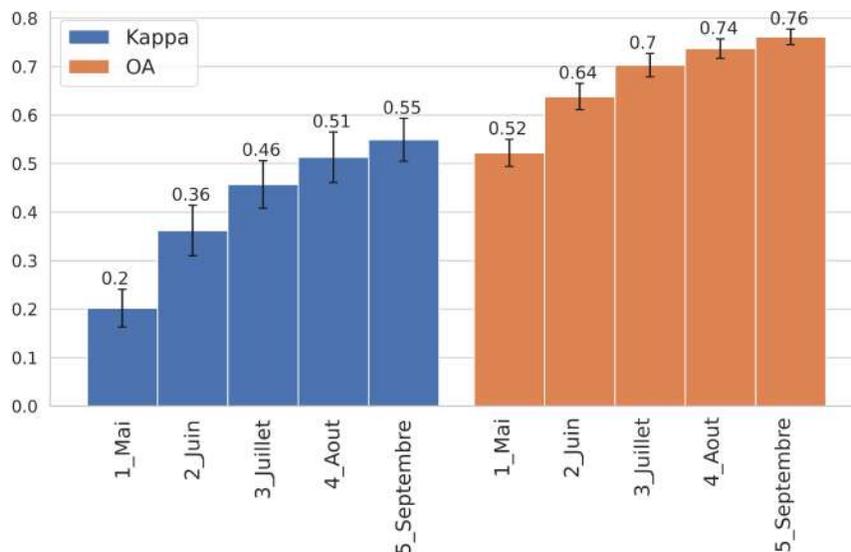


Figure 3.14 – **Performance globale pour l'approche cours de saison.** Les barres orange et bleu correspondent respectivement à la précision globale et au Kappa.

Pour les Fscores, illustrés par la figure 3.15, nous constatons qu'ils augmentent systématiquement lorsque nous ajoutons de la donnée au classifieur. Néanmoins cette augmentation se stabilise, à partir du mois de juillet pour le maïs irrigué et le tournesol, avec des Fscores respectifs de 0.80 et 0.92. Pour les autres classes, les résultats au mois de juillet sont plus mitigés avec des Fscores bas (inférieur à < 0.5). L'ajout de données permet une légère augmentation des Fscores pour ces classes minoritaires, mais les performances restent médiocres avec des Fscores inférieurs à 0.55 pour les cultures pluviales et le soja irrigué

Les bonnes performances observées pour les deux cultures majoritaires (maïs irrigué et tournesol) sont dues à la quantité de données d'apprentissage et à la bonne discrimination de leur dynamique temporelle. En effet, lorsque l'on observe la dynamique temporelle de ces deux cultures avec les indices de végétation optique (figure 3.4), nous constatons qu'elles se différencient à partir du mois de juillet par rapport aux autres cultures. Pour les trois autres cultures, les faibles performances sont dues au problème de manque de données de référence a déjà été illustré dans la section 3.3.3.

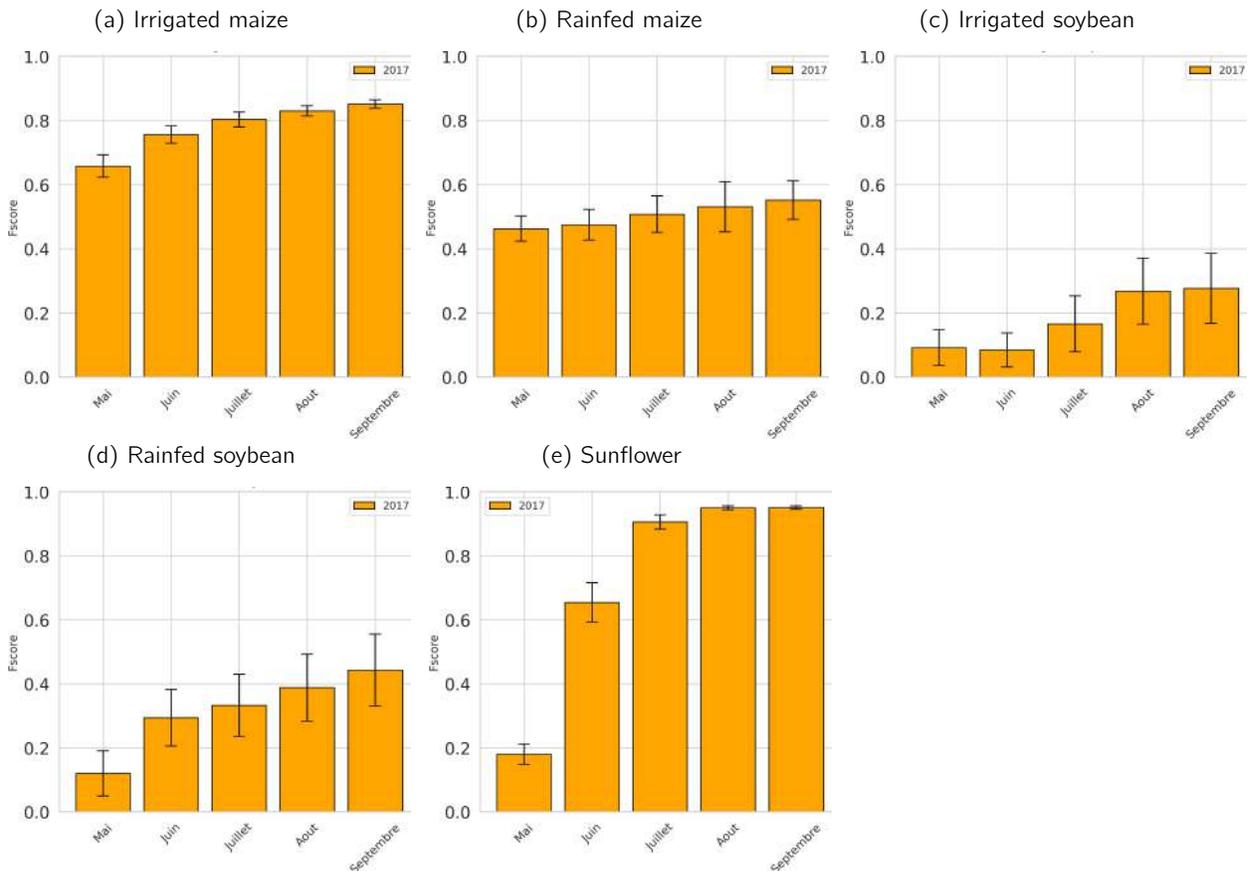


Figure 3.15 – Fscore par classe en fonction des données mensuelles ajoutées.

Pour la confusion entre les classes, nous nous sommes uniquement intéressés à la culture du maïs, car l'ensemble des confusions avec le soja sont déjà présentées dans la classification en fin de saison (section 3.3.4). Pour le maïs irrigué, nous constatons une diminution des confusions avec le maïs pluvial et les autres cultures au cours du temps. Le mois présentant le plus de confusion entre les différentes cultures est celui de mai, avec une confusion de 30%. Pour le maïs pluvial, la confusion avec le maïs irrigué augmente au cours de la saison culturale, pour atteindre au mois d'août 20 %.

La raison de la diminution de confusion pour le maïs irrigué est due à une bonne discrimination de la culture au cours du temps. En revanche pour la confusion entre le maïs irrigué et pluvial, celle-ci semble être due aux effets de bordures comme illustré sur la figure 3.16 et à la validité de la donnée de référence. Ces effets de bordures peut-être provoqués par le mode d'irrigation appliqué sur la parcelle. En effet, l'irrigation par enrouleur qui est majoritaire sur la plaine de l'Adour provoque une irrigation hétérogène sur la parcelle, avec les bordures de parcelle rarement irriguées.

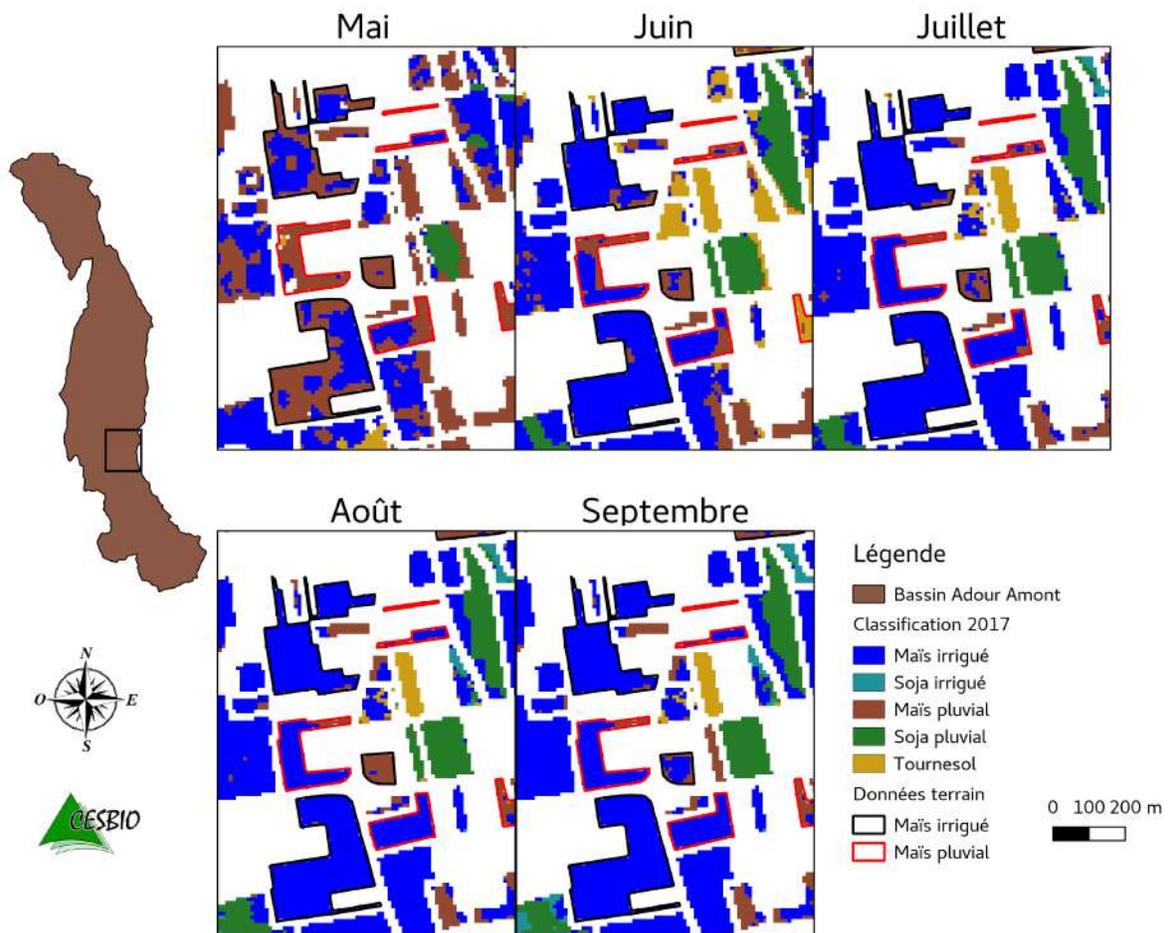


Figure 3.16 – Classification du maïs irrigué et pluvial au cours du temps sur l'année 2017

### 3.4.3 Bassin Versant - Tarn Aval

Les résultats présentés dans cette section, sont à titre d'exemple, car les nombres de données de référence étant trop faibles pour valider la méthodologie sur ce territoire.

#### 3.4.3.1 Performance globale

Les performances globales pour chaque scénario sont illustrées dans la figure 3.17. Le scénario présentant les meilleures performances est celui combinant l'ensemble des données satellitaires non cumulées soit le scénario 5, suivi du scénario optique seul. Les scénarios qui obtiennent les moins bonnes performances sont ceux basés uniquement sur les données SAR en 2017 et le scénario 4 en 2018, avec des Kappa et OA respectivement inférieurs à 0.25 et 0.52. Comparés aux résultats obtenus sur le bassin versant Adour Amont, les performances des scénarios cumulés sont moins bonnes. Cette baisse de performances sur ce bassin versant est probablement due à la donnée de référence, qui est moins nombreuse et dont la fiabilité de celle-ci peut être remise en question.

Malgré les performances des scénarios cumulés, nous allons conserver ces scénarios, soit le 3, 4 et 5 pour la suite de l'analyse.

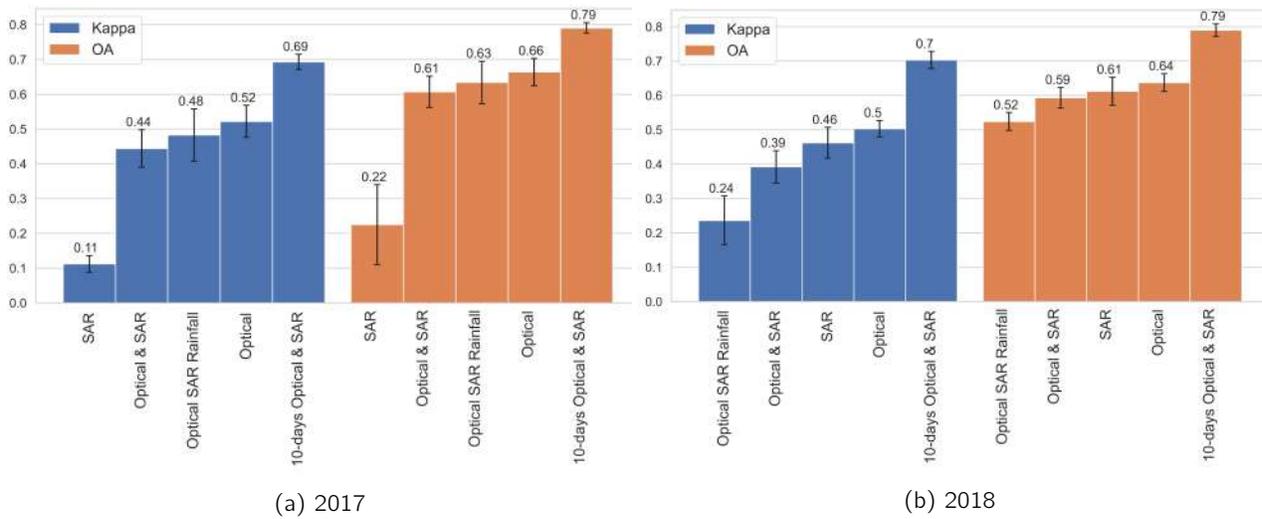


Figure 3.17 – **Performance globale pour chaque classe**, Les barres orange et bleu correspondent respectivement à la précision globale et au Kappa. La figure 3.17a illustre les résultats obtenus en 2017 et la figure 3.17b correspond à ceux obtenus en 2018 sur le Tarn Aval.

### 3.4.3.2 Fscore

Les figures illustrent les Fscores pour les 3 scénarios conservés. Comparés aux résultats obtenus sur le bassin versant Adour Amont, les Fscores des classes sont plus faibles et ceux pour les 3 scénarios, avec une différence notable pour le soja pluvial et le maïs pluvial qui possèdent des résultats médiocres (Fscore < 0.5). Pour les 3 autres classes, le scénario 5 permet d'obtenir des Fscores supérieurs à 0.80 pour le Tournesol, le maïs irrigué en 2017 et le soja irrigué en 2018. Les résultats pour ces classes sont nettement moins bons avec les scénarios cumulés et particulièrement pour le soja irrigué (Fscore < 0.35). Pour le maïs irrigué et le tournesol, nous observons des meilleures performances pour 2017 que pour 2018 et quelque soit le scénario. Cette diminution du Fscore s'explique par des dynamiques temporelles relativement similaires entre les cultures et par une baisse du nombre de parcelles échantillonnées entre ces deux années (voir Annexe 6). Cette tendance est inversée pour le soja irrigué, avec de meilleures performances en 2018 qu'en 2017, cela s'explique par un échantillonnage terrain plus important sur cette culture en 2018, avec 2 fois plus d'échantillons.

L'ajout des précipitations permet une légère augmentation des Fscores pour toutes les classes par rapport au scénario cumulé Optique & SAR, mais celle-ci n'est pas significative. Excepté pour le soja (irrigué et pluvial) en 2017, où l'ajout des précipitations dans la méthode cumulative permet une augmentation significative du Fscore, néanmoins, les performances restent inférieures au scénario de 10 jours (scénario 5).

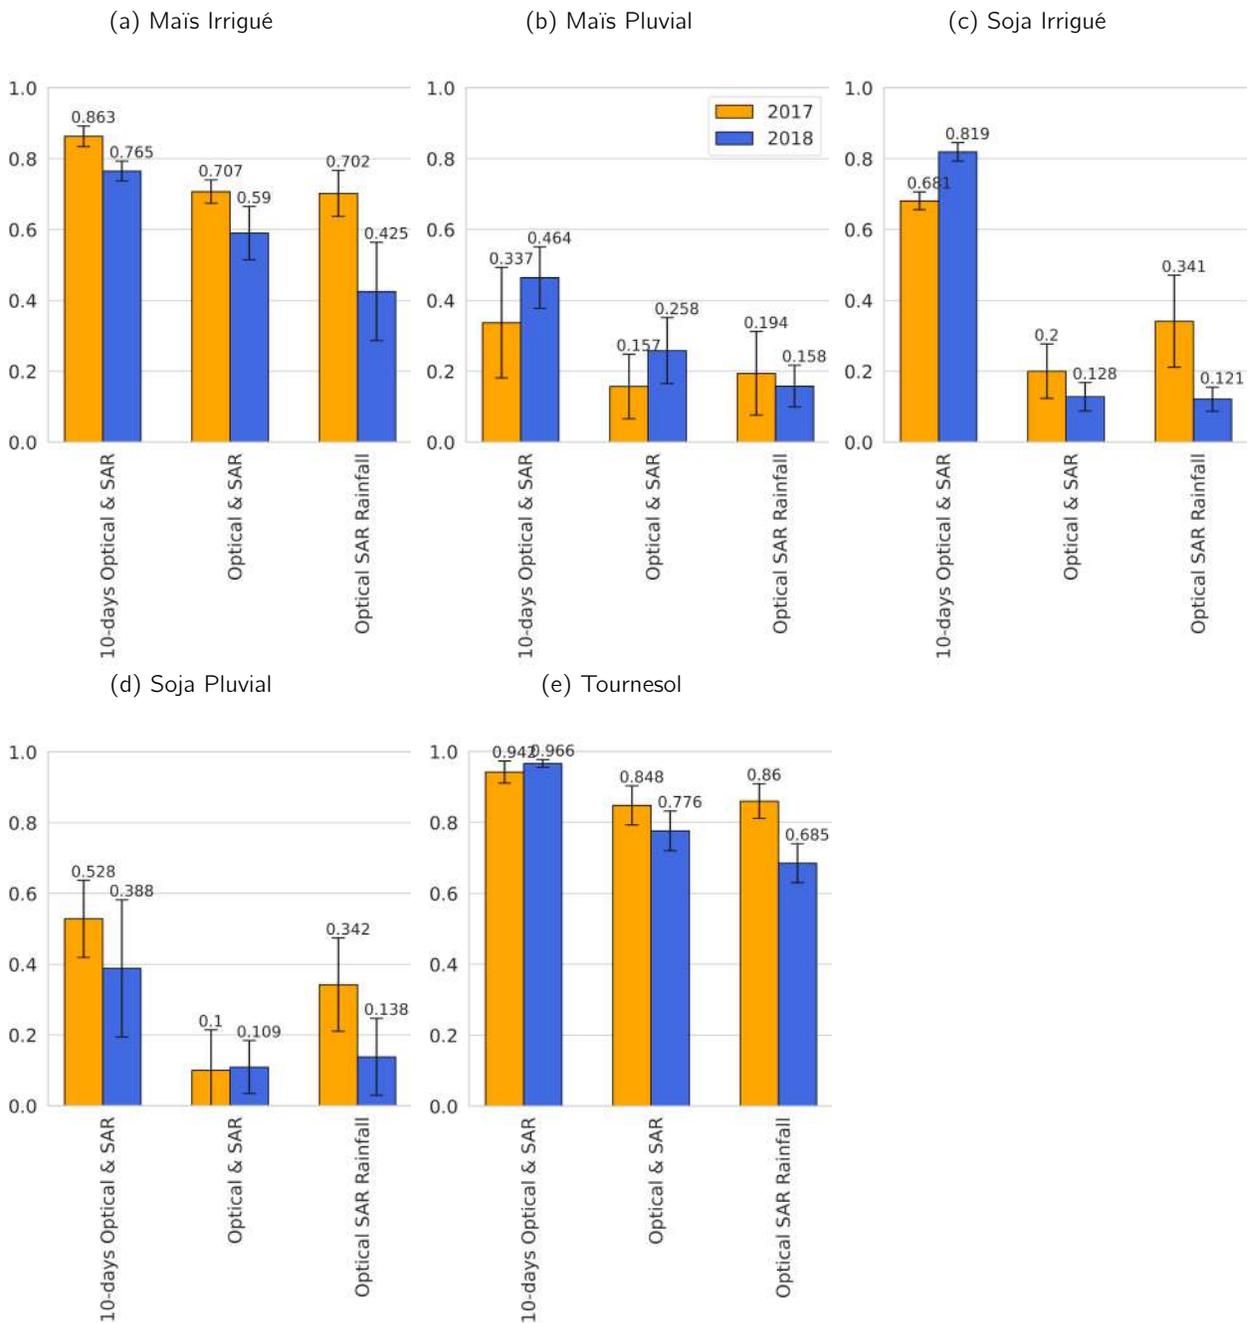


Figure 3.18 – **Fscore par classe en fonction des 3 scénarios** , Les barres orange et bleu correspondant respectivement aux années 2017 et 2018

### 3.4.3.3 Confusion entre les classes

La confusion entre les classes a été analysée pour les 3 scénarios. La figure 3.19 illustre le pourcentage de confusion entre les classes pour les deux années, c'est-à-dire le pourcentage d'erreur de prédiction commis par le modèle de classification.

Pour les deux années et quel que soit le scénario, on observe une confusion entre les pratiques (irriguées et pluviales) au sein d'une même culture. Les plus fortes confusions (32 à 45%) sont observées en 2017 entre le maïs pluvial et le maïs irrigué (figure 3.19c) et le soja pluvial et le maïs pluvial. Quant aux confusions les plus

faibles sont observées en 2018 entre le maïs irrigué et le maïs pluvial (figure 3.19a) et le soja irrigué et le soja pluvial (figure 3.19b) avec des pourcentages de confusions variant de 5 à 23 %. Les confusions observées pour le soja irrigué et pluvial (figure 3.19b et 3.19d) sont plus nombreuses, avec des pourcentages de confusion variant de 0 à 45% entre les autres cultures étudiées.

L'utilisation des données pluviométriques permet de réduire ces confusions et ceux pour toutes les cultures. En effet, les pourcentages de confusion sont presque systématiquement inférieurs pour le scénario 4 par rapport à ceux obtenus pour le scénario 3.

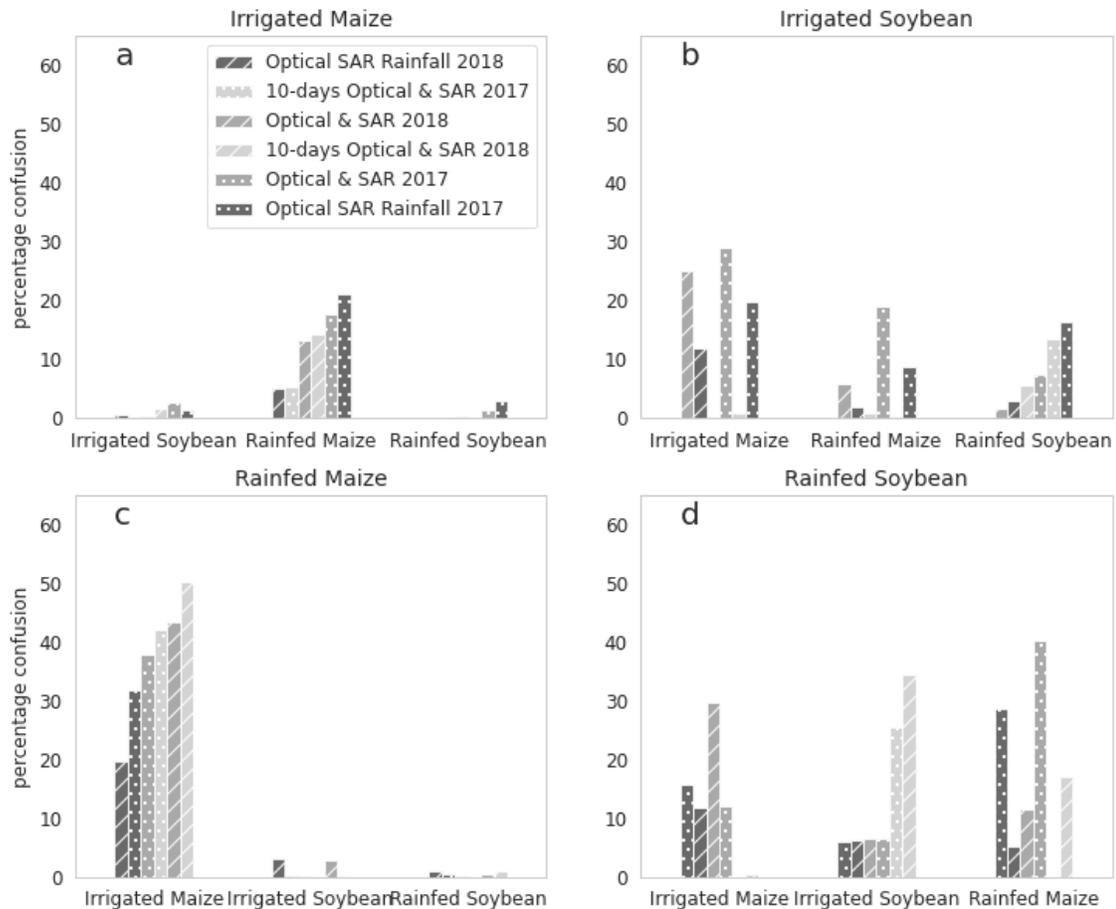


Figure 3.19 – **Confusion selon les scénarios.** Le titre de chaque sous-graphe correspond à la classe réelle et les étiquettes de l'axe horizontal font référence aux classes prédites.

#### 3.4.3.4 Statistiques régionales

Les données de validation dont nous disposons sur ce bassin versant, nous ont permis de calculer les superficies par culture étudiées et nous les avons comparées avec celle du RPG. Les résultats sont consignés dans le tableau 3.8. Nous constatons que le modèle de classification sous-estime la superficie des cultures de maïs (34 % ) et de soja (68% ) pour les deux scénarios, avec 34 % (Scénario 4) et de 20% (Scénario 5) pour le maïs et 68% et 88% pour le soja. En revanche, la superficie du tournesol est bien estimée par le classifieur avec un écart de 3000 ha pour les deux scénarios. L'annexe 7 montre la répartition spatiale des cultures d'étés étudiées sur l'ensemble du bassin versant et ce sur les deux années étudiées.

Table 3.8 – **Résumé des surfaces par classe pour les scénarios 4, 5 et le RPG pour les années 2017 . Elles sont exprimées en hectares.**

Cultures	RPG	Surface Classification S4	Surface Classification S5
Mais	12222	8060	9733
Soja	3450	1071	408
Tournesol	14590	11944	11345

#### Ce qu'il faut retenir

- **Cumul vs non cumul** : Les scénarios cumulés permettent d'obtenir des performances équivalentes aux scénarios non cumulés. En revanche les scénarios mono-source ont des performances globales peu convaincantes.
- **Cours de saison** : A partir du mois de juillet, les classifications des surfaces irriguées permettent une estimation correcte de la localisation des parcelles de maïs irrigué et de tournesol. En revanche pour les autres cultures, la détection est plus complexe, seule une série temporelle complète (mai - septembre) permet d'obtenir de meilleurs résultats.
- **Validation de la méthode sur un autre bassin versant - Cas du Tarn Aval** : Les résultats sur ce bassin, sont difficilement exploitables du fait du nombre de données de référence et de la fiabilité de celle-ci. Néanmoins, les résultats pour le tournesol et le maïs irrigué sont encourageants.

## 3.5 Discussion

### 3.5.1 Optique et/ou Radar

Les scénarios 1 et 2, basés sur l'utilisation d'une source unique d'informations radiométriques, présentent les pires performances en termes d'OA et de coefficient Kappa (entre 0,3 et 0,49). Le faible Fscore obtenu avec les seules données radars est dû aux grandes variations du signal SAR et au manque d'informations spectrales qui ne permettent pas une bonne discrimination entre les classes. En effet, les polarisations SAR sont le résultat de contributions multiples, entre la pluie, la végétation et le travail du sol, ce qui entraîne des erreurs de classification. Les résultats obtenus par ce scénario sont en accord avec ceux obtenus par Ferrant et al, sur la province de Telangana en Inde du Sud avec un coefficient Kappa compris entre 0,3 et 0,49 selon l'année [57]. La mauvaise performance du scénario 2 est due au faible nombre de primitives, dû à la couverture nuageuse (37% en 2017 et 31% en 2018) et à l'absence du capteur 2B en 2017 qui peut rendre difficile la détection de la croissance des cultures comme cela est fréquemment observé dans la littérature [27, 28, 52, 57, 58]. Ainsi, les scénarios dits "à source unique" dépendent fortement du nombre et de la qualité de l'ensemble de données. La figure 3.7 révèle que la synergie des données optiques et radars permet de limiter l'impact de la couverture nuageuse, avec un gain des performances pour les deux années. Des résultats similaires ont été trouvés dans la littérature avec un gain de performance significatif sur la détection des zones irriguées en Inde (plus de 74% de gain sur le Fscore et 0,20 sur le coefficient Kappa, lorsque la synergie des deux capteurs est utilisée), [57], dans le nord de l'Espagne, avec une augmentation de 5% de la précision globale par rapport à l'utilisation des seules données Sentinel-1 [59]. Néanmoins, l'utilisation conjointe des données de télédétection, n'améliore pas les performances de manière systématique. En effet, lorsque les classes disposent d'un grand nombre de données de référence, permettant d'illustrer la variabilité spatiale et temporelle du développement du couvert, les données optiques permettent d'obtenir d'excellents Fscore, et ce, quelle que soit la méthode (cumuls et non cumuls), comme illustré sur la figure 3.11. En revanche, si l'objectif est de cartographier les cultures printanières ou hivernales, telles que le blé irrigué, l'utilisation des données SAR peut-être obligatoire, pour s'affranchir de la nébulosité et obtenir des séries temporelles denses.

### 3.5.2 Impact des indices cumulés mensuels

La gestion du grand nombre d'images disponible nécessite des méthodes de calcul optimisées. Pour cela, nous avons évalué la performance des classifications avec un nombre réduit d'indices. Les résultats montrent que les indices cumulés conduisent à des performances équivalentes par rapport à l'utilisation de l'ensemble des primitives sur 10 jours (Figure 3.7), cela signifie qu'il y a de l'information redondante lorsque nous utilisons toutes les bandes spectrales et l'ensemble des dates. Cependant, nous avons constaté en comparant les scénarios cumulés et non cumulés basés sur les indices de végétation, une légère diminution des performances pour les scénarios cumulés. Cette diminution des performances est due à une dégradation de l'information spectrale liée à l'agrégation de la série temporelle. Toutefois, cette légère diminution des performances, n'impacte pas de manière significative les Fscores de classes majoritaires, qui présentent les Fscore les plus élevées ( $\geq 80\%$ ). Le Fscore le plus bas observé pour les classes minoritaires (soja et maïs pluvial) est dû à un déficit d'échantillons d'apprentissage. En effet, le faible nombre de données de référence pour ces classes ne permet pas de caractériser toute la variabilité spatiale et temporelle de ces classes, et entraîne par conséquent un degré élevé de confusion, comme le montre la figure 3.9. Pour le tournesol, on observe une diminution du Fscore et de la confiance entre 2017 et 2018, ce qui s'explique par une plus petite superficie d'échantillons en 2018, avec seulement 40 ha, contre 120 ha en 2017. Néanmoins, cette petite surface d'échantillons n'a pas d'impact significatif sur les résultats, car la phénologie de cette culture est très différente de celle des autres cultures étudiées, comme le montre la figure 3.4.

Dans l'optique, d'une application opérationnelle de la méthode de détection des surfaces irriguées, l'aspect consommation de la ressource informatique est essentiel. Les résultats illustrent que l'approche cumulative a nécessité beaucoup moins de ressources de calcul, comme le montre le tableau 3.7, avec une réduction du facteur 4. De plus, l'utilisation des cumuls permet de limiter la taille des images à l'entrée du classifieur et d'ajouter d'autres primitives pertinentes telles que la pluviométrie. En effet, pour le scénario 5, il est impossible d'ajouter d'autres primitives, car une contrainte informatique l'empêche. Cette contrainte est la taille des fichiers SQLITE permettant l'apprentissage de modèle de classification.

### 3.5.3 Contribution des données de précipitations

L'ajout de données pluviométriques dans le processus améliore légèrement la performance de la méthode cumulative, comme l'illustrent le Fscore (figure 3.8) et la confiance (figure 3.3.5 et tableau 3.5).

En effet, l'ajout de ces données améliore la séparabilité des classes (Figure 3.9), et le bruit éventuel de l'étiquetage présent dans les données de référence. Néanmoins, elles semblent perdre de leur importance pour détecter du tournesol et pendant les années pluvieuses, comme l'illustrent les résultats sur le maïs irrigué, qui montrent une diminution du Fscore entre 2017 et 2018 et une légère augmentation des confusions pour le tournesol (+ 2%) par rapport au scénario cumulé n'utilisant pas les précipitations. Cette perte d'efficacité peut s'expliquer par une dynamique similaire de croissance du couvert végétal entre les cultures irriguées et les cultures pluviales, car ces dernières ne sont pas soumises à un stress hydrique limitant leur développement phénologique pendant les périodes de sécheresse. Pour le tournesol, la perte d'efficacité est causée par l'ajout de bruit complexifiant la décision du modèle de classification pour étiqueter cette classe, mais cette perte d'efficacité n'est pas significative, ne rendant pas obsolète l'utilisation de cette donnée.

De plus, nous avons observé que le scénario 4 est légèrement plus rapide que le scénario 3 pendant la phase d'apprentissage et d'application du modèle (classification), ce qui explique par un plus grand nombre de primitives et que celle-ci permet une meilleure séparabilité entre les classes irriguées et pluviales rendant le modèle de classification moins complexe.

Ces données montrent également qu'elles peuvent être utilisées pour distinguer les cultures pluviales des cultures irriguées pour des approches en temps quasi-réel [59].

### 3.5.4 Cours de saison

La détection des surfaces irriguées en cours de saison, est une préoccupation majeure des gestionnaires de la ressource en eau, car elle permet d'estimer la superficie totale de parcelle ayant recours à l'irrigation

au cours de la campagne d'irrigation et donc d'estimer au mieux les besoins en eau pour l'agriculture durant les périodes critiques. Les résultats illustrent qu'une classification basée sur les données mensuelles allant de mai à juillet présentes de résultats convaincants pour le maïs irrigué et le tournesol. En effet, les Fscores des classes majoritaires sont satisfaisant avec 80% de bonne classification. Cependant, il est plus difficile de détecter les cultures minoritaires en cours de saison, soit dès le mois de juillet. En effet, les Fscores de ces classes sont inférieurs à 0.5. Ces faibles performances s'expliquent par un manque de données de référence, ne permettant pas de capter les variabilités spectrale et temporelle de ces cultures en cours de saison. Les performances obtenues avec les cumuls mensuels sont comparables avec ceux obtenus par Demarez et al [58] pour le maïs irrigué, mais pas pour le maïs pluvial, avec des Fscores bien inférieurs et ce sur toute la période allant de mai à septembre. En revanche, pour le tournesol nous obtenons des meilleures performances et ce dès le mois de mai, comparé à leurs résultats. Ces différences de performances peuvent s'expliquer par la méthodologie employée, mais aussi par la donnée de référence utilisée qui est différente entre les deux résultats.

Malgré les bonnes performances pour le maïs irrigué, des fortes confusions persistent entre cette culture et son homologue pluvial. Ces confusions peuvent s'expliquer par l'utilisation d'enrouleur pour irriguer les parcelles entraînant un apport d'eau hétérogène. Cette hétérogénéité est d'autant plus visible sur les bordures des parcelles comme illustré dans la figure 3.16.

### 3.6 Conclusion

L'objectif de ce chapitre était de cartographier les surfaces irriguées et pluviales à l'échelle du bassin versant. Pour cela, nous avons utilisé un algorithme de classification supervisée (Random Forest) couplé à des données de télédétection cumulées mensuellement, issues des capteurs Sentinel-1 & 2.

La méthodologie que nous avons développés permet de prendre en compte les divergences sur le développement de la canopée (vitesse et amplitude) entre différentes cultures et pratiques (irriguées et pluviales), tout en conservant les informations spectrales nécessaires pour distinguer les cultures irriguées et pluviales. Les résultats ont montré que l'utilisation du radar seul, ou l'optique seul, entraînent des performances médiocres ( $Kappa$  et  $OA < 0,5$ ) dues au manque d'information spectrale, ne permettant pas une bonne discrimination des classes. En revanche, l'utilisation combinée des primitives optiques et radars donne d'excellents résultats pour le maïs irrigué ( $Fscore > 0,80$ ), qui représente 80 % des cultures d'été sur le territoire Adour Amont. Les résultats sont moins bons pour le soja ( $Fscore < 0,60$ ), notamment en 2017, ce qui s'explique par le manque de données de référence in-situ, en partie dû à la faible représentativité de cette culture sur ce territoire (9%), rendant difficile la collecte de données in-situ. En plus des primitives radars et optiques, l'apport des données pluviométriques cumulées a été évalué. L'ajout de ces données permet une amélioration significative du Fscore pour les classes irriguées et pluviales et une réduction de la confusion entre les classes lors des années sèches. Cependant, la faible résolution spatiale des données pluviométriques utilisées dans notre étude (8 km), peut conduire à de fortes incertitudes, notamment dans les zones à forte hétérogénéité pluviométrique. Ces travaux révèlent également que l'utilisation d'indices cumulatifs mensuels conduit à des performances similaires à celles de l'utilisation d'images tous les 10 jours tout en réduisant le besoin en ressources informatiques ( $\times 4$ ). Cette nouvelle méthodologie de cartographie semble être un excellent choix pour une application opérationnelle, car elle permet d'obtenir de bonnes performances de classification, tout en réduisant le besoin en ressources informatiques.

Nous avons également évalué, cette méthodologie pour détecter les surfaces irriguées en cours de saison, et les résultats sont convaincants, avec des bonnes performances pour les classes majoritaires dès le mois de juillet. En revanche pour les classes faiblement représentées sur le territoire, la détection précoce de la pratique culturale est difficile. Pour améliorer ces résultats en cours de saison, l'augmentation du nombre de données de référence en impérative.

### 4.1 Introduction

Dans ce chapitre, nous présentons les résultats obtenus avec le modèle SAMIR, afin d'estimer les besoins et les consommations en eau du maïs irrigué sur le Sud-Ouest de la France. L'objectif final est de fournir aux gestionnaires des outils leur permettant d'optimiser la gestion de l'eau sur leur territoire (sous bassins-versants).

Pour répondre à cet objectif, nous avons couplé les données Sentinel-2 au modèle de culture. L'utilisation des données Sentinel est prometteuse car leurs caractéristiques (haute résolution spatiale et temporelle) permettent un suivi plus précis du développement des cultures que les images acquises par des missions plus anciennes (SPOT, LANDSAT) dont la faible répétitivité pouvait conduire à de longues périodes (jusqu'à 2 mois) sans images (à cause des nuages) [74],

Des études récentes ont démontré le potentiel des images Sentinel-2 pour estimer les composantes du bilan hydrique des cultures. Le Page et al [60], ont étudié le potentiel des images Sentinel-1 & 2 pour la détection des événements d'irrigation sur le maïs, en couplant ces images à un modèle de bilan hydrique basé sur la FAO-56. French et al [146], ont évalué le modèle FAO-56 couplé à des données Sentinel-2 pour déterminer l'évapotranspiration (ETR) du blé dur dans le Sud-Ouest des États-Unis. Les auteurs ont démontré que cette approche permettait une bonne estimation de l'évapotranspiration réelle (ETR). Cependant, ils précisent que l'estimation de l'ETR est nettement moins bonne en début de saison, du fait de la capacité limitée des indices de végétation optiques à détecter l'évaporation du sol et à représenter avec précision la transpiration d'un couvert épars. D'autres auteurs, tel que Carpintero et al [147], ont exploré l'estimation de l'évapotranspiration (ETR) et du stress hydrique sur les massifs de chêne vert en couplant des données Sentinel-2 et l'approche FAO-56. Les résultats montrent que le modèle reproduit correctement la dynamique de l'eau consommée par la végétation, avec un RMSE de  $0.47 \text{ mm.jour}^{-1}$ .

Les travaux présentés dans ce chapitre ont été menés sur du maïs irrigué. Cette culture présente un enjeu majeur en terme de gestion de l'eau car elle est majoritairement irriguée et atteint son pic de besoin en eau en été, durant les périodes les moins pluvieuses. C'est la céréale, la plus produite en France derrière le blé, avec en moyenne 1.5 millions d'hectares en 2016. Elle couvre près de 40 % des surfaces agricole dans le Sud-Ouest de la France (4.1 avec une production oscillant entre 15 et 18 millions de tonnes dans le Sud-Ouest. L'Occitanie figure ainsi parmi les principaux territoires français produisant du maïs. La majorité des surfaces cultivées en maïs se concentre dans les départements du Gers, des Hautes-Pyrénées, de la Haute-Garonne et du Tarn-et-Garonne, où se situent mes sites d'études. Sur le bassin versant Adour-Garonne, le maïs représente environ 511 000 ha, et la moitié de cette superficie est estimée comme étant irriguée. Cela représente environ une demande en eau globale de l'ordre de  $800 \text{ hm}^3$  par an [18]. Or les différents scénarios climatiques prévoient sur ce bassin une diminution annuelle moyenne des débits compris entre 20 et 40%, pouvant atteindre 50 % en période estivale, d'ici 2050 [17, 19–21].

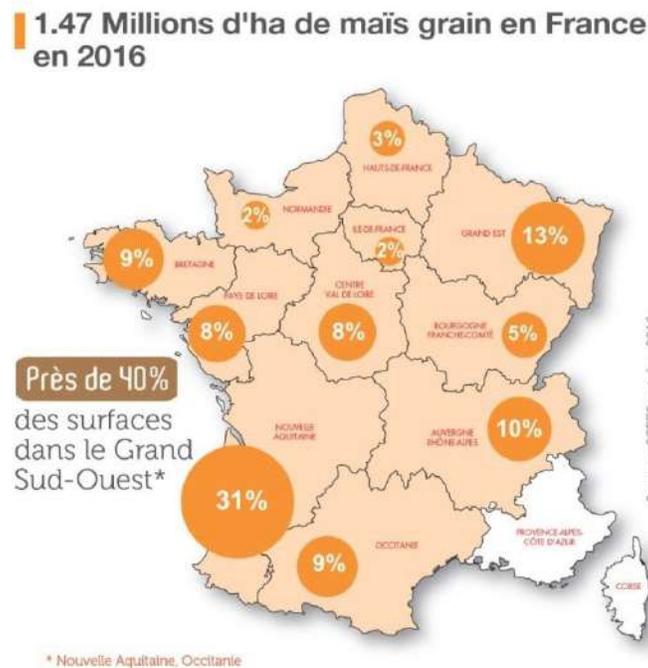


Figure 4.1 – Répartition du maïs sur le territoire français en 2016, source SCEES

La première partie du chapitre présente les équations du bilan hydrique et le modèle SAMIR. La seconde partie du chapitre présente les résultats de l'évaluation du modèle conduite à l'aide de mesures d'évapotranspiration (ETR) acquises durant six années sur la parcelle expérimentale de Lamothe.

Nous avons ensuite évalué la capacité du modèle à prédire les irrigations. Ce travail a été mené sur les parcelles agricoles suivies par nos partenaires (CA 81, 65, CACG) et sur les ASA suivies par la CACG 2.4.2.1). Au total 85 parcelles, (cf section 4.3.2.1) et quatre périmètres irrigués (ASA de Sainte Marie, ASA de Biran, ASA de Miradoux, ASA de Saint Sauvy, cf section 4.3.2.2) ont été étudiés.

Le modèle a ensuite été spatialisé à l'ensemble des parcelles de maïs des BV d'Adour Amont et de la Neste. Les volumes irrigués estimés par le modèle ont été comparés aux volumes irrigués souscrits (faute de volumes réellement prélevés disponibles).

Au cours de ce travail, nous avons évalué notamment l'impact de l'estimation de la réserve utilisable par les plantes (RU) sur la prédiction des irrigations à l'échelle saisonnière. La RU est difficile à estimer, comme l'attestent les nombreux travaux autour des méthodes d'estimations telles que ceux conduits dans l'ANR Rue-DesSols (2015- 2019) [107, 148]. Toutefois les résultats de ce projet ont permis de statuer sur la définition de la réserve utile / réservoir utilisable (RU), comme étant la quantité d'eau que le sol peut stocker et restituer aux plantes pour leur production de biomasse. Il a également été démontré que les incertitudes estimées de la RU croissent avec la profondeur de RU, et les erreurs moyennes d'estimation varient de 15 % à plus de 100%, avec des surestimations systématiques dans le cas de RU non limitant pour la végétation, rendant la spatialisation de la RU complexe [148]. Concernant, les conséquences des incertitudes sur la modélisation Constantin et al [149], ont démontré que le contenu en eau du sol avait un impact important sur l'estimation du rendement des cultures implantées sur des sols peu profonds, mais que l'incertitude de la RU a peu d'impact sur la prise de décision en irrigation, aussi bien sur la date de début de l'irrigation que sur les volumes d'eau apportés. Ils ont également démontré l'efficacité de l'emploi des produits GlobalSoilMap pour réduire fortement les incertitudes sur l'évaluation de la RU ou de ses composantes (humidité à la capacité au champ et au point de flétrissement permanent).

Nous avons évalué dans ce travail l'impact des différentes sources d'estimation de la RU : cf cartes des sols, présentées dans la section 2.3.3.

### 4.1.1 Calcul du bilan hydrique

Le calcul du bilan hydrique (4.1) consiste à décrire l'évolution du stock d'eau (S) disponible dans le sol, c'est-à-dire sa quantité et sa répartition dans les différents horizons de sol. Pour les cultures, le stock (S) est contenu dans l'horizon racinaire du sol, les apports en eau sont réalisés sous forme de précipitations (P) ou d'irrigations (I), et les pertes sont dues au drainage profond (D) et aux processus d'évapotranspiration réelle (ETR) (Figure 4.2).

$$\Delta S = P + Irr - ETR - R - D \quad (4.1)$$

où P représente l'intensité des précipitations en  $mm.j^{-1}$ , Irr l'irrigation, ETR l'évapotranspiration, R le ruissellement, D le drainage et  $\Delta S$  la variation de quantité d'eau stockée dans le sol.

L'évapotranspiration correspond à la quantité d'eau totale transférée du sol vers l'atmosphère par évaporation du sol, évaporation de l'eau libre et par transpiration des plantes. Ce terme correspond à la consommation en eau des cultures.

Le drainage (D) représente la quantité d'eau qui quitte le sol de manière gravitaire. Le drainage survient lorsque l'humidité d'une couche donnée devient supérieure à la capacité au champ  $w_{fc}$ . Il atteint sa valeur maximale lorsque le sol atteint l'humidité à saturation  $w_{sat}$ . Le ruissellement est un flux d'eau horizontal, qui apparaît lorsque la couche supérieure du sol atteint la saturation. Si l'intensité des précipitations s'avère supérieure à la capacité de stockage du sol, l'eau excédentaire alimentera le ruissellement. Ce flux peut-être entrant ou sortant, il peut également intégrer un drainage latéral de sub-surface.

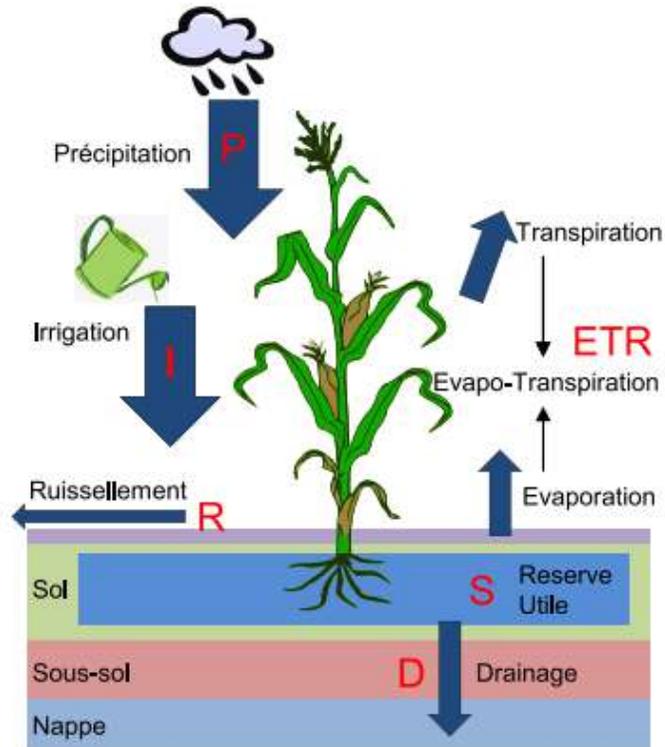


Figure 4.2 – Schéma du bilan hydrique d'une culture, source : Martin Claverie [150]

### 4.1.2 La méthode FAO

Les premières méthodes d'estimation de l'ETR reposaient sur des formules empiriques développées au cours des années 50 et améliorées dans les années 80 grâce à l'amélioration des mesures météorologiques. Parmi ces formalismes, nous retrouvons celui de Penman [66], repris par Priestley et Taylor [151] et celui de Perrier [152].

Ces formalismes sont difficilement applicables à l'échelle régionale, car ils ont fait l'objet de calibration locale et requièrent de nombreuses données météorologiques. Face aux différents formalismes proposés, la FAO a décidé de retenir celui de Penman. Cette méthode s'appuie sur l'équation de Penman-Monteith pour estimer le flux d'évapotranspiration de référence d'un gazon non-soumis aux stress, ayant une hauteur de 8 à 15 cm. Cette variable est nommée demande climatique. Elle est notée  $ET_0$ .

$$ET_0 = \frac{0.408\Delta(R_n - G + \gamma \frac{900}{T+273} u_2 (e_s - e_a))}{\Delta + \gamma(1 + 0.34u_2)} \quad (4.2)$$

L' $ET_0$  est utilisée pour estimer l'évapotranspiration de référence d'une culture selon l'équation 4.2.

Le modèle FAO-56 a été proposé par Allen et al en 1998 [153] puis amélioré en 2005, [154]. Il est basé sur les concepts d'évapotranspiration de référence ( $ET_0$ ) modulée par des coefficients de culture ( $K_c$ ) pour tenir compte du développement spécifique de toute végétation ainsi que son état hydrique. Le coefficient  $K$  proposé par Perrier [152] et Gosse et al [155] est un coefficient cultural qui permet de lier les variables caractérisant le climat et du couvert végétal. Il traduit la différence de fonctionnement entre le gazon et la culture étudiée. Ce coefficient est établi expérimentalement pour une région et une culture donnée, puis consigné dans des tables pour une utilisation ultérieure dans des régions similaires. Dans cette approche, le cycle de culture est subdivisé en quatre phases comme illustré sur la figure 4.3 :

- la phase initiale, du semis à environ 10% de couverture du sol,
- la phase de développement du couvert se terminant lorsque la couverture du sol est complète,
- la mi-saison qui se termine par le début de la sénescence foliaire,
- la phase de l'arrière-saison ou de maturation.

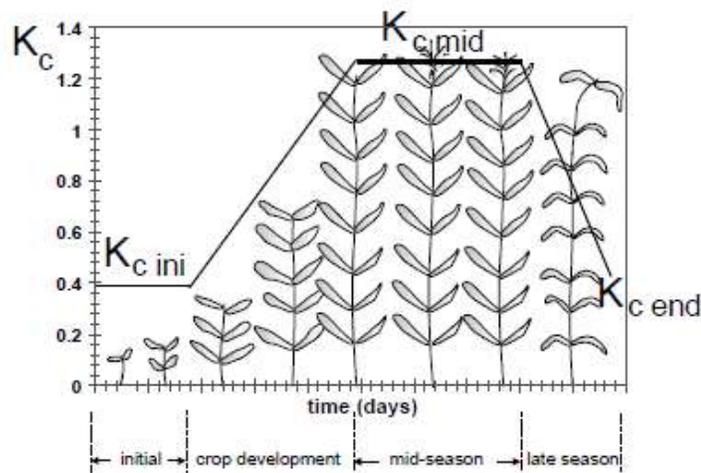


Figure 4.3 – **Évolution du coefficient cultural ( $K_c$ ) en trois phases :  $K_c$  initial,  $K_c$  de mi-saison et  $K_c$  de fin de saison** (source : Allen et al [153])

Le modèle développé par Allen et al [153], propose différentes méthodes de calcul de l'évapotranspiration des cultures. En conditions standards (absence de tout stress environnemental), la première méthode appelée ("single-crop"), définit l'évapotranspiration (ET) comme le produit de l' $ET_0$  par le coefficient cultural  $K_c$  4.3. Ce coefficient  $K_c$  traduit les effets du couvert, soit sol et plante combinée sur l'évapotranspiration. La seconde méthode appelée approche double coefficient cultural ("dual-crop"), permet de séparer l'évaporation du sol de la transpiration de la plante. Deux coefficients sont utilisés : le coefficient d'évaporation du sol ( $K_e$ ) et le coefficient de transpiration ( $K_{cb}$ ) [Équation 4.4].

Dans le cas de conditions non-standards, l'estimation de l'évapotranspiration est modifiée avec l'ajout d'un coefficient  $K_s$  traduisant le stress hydrique de la culture. On obtient alors les équations 4.5 et 4.6. Le coefficient cultural est alors supposé tenir compte à la fois de la différence de fonctionnement entre le gazon et la culture étudiée, mais aussi de l'ensemble des stress environnementaux autres que le stress hydrique. Dans le cas de la méthode « dual-crop coefficient » [ Équation 4.6] , le coefficient  $K_{cb}$  est défini de manière théorique comme étant le rapport entre ETR et  $ET_0$ , lorsque le sol est sec ( $K_e = 0$ ) et que la culture ne présente pas de stress hydrique ( $K_s = 1$ ).

$$ETR = K_c \times ET_0 \quad (4.3)$$

$$ETR = (K_{cb} + K_e) \times ET_0 \quad (4.4)$$

$$ET_{Radj} = K_s \times K_c \times ET_0 \quad (4.5)$$

$$ETR = (K_s \times K_{cb} + K_e) \times ET_0 \quad (4.6)$$

## 4.2 Modèle SAMIR

### 4.2.1 Présentation du modèle

Le modèle SAMIR (SATellite Monitoring of IRrigation) est basé sur le couplage du modèle FAO-56 "dual-crop" et l'utilisation de séries temporelles de NDVI. Il a été développé par des chercheurs du CESBio [80]. Le modèle simule le flux d'évapotranspiration réel (ETR), le contenu en eau du sol (SWC) dans trois horizons de sol (superficiel  $Z_e$ , racinaire  $Z_r$  et profond  $Z_d$ ), ainsi que les dates et doses d'irrigation optimales. Le bilan hydrique du sol est calculé au pas de temps journalier. Il s'agit d'un modèle à réservoir. Les ruissellements de surface et de sub-surface sont négligés dans l'approche.

Pour calculer le bilan hydrique journalier d'une culture, les données nécessaires sont : l'évapotranspiration de référence ( $ET_0$ ), les apports d'eau à savoir la pluviométrie ( $P$ ), éventuellement l'irrigation ( $I$ ), une série temporelle de NDVI, des informations d'ordre pédologiques (capacité au champ, point de flétrissement, profondeur de sol), les règles d'irrigation (volume de dose, fréquence) et le type d'assolement (cf Figure 4.6).

Le calcul du bilan hydrique comporte plusieurs étapes successives :

- Prise en compte de l'évolution du front racinaire, à partir de la fraction de couvert végétal (FCover) pour le calcul des contenus en eau et de la RU.
- Calcul des déficits en eau
- Mise à jour des contenus en eau du sol
- Calcul de l'évapotranspiration
- Calcul des flux diffusifs et gravitaires. Ce calcul est une adaptation de celui proposé par Devonec et Barros [156]. Ces flux sont calculés grâce à la différence de teneur en eau entre la couche profonde et la couche racinaire, et permet de simuler les transferts d'eau par capillarité.
- Mise à jour des déficits en eau avec l'évaporation et la transpiration

La capacité de stockage en eau du sol est définie par sa réserve utile. Pour l'horizon superficiel (TEW pour "Total Evaporable Water") et l'horizon racinaire (TAW pour "Total Available Water", exprimée en mm), la réserve utile est calculée en fonction de l'humidité à la capacité au champ ( $\theta_{fc}$  " field capacity " en  $m^3.m^{-3}$ ), de l'humidité au point de flétrissement ( $\theta_{wp}$  pour " wilting point " en  $m^3.m^{-3}$ ) et de l'épaisseur de la couche ( $Z$  exprimé en mm)[Équation 4.7 & 4.8]. L'épaisseur de l'horizon superficiel ( $Z_e$ ), la capacité au champ et le point de flétrissement sont renseignés par l'utilisateur (4.1). L'épaisseur de l'horizon racinaire évolue en fonction du développement de la plante (FCover), conduisant à une augmentation de la couche  $Z_r$  et par conséquent une

diminution de la couche profonde (Zd). Les bornes minimales (Zrmin) et maximale (Zrmax & Zsoil) sont fixées [Équation 4.9] par l'utilisateur.

$$TEW = (\theta_{FC} - \frac{\theta_{WP}}{2}) \times Z_e \quad (4.7)$$

$$TAW = (\theta_{FC} - \theta_{WP}) \times Z_r \quad (4.8)$$

$$Z_r = Z_{rmin} + (Z_{rmax} - Z_{rmin}) \times \frac{FCover_{Z_r}}{\max(FCover)} \quad (4.9)$$

avec

$$FCover_{Z_r} = \begin{cases} \text{if : } NDVI_j \geq \max(NDVI) \\ \max(FCover) \\ \text{else : } FCover_j \end{cases}$$

Seule l'eau contenue dans l'horizon superficiel (Ze) peut être sujette à évaporation (E), tandis que l'eau sujette à transpiration (T) peut être prélevée dans les deux horizons (Ze et Zr, tous deux explorés par le système racinaire). L'eau contenue dans l'horizon profond alimente le drainage profond (DP) lorsque le contenu en eau du sol de cet horizon est supérieur à la capacité au champ. Cette eau excédentaire est définitivement perdue par le système (cf Figure 4.4).

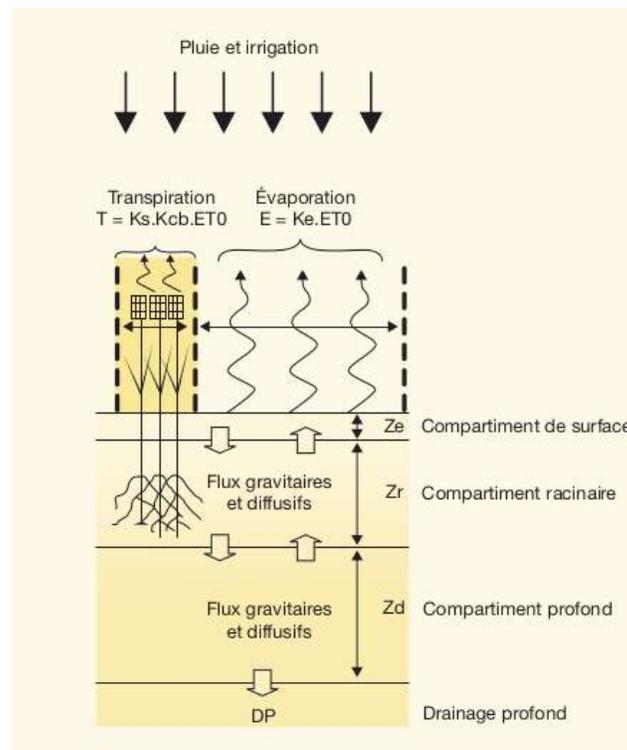


Figure 4.4 – Schéma modélisant les transferts d'eau entre sol, végétation et atmosphère dans SAMIR, par Simonneaux et al [80]

L'évapotranspiration réelle (ETR) est estimée à partir de l'ET0 et de trois coefficients : Ke (coefficient d'évaporation), Kcb (coefficient cultural) et Ks (coefficient de stress hydrique) [Équation 4.10, 4.11 & 4.12].

$$ETR = E + T \quad (4.10)$$

$$E = Ke \times ET_0 \quad (4.11)$$

$$T = Kcb \times Ks \times ET_0 \quad (4.12)$$

L'évaporation du sol (E) est fonction de la demande climatique (ET<sub>0</sub>) et du coefficient d'évaporation du sol (Ke) [Équation 4.11]. Le coefficient Ke dépend de la fraction de sol nu mouillée (*few*), et ne peut pas être supérieur à (*few* × *Kc<sub>max</sub>*). La *few* est estimée à partir de la fraction de couvert végétal (FCover) et de la fraction de sol mouillée par l'irrigation (*fw*) [Équation 4.13]. FCover est estimé à partir du NDVI calculé à partir des réflectances de surface des images S2. La relation qui relie le FCover au NDVI est issue des travaux de Saadi et al [84]. Les coefficients (a et b) de l'équation 4.14 sont définis par l'utilisateur pour chaque culture. Le *Kc<sub>max</sub>* représente la limite supérieure de l'évaporation et de la transpiration qui peut avoir lieu sur une parcelle cultivée. Selon la FAO cette valeur est comprise entre 1.05 et 1.30. Dans cette étude, le Kc max est fixé à 1.15, selon les recommandes de la FAO-56 [153, 157].

$$Ke = Kr \times (Kc_{max} - Kcb) \leq few \times Kc_{max} \quad (4.13)$$

avec

$$few = 1 - Fcover \leq fw$$

où *fw* = 1 pour l'irrigation par aspersion

$$FCover = a \times NDVI + b \quad (4.14)$$

L'évaporation du sol est réduite au cours des épisodes d'assèchement par le coefficient Kr. Ce coefficient est calculé par une fonction bilinéaire proposée par Allen et al [153, 154]. Cette fonction dépend du contenu en eau dans l'horizon superficiel, du déficit en eau et de l'eau facilement évaporable (REW = Readily Evaporative Water), défini à partir des tables de la FAO. Elle est définie par l'équation suivante [4.15] :

$$Kr = \frac{TEW - De}{TEW - REW} \quad (4.15)$$

avec

$$De = 0 \leq (De_{j-1} + \frac{E}{few} + T - P) \leq TEW$$

L'estimation du coefficient réducteur de l'évaporation du sol nu (Kr) se déroule en 2 étapes : le stade 1 correspond au maximum d'évaporation lorsque (*De* ≤ REW) et le stade 2 correspond à une réduction de l'évaporation proportionnelle au déficit hydrique (*De*) lorsque *De* > REW, comme illustré dans la figure 4.5 et l'équation 4.15.

Le déficit en eau dans le sol pour l'horizon superficiel est calculé de manière dynamique en fonction du déficit du jour précédent (*De<sub>j-1</sub>*), des pertes en eau par évaporation du sol (E) et transpiration de la végétation du jour *j* et des apports d'eau (Précipitation et Irrigation) du jour *j*. La transpiration (T), est donnée par le produit de la demande climatique (ET<sub>0</sub>), du coefficient cultural (Kcb) et d'une fonction de stress hydrique (Ks) [Équation 4.12]. Le coefficient cultural est estimé à partir du NDVI par l'intermédiaire d'une relation linéaire [Équation 4.16], où les coefficients (a et b) sont fixés par l'utilisateur en fonction de la culture étudiée.

$$Kcb = a \times NDVI + b \quad (4.16)$$

Le coefficient de stress hydrique (Ks), varie entre 0 (stress maximum) et 1 (pas de stress). Il dépend du contenu en eau du sol dans la couche racinaire, pondéré par un facteur *p*, permettant de calculer l'eau facilement utilisable par la plante [Équation 4.17].

$$Ks = \frac{TAW - Dr}{TAW \times p} \quad (4.17)$$

avec

$$Dr = 0 \leq Dr_{j-1} + ET - P - I \leq TAW$$

Le déficit en eau dans l'horizon racinaire est calculé de manière dynamique en fonction du déficit du jour précédent (*Dr<sub>j-1</sub>*), de l'évapotranspiration et des apports en eau (Irrigation et Précipitation). Si le contenu en

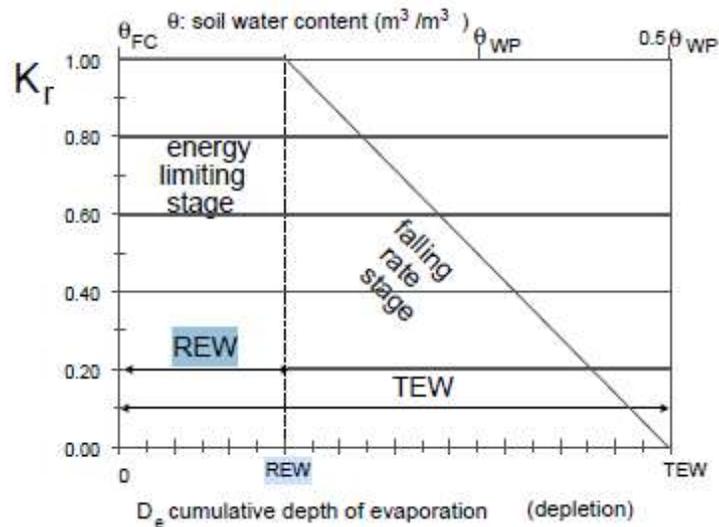


Figure 4.5 – Méthode d'estimation du coefficient  $K_r$ , selon la FAO-56 : source Allen et al [153]

eau de l'horizon racinaire vient à se remplir jusqu'à sa capacité maximale, l'eau excédentaire ( $D$ ) alimentera l'horizon profond. Cet horizon profond correspond à un réservoir de stockage connecté à l'horizon racinaire en période culturale et à l'horizon superficiel en période de sol nu [158].

Le contenu en eau du sol est calculé selon les équations suivantes [4.18 & 4.19] :

$$SWC_{Ze} = 1 - \frac{De}{TEW} \quad (4.18)$$

$$SWC_{Zr} = 1 - \frac{Dr}{TAW} \quad (4.19)$$

Il existe 2 modes pour le pilotage de l'irrigation : le mode forcé et automatique. Les irrigations forcées sont issues d'une observation in-situ lorsqu'elles sont disponibles. Le mode automatique repose sur un seuil de déclenchement basé sur 2 conditions : (1) le déficit maximal autorisé dans la zone racinaire et (2) une condition relative au développement du couvert végétal, selon l'équation 4.20. L'intervalle de temps entre deux irrigations est fixé par l'utilisateur ainsi que la dose maximale d'irrigation appliquée à chaque événement. La condition relative au développement du couvert végétal est basé sur le NDVI et une date de semis définie arbitrairement afin de filtrer la présence potentielle de couvert intermédiaire (Figure 4.6).

Ces deux variables (intervalle entre 2 événements et la quantité d'eau) ont été discutés avec nos partenaires. Il a été convenu de les fixer respectivement à 10 jours et 30 mm. Ces valeurs semblaient traduire les pratiques les plus représentatives de nos territoires d'étude.

La valeur  $p$  qui définit la fraction du déficit au-delà duquel l'irrigation est déclenchée a été fixé à 0.55, valeur issue des tables de la FAO-56 [154]. [Équation 4.20].

$$Irrigable = \begin{cases} D_r > TAW * p \\ K_{cb} > K_{cbini} \end{cases} \quad (4.20)$$

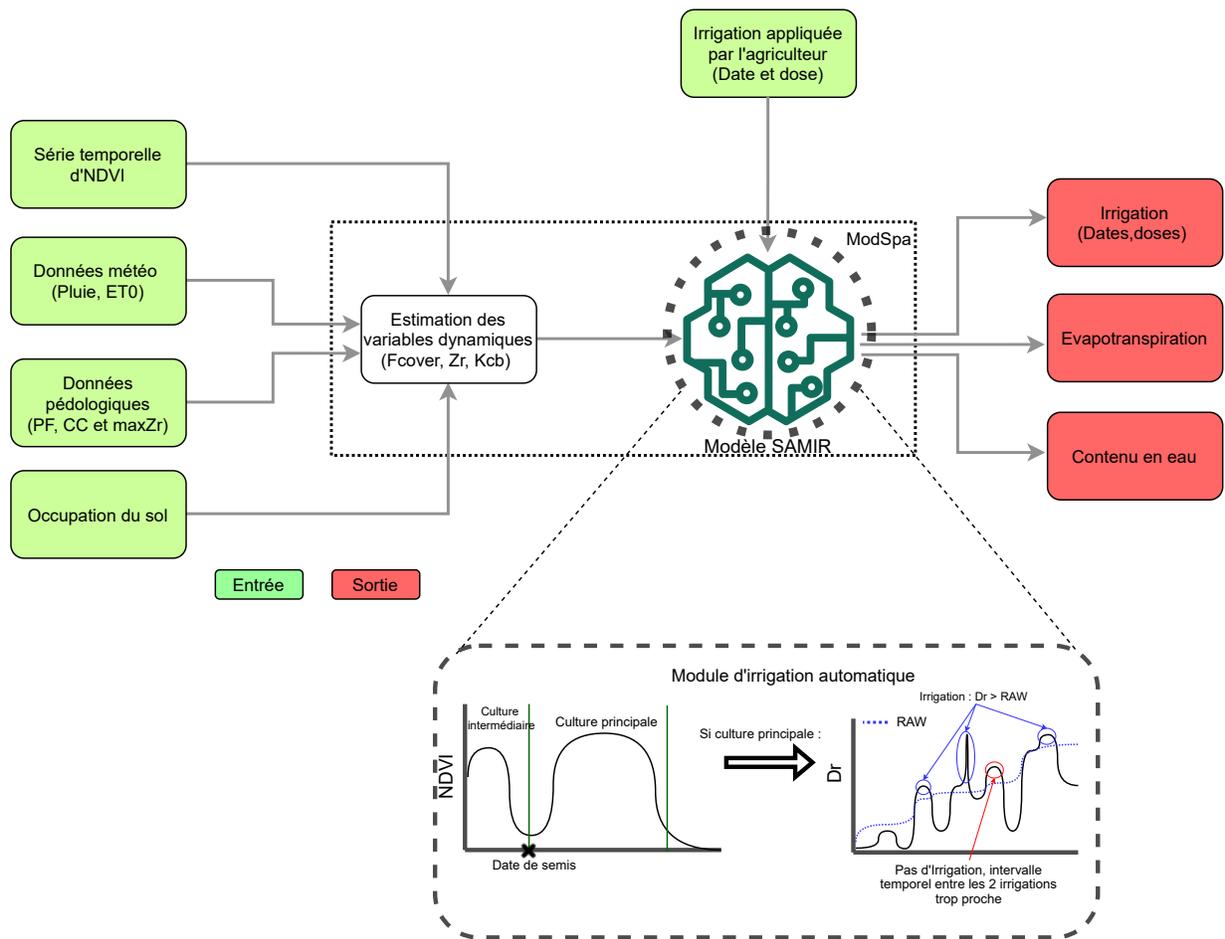


Figure 4.6 – **Schéma conceptuel du modèle SAMIR**. Les carrés verts illustrent les entrées du modèle, quant aux carrés rouges, ils correspondent aux sorties de celui-ci. Le carré en pointillés illustre le fonctionnement du module d'irrigation de manière schématique.

Les données météorologiques (ET0 et Précipitation) que nous avons utilisées pour ces travaux proviennent de la base de données SAFRAN [102] sous sa forme données journalière fournies par Météo-France. Les séries temporelles de NDVI, sont issues des données de Sentinel-2. Les données pédologiques utilisées pour calculer TAW (RU), proviennent des cartes pédologiques  $RRP_{UTS}$  et GlobalSoilMap (GSM) ainsi que les mesures terrain.

#### 4.2.2 Approche méthodologique

Le modèle a été évalué à différentes échelles : la parcelle (expérimentale et des partenaires) et les périmètres irrigués.

**Parcelle expérimentale :** Nous avons utilisé des données d'ETR estimées à partir des capteurs d'Eddy-Covariance pour évaluer l'ETR simulé par SAMIR sur 6 années. Ce travail nous a conduit à introduire un nouveau formalisme d'estimation de l'évaporation du sol nu. Nous avons pour cela comparé l'approche proposée par Merlin et al [159, 160] à l'approche FAO -56 [153, 154].

Nous avons également comparé l'apport de produits Fcover satellitaires estimés via les données S2 à l'approche initialement implémentée dans le modèle qui reposait sur l'utilisation d'une relation empirique NDVI/Fcover

[Équation 4.14].

Étant donné que les images Sentinel-2 ne sont pas disponibles avant 2017, pour les années antérieures à 2017, nous avons utilisé un ensemble de séries temporelles de NDVI issues des capteurs Formosat et Spot. Ces données ont été présentées dans la thèse de Marjorie Battude [161].

**Les parcelles des partenaires :** Les données fournies par nos partenaires sont les dates et les doses d'irrigations sur l'année 2017 et sont représentatives des pratiques du bassin versant Adour Garonne. Nous avons donc comparé les volumes d'irrigation saisonniers estimés par SAMIR pour chaque parcelle. Ce travail a permis de mener une réflexion sur l'impact de la profondeur d'enracinement et de la RU sur les volumes irrigués. Pour cela les données pédologiques issues de GSM et du RRP<sub>UTS</sub> ont été utilisées.

**Périmètres irrigués :** La CACG nous a fourni les volumes saisonniers de 4 périmètres irrigués. Nous avons cumulé les volumes irrigués simulés par SAMIR pour les parcelles cultivées en maïs et les avons comparés à ceux fournis par les partenaires en utilisant les données pédologiques issues de GSM et du RRP<sub>UTS</sub>.

#### 4.2.2.1 Évaporation du sol nu

Les récents travaux d'Olivera et al [82, 162] et Er-Raki et al [163] ont montré qu'il existait de fortes incertitudes sur l'évaporation du sol nu, pouvant provenir d'une mauvaise estimation du REW. Ces travaux ont conduit à proposer une nouvelle estimation du coefficient  $K_r$  par Merlin et al [159, 164] et Amazirh et al [142]. [Équation 4.21 & 4.22], en se basant sur les propriétés texturales du sol.

$$K_r = \left[ 0.5 - 0.5 \cos \left( \frac{\pi \theta_s}{\theta_{max}} \right) \right]^P ; \theta_s < \theta_{max} \quad (4.21)$$

$$K_r = 1; \theta_s \geq \theta_{max}$$

avec

$$P = \frac{\ln [K_{r\text{tex}}(\theta_{1/2})]}{\ln \left[ 0.5 - 0.5 \cos \left( \frac{\pi \theta_{1/2}}{\theta_{SAT}} \right) \right]} \quad (4.22)$$

avec  $K_{r\text{tex}}(\theta_{1/2}) = 0.5$

Ce nouveau formalisme permet une estimation plus précise du flux évaporateur par rapport à la méthode FAO, avec un RMSE de 0,16 mm/jour contre 0,88 mm/jour pour la FAO [160]. Il permet également de s'affranchir du REW, qui est souvent fixé de façon arbitraire et ne permet pas de prendre en compte une forte gamme de variabilité texturale des sols, car celui-ci est uniquement donné pour 9 grands types de sols (Figure 4.7).

Typical soil water characteristics for different soil types					
Soil type (USA Soil Texture Classification)	Soil water characteristics			Evaporation parameters	
	$\theta_{FC}$	$\theta_{WP}$	$(\theta_{FC} - \theta_{WP})$	Amount of water that can be depleted by evaporation	
				stage 1 REW	stages 1 and 2 TEW* ( $Z_e = 0.10$ m)
	$m^3/m^3$	$m^3/m^3$	$m^3/m^3$	mm	mm
Sand	0.07 - 0.17	0.02 - 0.07	0.05 - 0.11	2 - 7	6 - 12
Loamy sand	0.11 - 0.19	0.03 - 0.10	0.06 - 0.12	4 - 8	9 - 14
Sandy loam	0.18 - 0.28	0.06 - 0.16	0.11 - 0.15	6 - 10	15 - 20
Loam	0.20 - 0.30	0.07 - 0.17	0.13 - 0.18	8 - 10	16 - 22
Silt loam	0.22 - 0.36	0.09 - 0.21	0.13 - 0.19	8 - 11	18 - 25
Silt	0.28 - 0.36	0.12 - 0.22	0.16 - 0.20	8 - 11	22 - 26
Silt clay loam	0.30 - 0.37	0.17 - 0.24	0.13 - 0.18	8 - 11	22 - 27
Silty clay	0.30 - 0.42	0.17 - 0.29	0.13 - 0.19	8 - 12	22 - 28
Clay	0.32 - 0.40	0.20 - 0.24	0.12 - 0.20	8 - 12	22 - 29

$$*TEW = (\theta_{FC} - 0.5 \theta_{WP}) Z_e$$

Figure 4.7 – Caractéristiques hydriques et d'évaporation en fonction des différents types de sol, issues de la FAO-56 [153]

#### 4.2.2.2 Initialisation de la RU : Quelle méthode ?

L'initialisation du remplissage de la réserve utile est une étape clé pour modéliser le bilan hydrique des cultures. Elle consiste à estimer la quantité d'eau disponible dans le sol au début de la simulation, soit au 1 janvier dans notre cas. Nous avons donc évalué 3 méthodes de remplissage initial de la RU : remplissage à 0 % , à 100 % au 1<sup>er</sup> janvier et remplissage à partir de simulations de l'année n-1. Cette méthode consiste à simuler le bilan hydrique de l'année n-1, avec le modèle SAMIR. Nous avons évalué l'impact de ces initialisations sur les ETR journalières.

#### 4.2.2.3 Apport du FCover satellitaire

Dans les approches basés sur la FAO-56, une relation empirique permet de relier le FCover au NDVI. Cependant, cette relation [Équation 4.14], est basée sur deux coefficients a et b, estimés à partir de mesures in-situ rendant cette équation peu extrapolable à d'autres sites. Afin de s'affranchir de cette limitation, nous avons décidé de remplacer le FCover estimé empiriquement ( $F_{cover_{emp}}$ ) par celui issu directement des réflectances satellitaires ( $F_{cover_{sat}}$ ). Nous avons généré le produit FCover au moyen de l'outil BVNet et des réflectances de surface Sentinel-2, le tout au travers du logiciel SeNtinel Application Platform (SNAP) [<https://step.esa.int/main/toolboxes/snap/>]. L'outil BVNet (« Biophysical Variables Neural NETWORK ») développé par l'INRAE présenté dans l'article [165, 166] a démontré son efficacité pour estimer le Fcover de différentes cultures [167–169].

#### 4.2.2.4 Impact de la profondeur d'enracinement maximale sur l'ETR et les volumes irrigués

Nous avons également cherché à évaluer l'impact de  $maxZr$  sur la modélisation des ETR. Pour cela, nous avons conduit une étude de sensibilité en faisant varier le paramètre  $maxZr$  sur une gamme de 800 mm à 1500 mm. Le choix de la gamme de variation du  $maxZr$  est issue des mesures effectuées sur cette parcelle par la ferme de Lamothe (Ecole d'Ingénieur de Purpan). La profondeur maximale d'enracinement varie entre 1000 mm et 1500 mm (Figure 2.15).

Notre objectif étant la spatialisation du modèle SAMIR, nous avons choisi d'évaluer 2 sources de données pédologiques : la carte Global Soil Map (GSM) et la carte du  $RRP_{UTS}$  présentées dans la section 2.3.3. La RU a été calculée à partir des fonctions de pédotransfert proposées par Bruand et al [88] pour le  $RRP_{UTS}$  et de Dobarco et al [107] pour les données GSM.

#### 4.2.2.5 Évaluation des pratiques d'irrigations : dates et doses d'irrigation

Au cours de ce travail, nous avons évalué le module d'irrigation sur la parcelle expérimentale. Pour cela, nous avons activé le mode d'irrigation automatique du modèle et comparé les doses appliquées par le modèle à celles renseignées par l'agriculteur.

#### 4.2.2.6 Spatialisation du modèle à l'échelle du bassin versant

Pour finir, nous avons évalué la capacité du modèle à spatialiser les volumes irrigués à l'échelle des BV étudiés. Pour cela, nous avons utilisé les données pédologiques GSM avec une profondeur d'enracinement fixe.

Pour l'assolement, nous avons utilisé le RPG pour le BV de la Neste, afin de récupérer l'ensemble des parcelles de maïs et la cartographie des surfaces irriguées sur le BV d'Adour Amont.

#### 4.2.2.7 Initialisation des paramètres d'entrée du modèle

Les valeurs d'initialisation des paramètres du modèle sont consignées dans les tableaux 4.1 & 4.2.

Les paramètres de la relation NDVI/Kcb sont issus de Toureiro et al, [170] . Ils ont été établis pour du maïs irrigué en Espagne à partir de données Sentinel-2.  $Z_e$ ,  $Z_{rmin}$  et  $Z_{soil}$  ont été fixés à l'aide des tables de la FAO-56 [153, 154]. Ils sont identiques pour toutes les parcelles.

$\theta_{fc}$ ,  $\theta_{wp}$ ,  $Z_{rmax}$  ont été estimés à partir de mesures terrain et de cartes pédologiques.

Table 4.1 – Liste des paramètres du modèle SAMIR, avec leurs annotations, leurs définitions et la source de la donnée, les données en gras correspondent à celles utilisées pour la spatialisation

	Paramètres	Définition	Source de la donnée
Paramètre de sol	$\theta_{fc}$ [ $m^3.m^{-3}$ ]	Capacité au champ	Observation terrain <b>GSM/RRP<sub>UTS</sub></b>
	$\theta_{wp}$ [ $m^3.m^{-3}$ ]	Point de flétrissement	Observation terrain <b>GSM/RRP<sub>UTS</sub></b>
	Init RU [%]	Initialisation du contenu en eau du sol	0/100/n-1
	Ze [mm]	Profondeur de l'horizon évaporateur	FAO-56
	$Zr_{min}$	Profondeur minimale de la zone racinaire	FAO-56
	$Zr_{max}$	Profondeur maximale de la zone racinaire	Observation terrain <b>GSM/RRP<sub>UTS</sub></b>
	REW	Quantité d'eau facilement évaporable	FAO-56
	p [%]	Capacité de rétention d'eau	FAO-56
	Zsoil [mm]	Profondeur totale de sol	FAO-56
Paramètre de végétation	A Kcb	Coefficient 'a' de la relation linéaire NDVI/kcb	Toureiro et al [170]
	b Kcb	Coefficient 'b' de la relation linéaire NDVI/kcb	Toureiro et al [170]
Paramètre d'irrigation	FW [%]	Fraction de sol mouillé par l'irrigation	FAO -56
	Lame eau [mm]	Quantité d'eau ajoutée par l'irrigation	Expertise terrain
	Interval day [j]	Intervalle de temps entre deux irrigations	Expertise terrain

Table 4.2 – Initialisation des paramètres du modèle selon les cas d'étude.

	Paramètres	Lamothe	Partenaires	ASA
Paramètre de sol	$\theta_{fc}$ [ $m^3.m^{-3}$ ]	0.373	GSM/RRP <sub>UTS</sub>	GSM/RRP <sub>UTS</sub>
	$\theta_{wp}$ [ $m^3.m^{-3}$ ]	0.175	GSM/RRP <sub>UTS</sub>	GSM/RRP <sub>UTS</sub>
	Init RU [%]	0/100/n-1	100	100
	Ze [mm]	150	150	150
	$Zr_{min}$	150	150	150
	$Zr_{max}$	1200	GSM/RRP <sub>UTS</sub>	GSM/RRP <sub>UTS</sub>
	REW	8	Merlin	Merlin
	p [%]	0.55	0.55	0.55
	Zsoil [mm]	3000	3000	3000
Paramètre de végétation	A Kcb	1.46	1.46	1.46
	b Kcb	-0.25	-0.25	-0.25
Paramètre d'irrigation	FW [%]	100	100	100
	Lame eau [mm]	Obs.	30	30
	Interval day [j]	Obs.	10	10

## 4.3 Résultats et Discussion

### 4.3.1 Évaluation de l'évapotranspiration

#### 4.3.1.1 Formalisme de Merlin et al vs FAO-56

Pour évaluer l'apport du formalisme de Merlin et al [159, 164] et Amazirh et al [142] par rapport à celui de la FAO-56, nous avons comparé les flux d'ETR modélisées à ceux mesurées sur la parcelle expérimentale de Lamothe.

La figure 4.8 présente la comparaison des ETR mesurées et simulées par SAMIR pendant la période de croissance, en utilisant les deux approches. Des performances similaires sont observées. La même tendance est observée sur les dynamiques temporelles (cf Annexe 8).

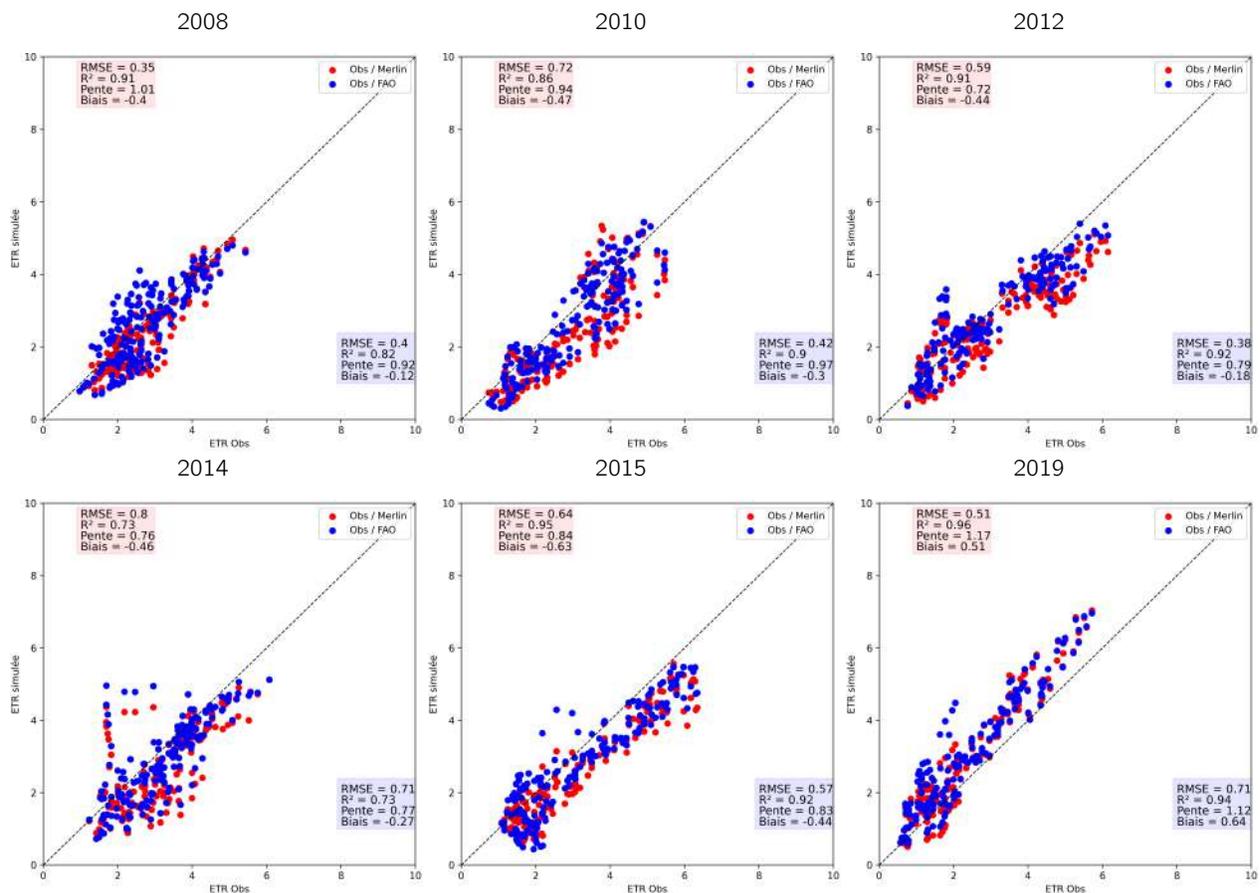


Figure 4.8 – **ETR mesurées et modélisées, selon la méthode FAO ou Merlin et al** Les points bleus correspondent aux résultats issus du formalisme FAO. Les points rouges correspondent aux résultats issus du formalisme de Merlin et al [159, 160]

Nous observons que la dynamique du Kr en fonction du contenu en eau dans la couche Ze est différente selon l'approche utilisée (Figure 4.9). Les valeurs de Kr défini par Merlin et al, n'atteignent jamais la valeur 1. En observant les dynamiques des humidités du sol mesurées par les sondes tensiométriques situées sur la parcelle Lamothe à différentes profondeurs (0, 5 et 10 cm), nous constatons que le contenu en eau de cette couche, n'est jamais supérieur à l'humidité à saturation (ligne noire), comme illustré par la figure 4.10. Au vu de ces dynamiques, nous pouvons conclure que, dans notre cas d'étude, le formalisme de la FAO-56, conduit à une surestimation de Kr.

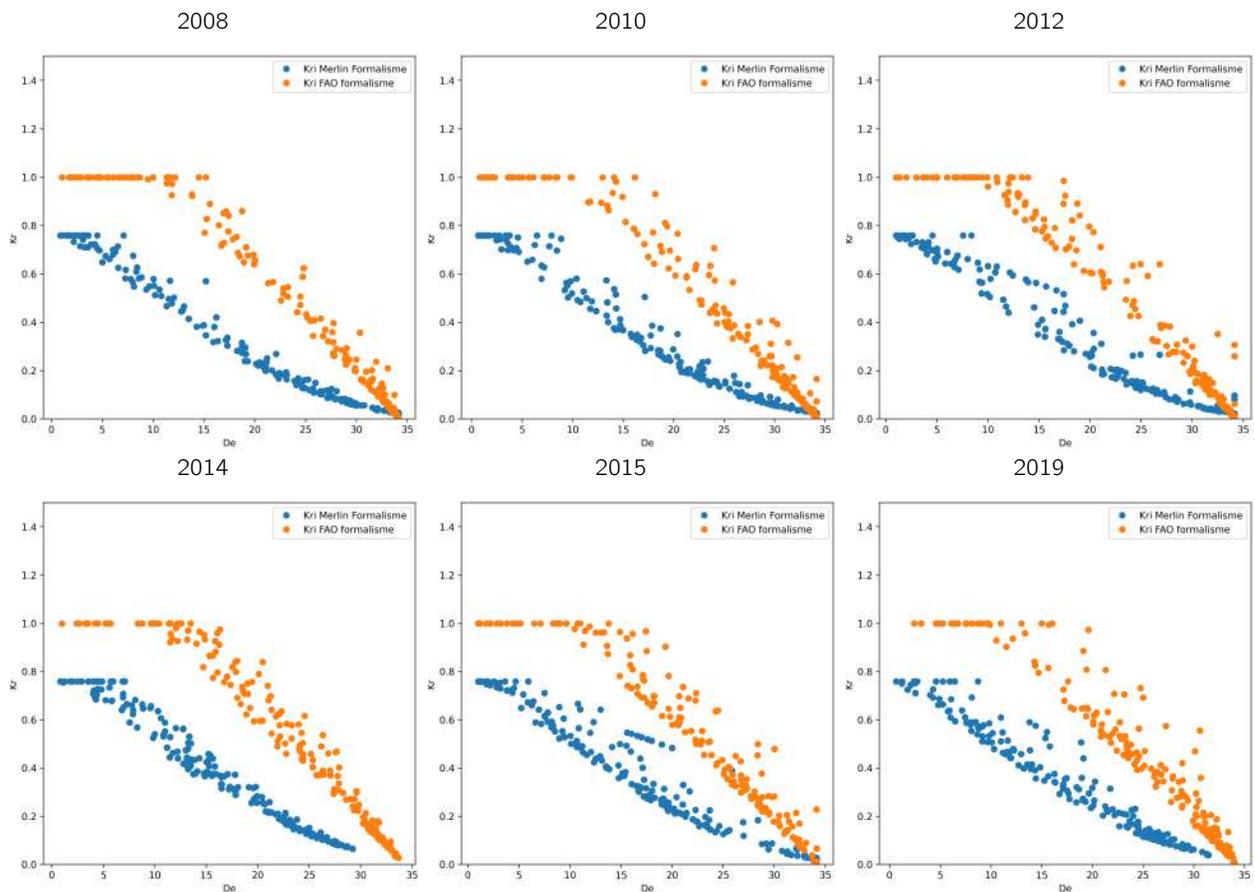


Figure 4.9 – **Dynamique du coefficient  $K_r$  en fonction du déficit en eau dans l'horizon évaporateur ( $D_e$ ).** Les points bleus illustrent l'approche développée par Merlin et les points orange correspondent à la méthode FAO-56.

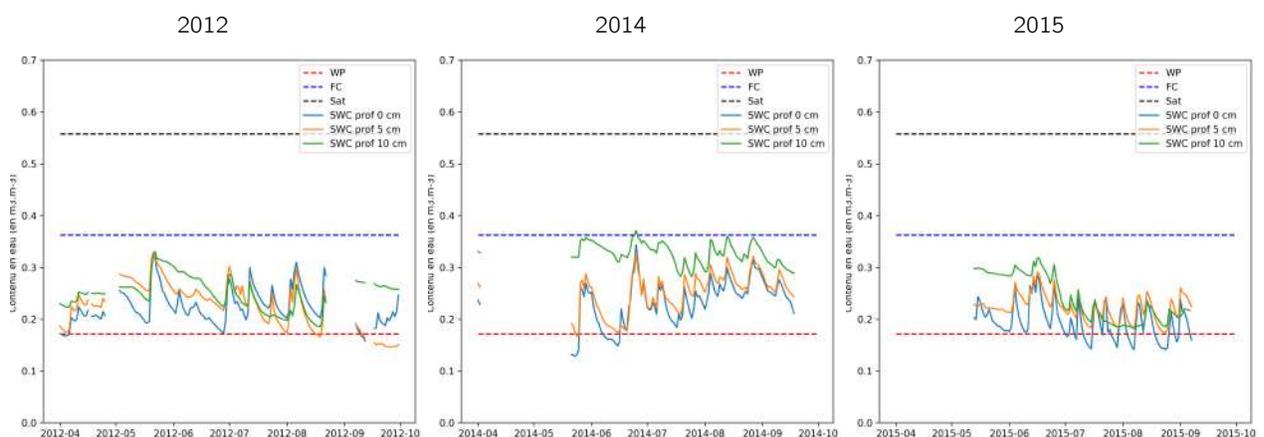


Figure 4.10 – **Dynamique du contenu en eau du sol issues des sondes à différentes profondeurs.** Les courbes bleue, orange et verte correspondent respectivement à l'humidité du sol à 0, 5 et 10 cm de profondeur.

#### 4.3.1.2 Sensibilité du modèle aux valeurs d'initialisation de la Réserve Utile

La figure 4.11 illustre les ETR observées et simulées selon les 3 méthodes d'initialisation, pour 3 années : 2012, 2014 et 2015. Nous avons choisi ces trois années, car elles sont caractérisées par des conditions météorologiques différentes. Les résultats des autres années sont présentés en annexe 9.

Nous observons sur la figure 4.11, des différences significatives en 2012 et 2015 selon les méthodes utilisées. Cette différence apparaît pendant la phase de croissance maximale de la culture. En effet, pour ces années, nous observons une meilleure estimation des ETR lorsque la réserve utile est considérée pleine en début d'année, avec des RMSE respectifs de 0.42 mm et 0.51 mm contre des RMSE de 1.22 mm et 2.46 mm pour 2012 et 2015 lorsque la réserve est vide. En revanche, aucune différence n'est observable en 2014.

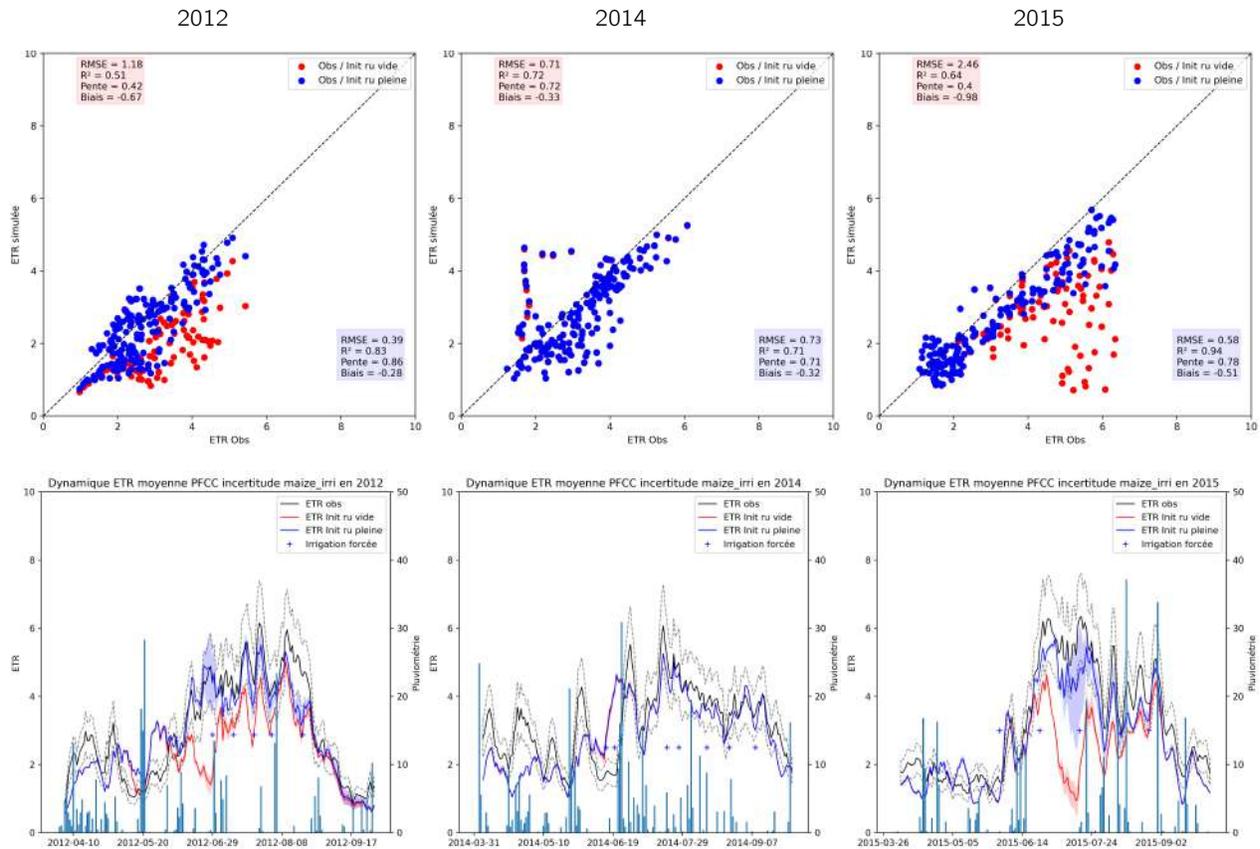


Figure 4.11 – Comparaison des ETR observés et modélisés, en fonction de l'initialisation de la réserve utile en début d'année. La courbe et les points rouges correspondent aux résultats issus de l'initialisation de la RU vide (RU = 0%). Les points et la courbe bleus illustrent les résultats issus de la simulation avec la RU pleine (RU =100 %). Quant à la courbe noire elle représente la dynamique journalière de l'ETR observé par la station. Les intervalles de confiance sont illustrés par les courbes en pointillées pour l'ETR observé et en bleu et rouge en fonction de l'initialisation de la RU.

En 2012 et 2015, les apports d'eau (pluie + irrigation) sont insuffisants pour remplir correctement le réservoir racinaire, ce qui se traduit par des ETR trop faibles et des déficits importants dans la zone racinaire, illustré par la figure 4.13. En effet, sur la figure nous constatons en 2012 et 2015, que la perte en eau dans l'horizon Zr (Dr) est supérieure à la quantité d'eau facilement utilisable pour la plante (RAW) et à la quantité d'eau totale dans le réservoir (TAW) et ce pendant une majeure partie du cycle de végétation. Ces fortes déficits ne sont pas compensés par des apports d'eau, entraînant une diminution de l'ETR. En revanche, nous constatons que la pluviométrie permet de compenser l'évaporation du sol nu en début de saison.

Les résultats de 2014, s'expliquent par une forte pluviométrie en début de saison culturale permettant de

compenser les pertes en eau liées à l'évaporation du sol et à la transpiration de la végétation. En effet, 2014 est une année très pluvieuse avec un cumul annuel de 780 mm, comparativement aux autres années, qui présentent un cumul annuel moyen de 640 mm. Nous observons également pour cette année, un écart entre le flux d'ETR observé et celui modélisé autour du mois de juin. Cet écart semble être causé par un surplus d'irrigation renseigné par l'agriculture mais non appliqué sur la parcelle. Ce surplus d'irrigation entraînant une surestimation de l'ETR modélisée observable sur la figure 4.11. Cette irrigation supplémentaire n'est pas observable sur les dynamiques des sondes d'humidité du sol (Figure 4.17), où nous constatons que le signal d'humidité du sol en surface ne réagit pas à la deuxième irrigation (fin juin).

La seconde hypothèse est liée à la présence de mouillère sur la parcelle (cf Figure 4.12), qui limite le flux évaporateur du sol nu, qui est majoritairement présent à cette période.



Figure 4.12 – Photographie de la parcelle de Lamothe le 25 juin 2014. ©CESBio

Pour les autres années de maïs, les résultats illustrent la même tendance que pour les années 2012 et 2015 (cf Annexe 10).

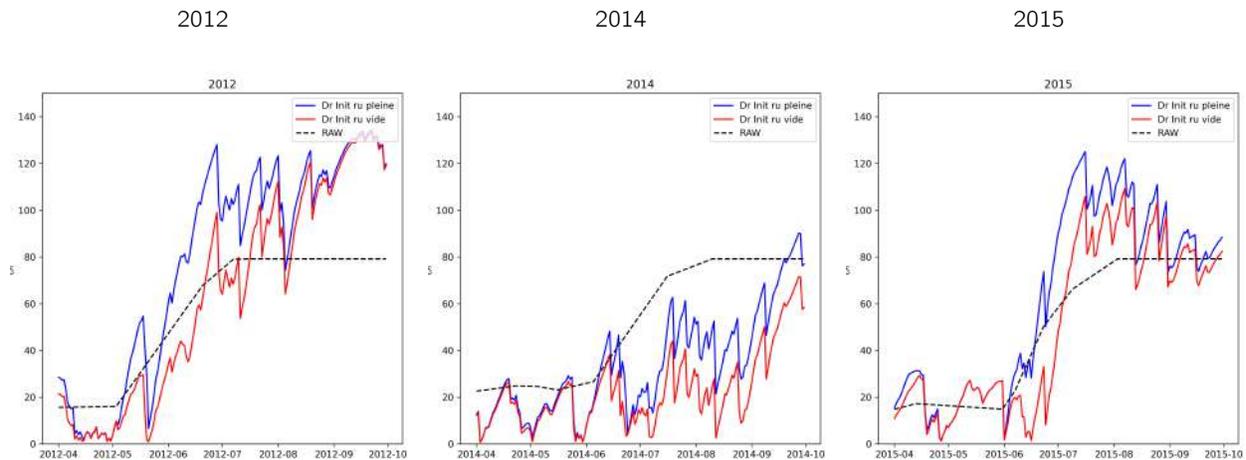


Figure 4.13 – **Dynamique du coefficient  $K_s$ , des déficits en eau dans l'horizon racinaire, en fonction du remplissage de la RU en début de simulation.** Les courbes en pointillés correspondent au coefficient de stress ( $K_s$ ). Les courbes en trait plein correspondent au déficit en eau dans l'horizon racinaire et celle avec un trait discontinu au contenu en eau facilement accessible par la plante soit RAW. La couleur bleu correspond aux simulations avec une réserve utile pleine et celle en rouge à une réserve utile vide.

La figure 4.14 illustre la comparaison des flux d'ETR observés et simulés en fonction des deux autres valeurs d'initialisation (100% et  $RU = N-1$ ) de la réserve utile pour 3 mêmes années. Nous observons qu'il y a aucune différence significative entre les deux méthodes d'estimation de la réserve utile initiale et ce pour 2014 et 2015. Seule l'année 2012 présente un léger écart d'estimation d'ETR lorsque le contenu en eau de la RU est simulé avec l'année n-1. Cette écart est dû à une estimation de la réserve utile initiale différente avec pour l'année n-1 une estimation de celle-ci de 40 %, contre 100 % pour l'approche standard. Malgré, cette écart d'estimation, nous pouvons constater que les ETR modélisées restent très similaires.

Cette méthode d'estimation du contenu en eau dans la réserve utile permet de tenir compte de la variabilité inter-annuelle des précipitations. Néanmoins, pour mettre en place cette méthode, il est impératif de connaître l'occupation du sol de l'année n-1. Pour les trois autres années étudiées, les résultats sont observables en annexe 10 et illustrent une tendance similaire, avec des RMSE et biais similaires entre les deux méthodes.

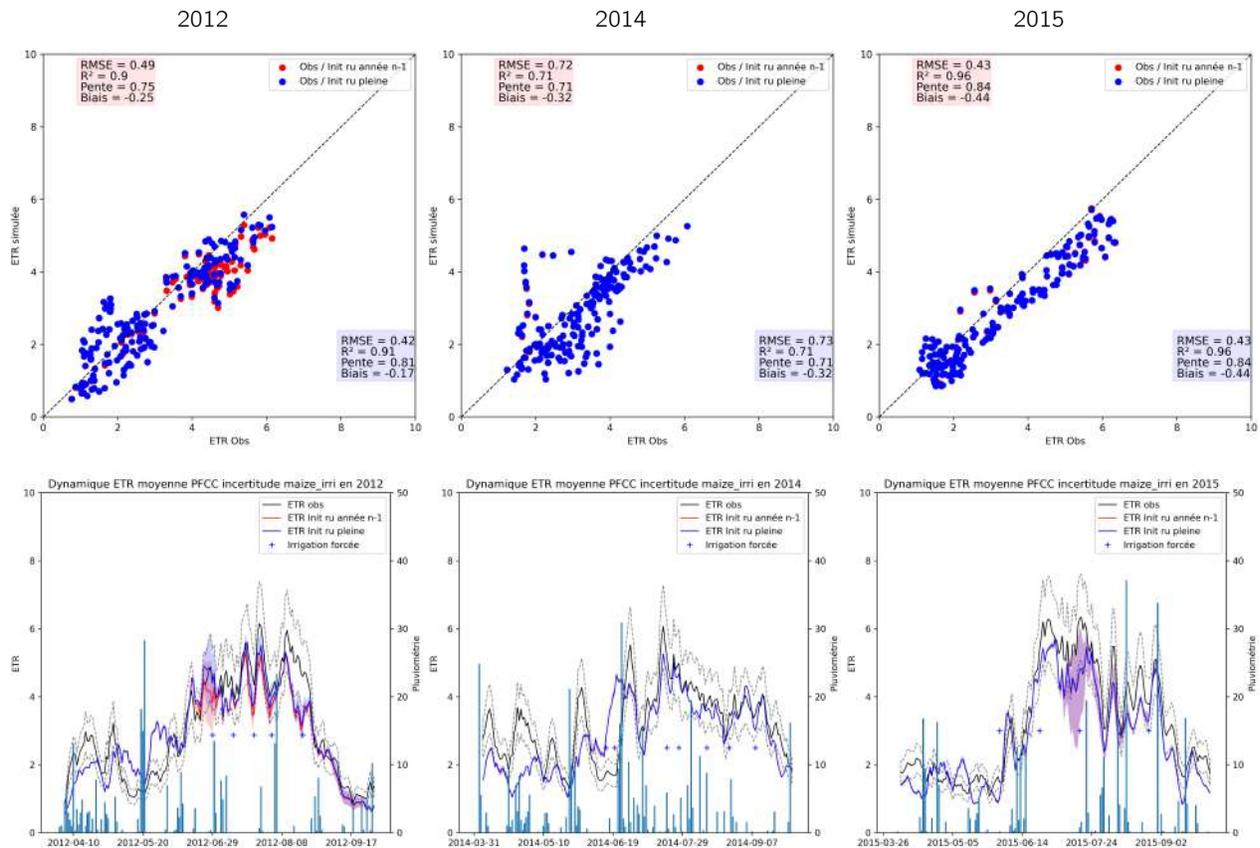


Figure 4.14 – **Comparaison des ETR observés et modélisés, en fonction de l'initialisation de la réserve utile en début de simulation.** La courbe et les points bleus correspondent aux résultats issus de l'initialisation de la RU pleine (RU = 100%). Les points et la courbe rouges illustrent les résultats issus de la simulation avec la RU initialisé avec l'année N-1 (RU = N-1 %). Quant à la courbe noire elle représente la dynamique journalière de l'ETR observée par la station. Les intervalles de confiance sont illustrés par les courbes en pointillées pour l'ETR observé et en bleu et rouge en fonction de l'initialisation de la RU.

#### 4.3.1.3 Impact du FCover satellite sur l'estimation de l'ETR

Les deux méthodes d'estimation du FCover conduisent à des ETR similaires, comme illustré dans la figure 4.15. L'utilisation de BVNet pour estimer un FCover est plus robuste, car elle ne repose pas sur l'utilisation de mesures in-situ pour la calibration du modèle. De plus, l'utilisation du  $Fcover_{sat}$  tient compte des variabilités spatiales du couvert sans dépendre du NDVI [171].

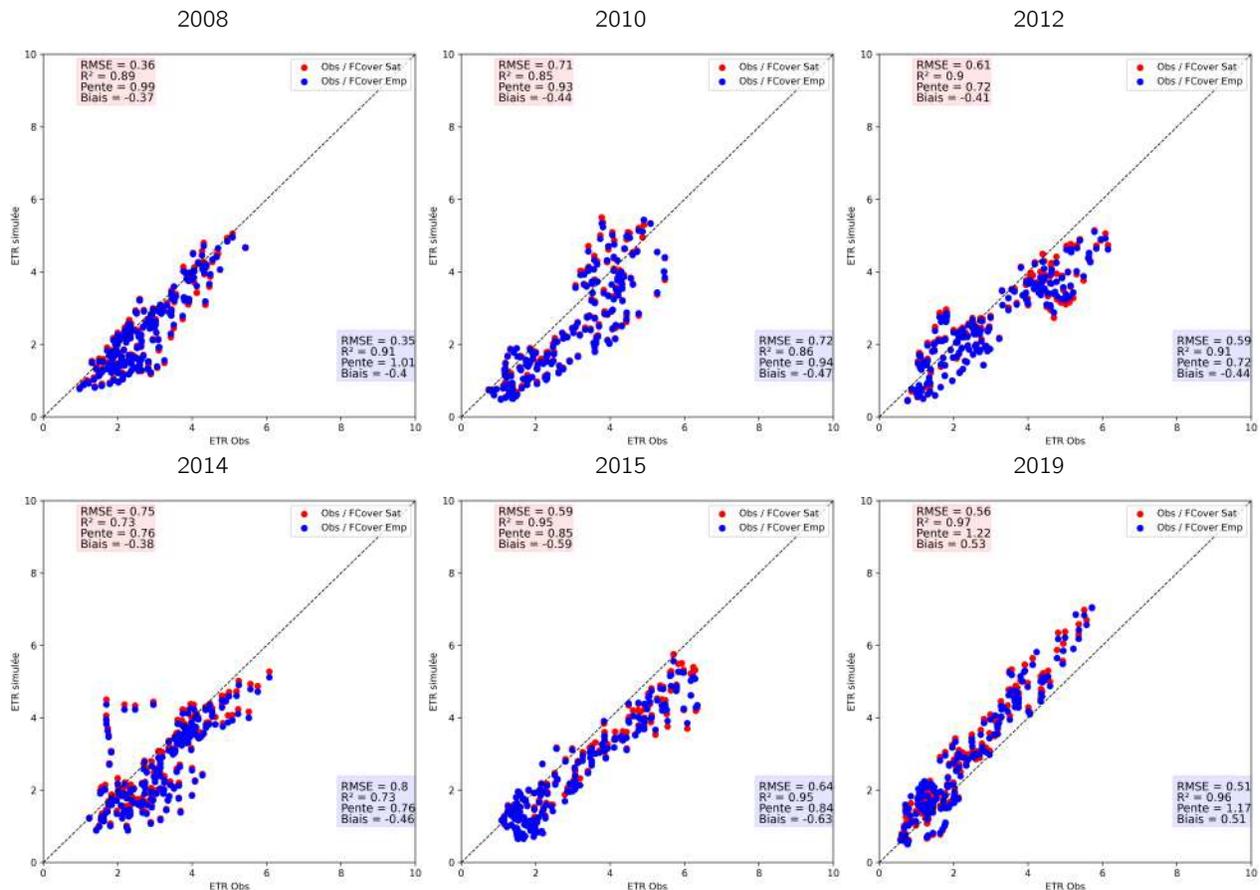


Figure 4.15 – **Comparaison des ETR observées et modélisées, en fonction deux méthodes de calcul du Fcover.** Les points bleus illustrent les résultats issus des simulations utilisant la  $Fcover_{emp}$ . Quant aux points rouges, ce sont les résultats avec le  $Fcover_{sat}$  qui sont illustrés.

#### 4.3.1.4 Variation de l'enracinement maximal, impact sur l'irrigation

Les résultats présentés dans la figure 4.16, illustrent les 3 mêmes années et révèlent que l'ETR est faiblement sensible à la profondeur d'enracinement pour des profondeurs supérieures 1 000 mm. En revanche, pour des plus faibles profondeurs d'enracinement ( $\leq 1\ 000$  mm), les résultats relèvent une plus forte sensibilité de l'ETR, car le système racinaire ne peut pas prospecter plus en profondeur pour prélever suffisamment d'eau. Cette forte sensibilité est observable sur l'année 2015, avec une forte chute de l'ETR au mois de juillet, ainsi qu'une augmentation du stress hydrique (trait en pointillé bleu). Nous constatons également sur les autres années (2012 et 2014) que le stress hydrique est significativement plus important pour un  $maxZr$  égal à 800 mm. Les résultats pour les années 2008, 2010 et 2019 sont observables en annexe 11 et illustrent la même tendance.

Pour les valeurs de  $maxZr$  comprises entre 1000 et 1500 mm, nous ne constatons aucune différence significative. Cependant une profondeur d'enracinement de 1500 mm permet une bonne estimation du flux d'ETR avec des RMSE plus faibles que pour un  $maxZr$  de 1000 mm.

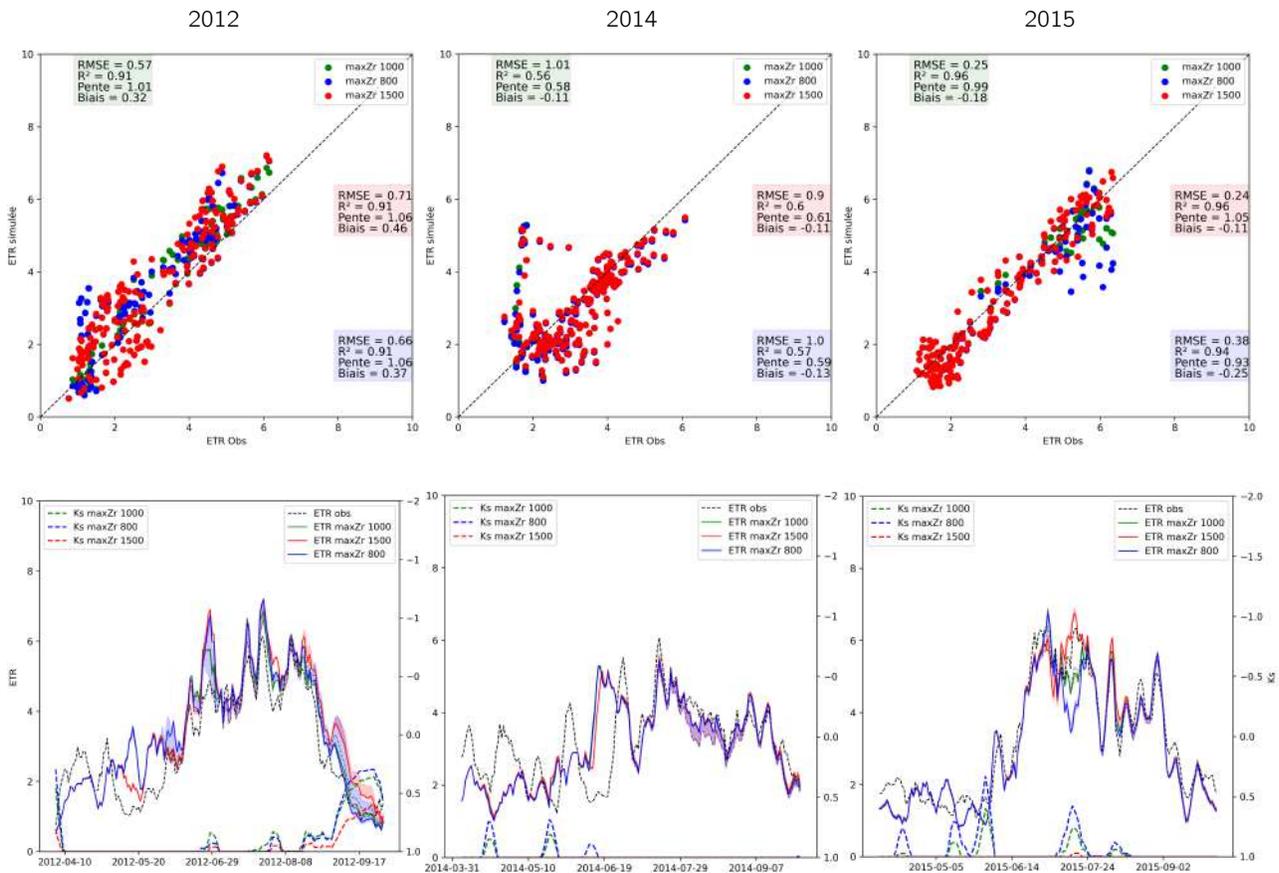


Figure 4.16 – **Comparaison des ETR observées et modélisées, en fonction de maxZr sur la parcelle de Lamothe**, Les différents couleurs des points représentent la comparaison des ETR journalières (modélisées vs observées) en fonction de la profondeur d'enracinement maximale, avec en bleu maxZr = 800 mm, en vert 1000 mm et en rouge 1500 mm. Les courbes illustrent les dynamiques journalières des ETR en fonction de maxZr, et celles en pointillés correspondent aux dynamiques de Ks. Les intervalles de confiance sont illustrés par les courbes en pointillés bleue, rouge et verte en fonction de la valeur de maxZr

#### 4.3.1.5 Évaluation des pratiques d'irrigations : doses d'irrigation

Au vu des résultats sur la sensibilité de l'ETR à la variation du maxZr, nous avons conclu que l'ETR était peu sensible à la variation du maxZr lorsqu'il est supérieur à 1000 mm. En revanche, nous avons analysé la sensibilité du déclenchement de l'irrigation en fonction du maxZr (1000 et 1500 mm). Pour cela, nous avons comparé les doses d'irrigations déclarées par l'agriculteur à celles simulées par le modèle (mode automatique). Nous constatons sur le tableau 4.3 que le nombre d'irrigations déclenchées par le modèle est semblable à celui fourni par l'agriculteur pour les années sèches soit 2010, 2012 et 2015. Pour les années pluvieuses, les irrigations modélisées sont moins nombreuses que celle renseignées par l'agriculteur, avec des différences importantes en 2014 et 2019. Pour 2014, des irrigations ont été déclarées, alors qu'aucun stress hydrique n'est simulé par le modèle, ni observable par les sondes tensiométriques (cf Figure 4.17) durant la période de végétation.

En 2008, nous observons une forte surestimation des irrigations modélisée. Cette surestimation est causée par un stress hydrique important lié à un manque d'eau durant la période de croissance (cf Figure 4.18). En analysant le contenu en eau de la plante estimé à partir des mesures de biomasse réalisées sur la parcelle expérimentale, nous constatons que celle-ci est identique par rapport aux autres années ( $\approx 70\%$  en 2008, 2012, 2014 et 2019,  $\approx 65\%$  en 2010 et 2015), ce qui exclut la présence de stress hydrique. De plus, nous constatons sur la figure 4.18, une augmentation de l'humidité du sol en surface fin juillet, qui n'est pas liée à un apport d'eau

(pluie et irrigation). Ces résultats montrent que l'agriculteur n'a probablement pas déclaré une à deux irrigations (début et fin juillet) sur cette période. Nous constatons également le fort impact du paramètre maxZr sur le déclenchement de l'irrigation et ce quelle que soient les années climatiques. Pour un maxZr de 1000 mm, nous observons une à deux irrigations de plus par rapport à un maxZr valant 1500 mm. Donc il est essentiel de bien estimer cette variable pour assurer une estimation cohérente des irrigations à l'échelle de territoires.

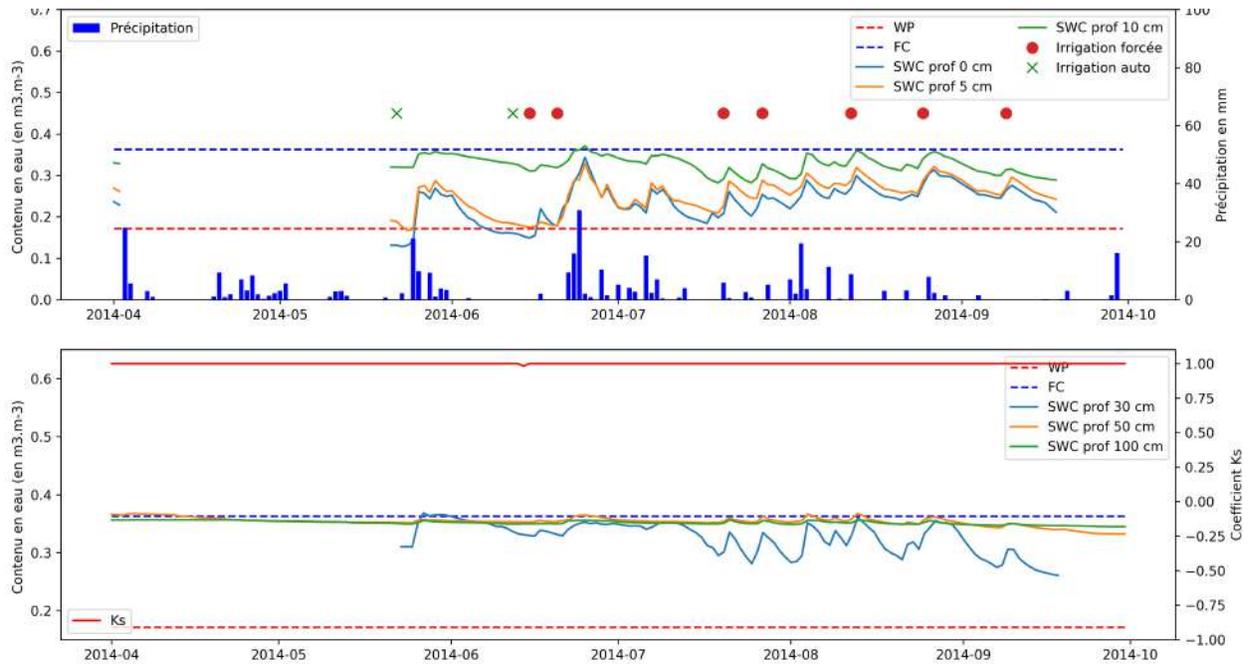


Figure 4.17 – **Dynamique de l'humidité du sol de la parcelle de Lamothe en 2014** ,Les courbes bleu, jaune et vert, illustrent la dynamique des humidités du sol à différentes profondeurs. La courbe rouge illustre la dynamique du Ks modélisée par SAMIR.

Suite aux résultats, nous pouvons estimer que les dates et doses d'irrigations sur cette parcelle, ne peuvent être utilisées pour calibrer et valider le module d'irrigation du modèle.

Table 4.3 – **Nombre d'irrigation simulées vs Irrigation observées sur la parcelle expérimentale en fonction de la profondeur d'enracinement maximale (maxZr)**

	maxZr = 1000 mm		maxZr = 1500 mm		Obs.		Précipitation
	Nb. Irrigation.	Quantité	Nb. Irrigation.	Quantité	Nb. Irrigation	Quantité	Quantité
<b>2008</b>	7	207	3	90	1	39	767
<b>2010</b>	6	178	4	120	4	130	633
<b>2012</b>	7	210	5	150	5	145	566
<b>2014</b>	2	49	2	58	7	175	780
<b>2015</b>	5	150	4	120	4	140	537
<b>2019</b>	4	120	2	60	5	200	681

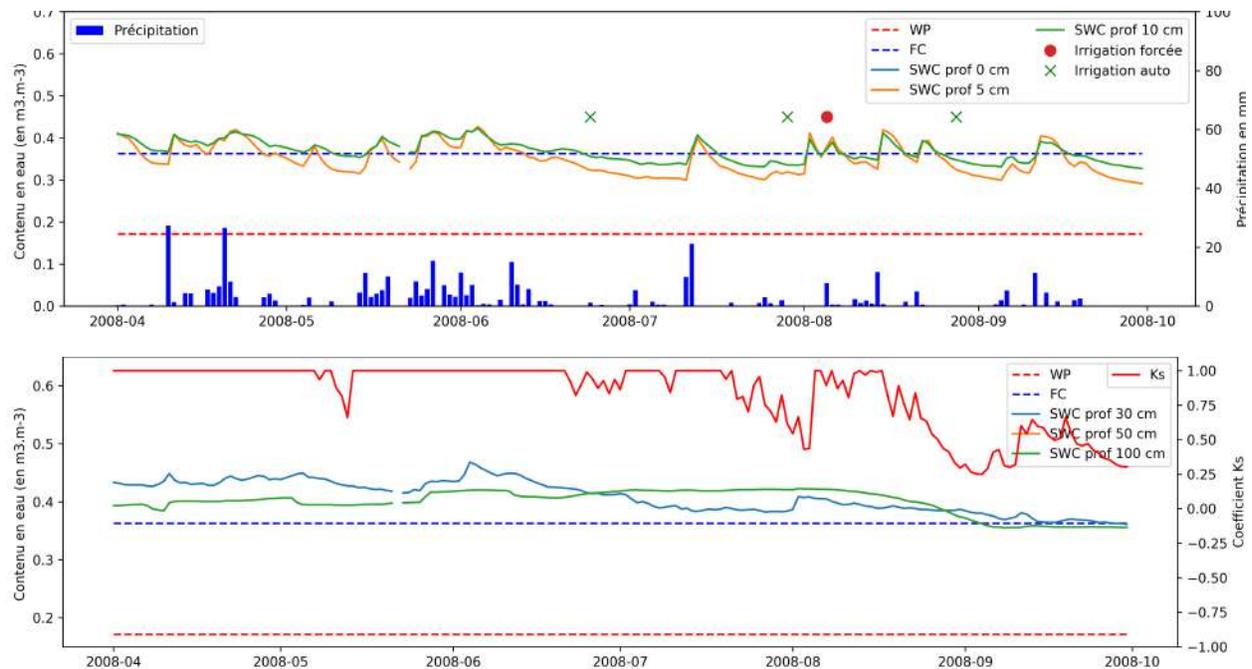


Figure 4.18 – **Dynamique de l'humidité du sol de la parcelle de Lamothe en 2008**, Les courbes bleu, jaune et vert, illustrent la dynamique des humidités du sol à différentes profondeurs. La courbe rouge correspond au coefficient de stress hydrique (Ks), Les croix et les ronds illustrent les événements d'irrigation (observés en rouge et simulés en vert)

Les dynamiques des sondes tensiométriques pour les 5 autres années sont observables en Annexe 12. Nous constatons sur ces figures que la capacité au champ est très rarement atteinte par les mesures dans l'horizon superficiel quelle que soit l'année. Pour les années sèches, nous observons que les événements des irrigations simulées sont proches de celle renseignées par l'agriculteur, en termes de quantité et de timing.

#### 4.3.1.6 Conclusion de la calibration du modèle sur la parcelle expérimentale

##### Ce qu'il faut retenir

- **Apport du formalisme Merlin par rapport à la FAO-56** : L'utilisation du formalisme de Merlin et al conduit à des ETR similaires au formalisme FAO-56. Toutefois cette approche qui s'appuie sur les propriétés du sol permet de s'affranchir du paramètre REW qui est souvent défini de façon arbitraire.
- **Sensibilité du modèle aux valeurs d'initialisation de la Réserve Utile** : Remplir la RU à 100% en début d'année ou l'initialiser à partir d'un bilan hydrique calculé l'année N-1 conduit aux mêmes résultats. L'utilisation de l'année N-1 nécessite cependant de connaître les occupations des sol l'année précédente.
- **Impact du Fcover satellite** : L'utilisation du  $Fcover_{sat}$  issu des images satellitaires conduit à des ETR similaires à celles obtenues à l'aide d'une relation empirique basée sur des mesures in-situ. L'utilisation des  $Fcover_{sat}$  est intéressante car elle s'affranchit de mesures in-situ.
- **Variation de l'enracinement maximale** : L'analyse de la variation du paramètre  $maxZr$  a démontré que pour de fortes valeurs d'enracinement (1 000 m à 1 500 mm), l'ETR était faiblement sensible à ces variations. En revanche, nous avons démontré que le déclenchement des irrigations était très sensible à  $maxZr$ , avec une augmentation de 64% des irrigations lorsque  $maxZr$  varie entre 1000 et 1500 mm
- **Validité des données d'irrigations** : Les résultats du modèle ont mis en évidence de probables incohérences dans les déclarations des irrigations sur la parcelle expérimentale pour les années pluvieuses, en particulier 2008 et 2014. En revanche sur les années sèches le modèle reproduit correctement les événements d'irrigation déclarés.

### 4.3.2 Spatialisation du modèle

Les analyses menées sur la parcelle expérimentale ont permis de quantifier l'impact de la profondeur maximale d'enracinement ( $maxZr$ ) sur les quantités irriguées. Dans cette partie, nous avons cherché à évaluer cet impact sur 85 parcelles et 4 ASA situées dans des contextes pédologiques variés, dans le Gers. Les quantités simulées par le modèle ont été comparées à celles fournies par les partenaires issues d'enquêtes et de relevés compteur.

Pour mener cette étude nous avons utilisé deux sources de données pédologiques : les cartes GSM et les cartes RRP, présentés dans la section 2.3.3. Nous avons donc évalué la complémentarité de ces différents jeux de données.

#### 4.3.2.1 Parcelles des partenaires

Les résultats obtenus avec la carte GSM sont illustrés dans la figure 4.19a. Nous constatons que l'utilisation de cette carte avec une RU calculée à partir d'une profondeur du sol, entraîne une sous-estimation des irrigations saisonnières (biais de -11 mm,  $rmse \approx 57$ ). Or il existe des différences nettes entre la profondeur de sol fournie par GSM et celle fournie L.Rigou ( $RRP_{UTS}$ ) (Figure 4.20b). Ainsi utiliser la profondeur du sol au lieu de la profondeur racinaire conduit à surestimer la RU comme illustré dans la figure 4.20a et par conséquent à sous estimer les volumes irrigués.

L'utilisation de  $RRP_{UTS}$  (avec les profondeurs d'enracinement et la cartographie des UTS), conduit à une forte surestimation des volumes irrigués (avec des  $rmse = 74$  mm et biais de 43) (figure 4.19b).

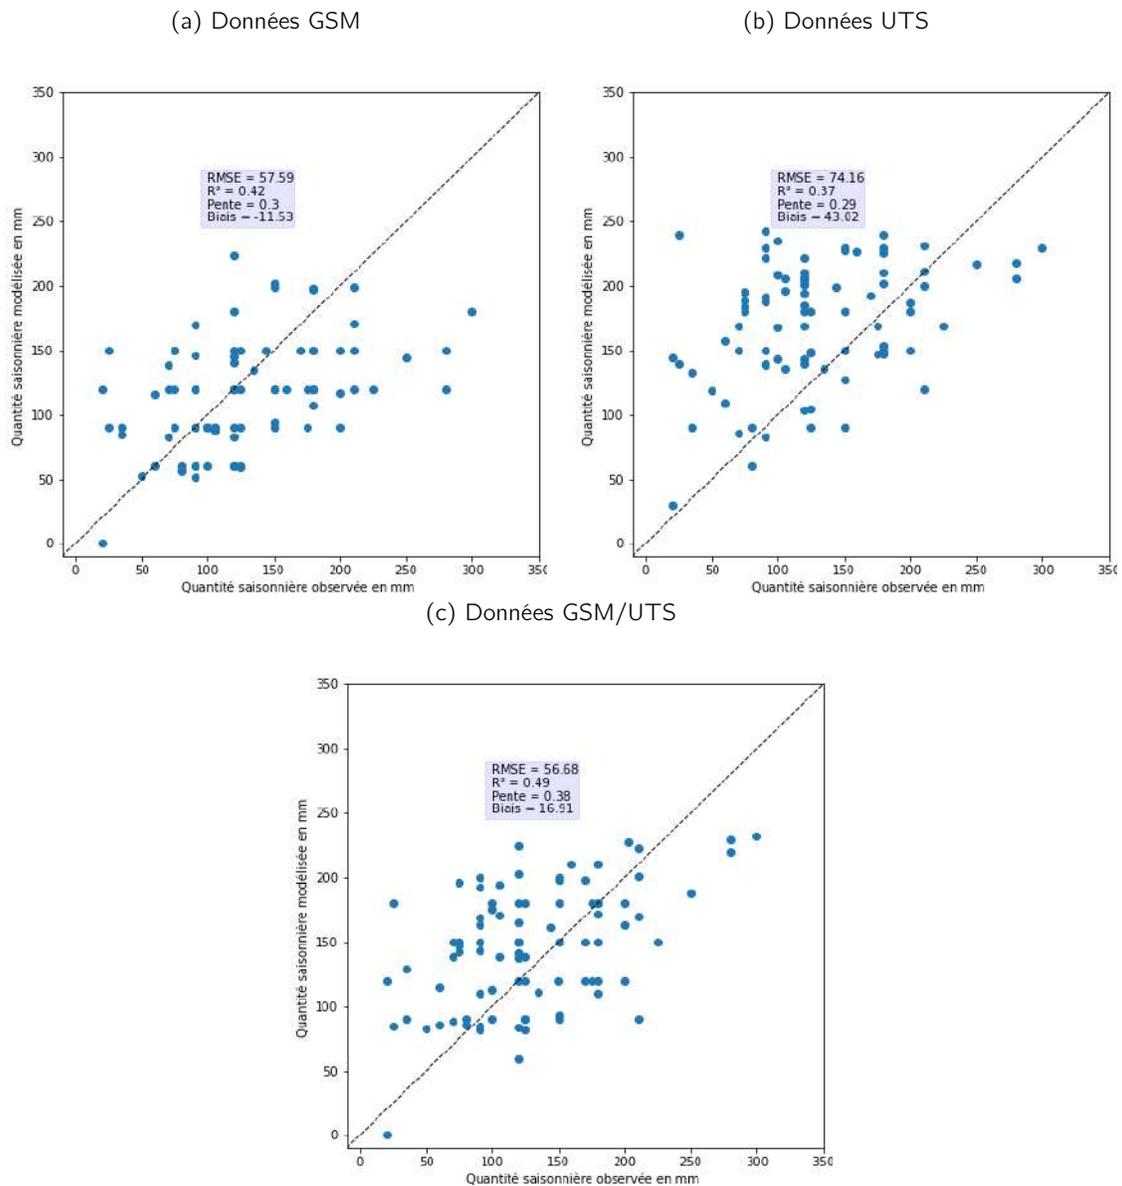


Figure 4.19 – **Comparaison des irrigations saisonnières observées et modélisées en fonction des données pédologiques** a) Utilisation des données GSM, soit les fonctions de pédo-transfert et la profondeur de sol), b) Utilisation des données  $RRP_{UTS}$ , soit les fonctions de pédo-transfert de Bruand et la profondeur d'enracinement maximale et c) Combinaison des données pédologiques avec les fonctions de pédo-transfert de GSM et la profondeur d'enracinement maximale du  $RRP_{UTS}$ .

Cette surestimation peut-être liée à une mauvaise estimation de la profondeur d'enracinement maximale, causée par un biais expérimentateur (selon L. Rigou). En effet, le protocole de mesure de la profondeur d'enracinement est basé sur une expertise visuelle du profil de sol prélevé avec une tarière. Or ce protocole de mesure limite l'échantillonnage de la colonne sol à 1.25 m, soit la longueur de la tarière. Nous constatons sur la figure 4.20b que les profondeurs d'enracinement maximale des données  $RRP_{UTS}$ , sont inférieures à 1.11 m, entraînant possiblement une sous-estimation des RU comme illustré sur la figure 4.20a.

La surestimation des irrigations peut-être également due à la fonction de pédotransfert utilisée, celle de Bruand. Cette fonction ne permet pas de restituer la variabilité des propriétés hydrodynamiques du sol, car elle repose sur des classes de valeurs pour les points de flétrissement (PF) et les capacités au champ (CC). Or cette

classification peut conduire à des évaluations erronées [172].

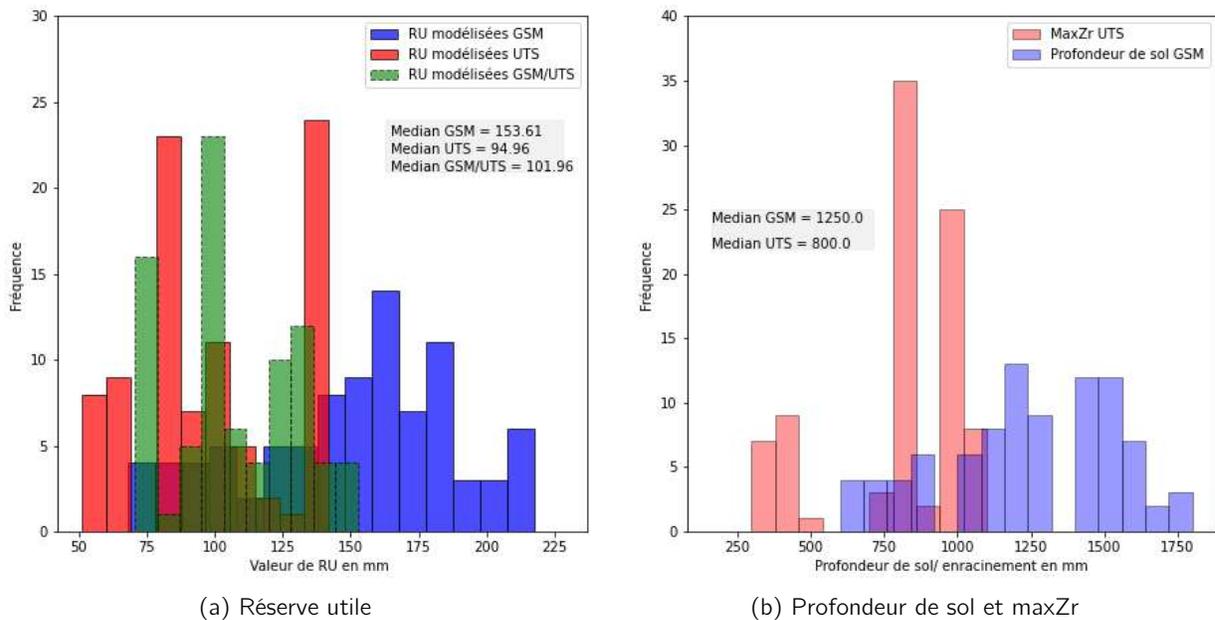


Figure 4.20 – Répartition des RU modélisées (a) et des maxZr et profondeur de sol (b) en fonction des données pédologiques. Les barres bleues correspondent aux RU modélisées et à la profondeur de sol à partir des données pédologiques de GSM et quant aux barres rouges, elles illustrent les RU modélisées et les maxZr issues des données pédologiques du RRP<sub>UTS</sub>. Les barres vertes correspondent aux RU modélisées selon les fonctions de pédotransfert de GSM et maxZr des données RRP<sub>UTS</sub>

Suite aux résultats obtenus avec les deux produits pédologiques, nous avons comparé les performances du modèle en forçant le maxZr avec celui du RRP<sub>UTS</sub> et pour estimer les propriétés hydrauliques du sol, nous avons utilisé les fonctions de pédotransfert de GSM. Les résultats sont illustrés dans la figure 4.19c. L'utilisation combinée des deux produits pédologiques conduit cette fois à une surestimation des quantités irriguées (RMSE  $\approx$  57 et biais de 16 mm).

Donc l'utilisation conjointe de GSM et du maxZr permet une meilleure estimation des quantités d'irrigation en fin de saison que l'utilisation des données GSM ou RRP<sub>UTS</sub> seule. Cependant, cette carte de maxZr n'est disponible que sur une partie de notre territoire d'étude. Donc nous avons également simulé les volumes irrigués en utilisant les valeurs de maxZr fournies par la FAO (Figure 4.21) avec la carte GSM. Les valeurs de maxZr données par la FAO, pour le maïs, varient entre 1 et 1.7 m

Crop	Maximum Root Depth <sup>1</sup> (m)	Depletion Fraction <sup>2</sup> (for ET ≈ 5 mm/day) p
<b>I. Cereals</b>		
Barley	1.0-1.5	0.55
Oats	1.0-1.5	0.55
Spring Wheat	1.0-1.5	0.55
Winter Wheat	1.5-1.8	0.55
Maize, Field (grain) ( <i>field corn</i> )	1.0-1.7	0.55
Maize, Sweet ( <i>sweet corn</i> )	0.8-1.2	0.50
Millet	1.0-2.0	0.55
Sorghum – grain	1.0-2.0	0.55
– sweet	1.0-2.0	0.50
Rice	0.5-1.0	0.20 <sup>4</sup>

Figure 4.21 – Valeurs de profondeur d'enracinement maximale (maxZr), et fraction d'épuisement de l'eau du sol (p), pour les cultures d'été.

Les résultats sont illustrés dans la figure 4.22 et dans le tableau 4.4. Nous constatons que les irrigations saisonnières modélisées à partir des données GSM sont proches de celles observées lorsque maxZr est comprise entre 1000 et 1100. Lorsque maxZr est supérieur à 1200 mm, nous observons une sous-estimation des irrigations modélisées.

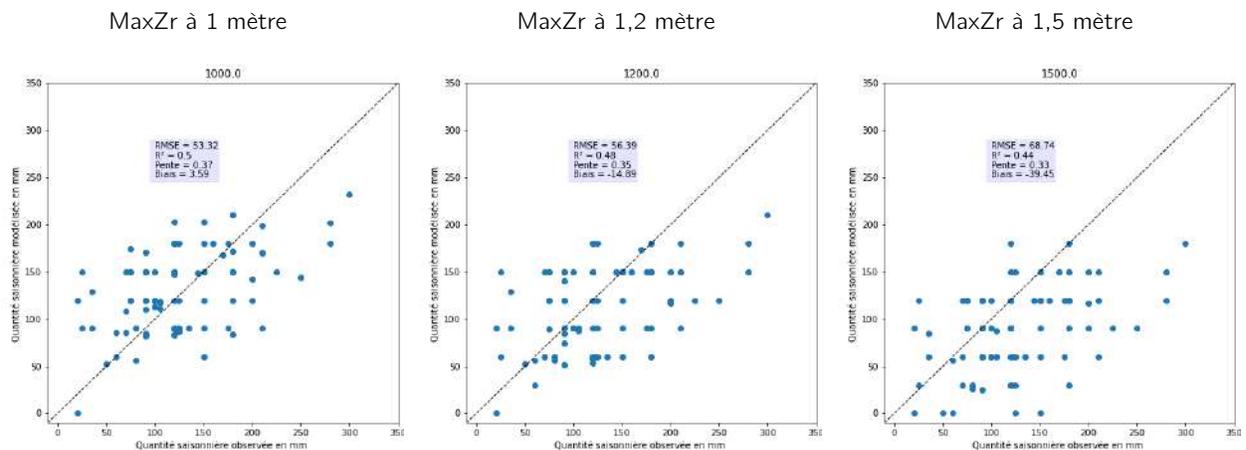


Figure 4.22 – Comparaison des irrigations saisonnières observées sur les parcelles des partenaires et ceux modélisées en fonction du forçage de maxZr selon la table 22 de la FAO-56 et des données GSM.

Table 4.4 – Valeurs des métriques d'évaluation issues de simulations avec différentes valeurs de maxZr, conseillées par le FAO-56.

	MaxZr						
	1000	1100	1200	1300	1400	1500	1600
<b>RMSE</b>	53.32	53.92	56.39	58.82	62.55	68.74	73.77
<b>R<sup>2</sup></b>	0.5	0.48	0.48	0.49	0.48	0.44	0.46
<b>Biais</b>	3.59	-5.1	-14.89	-22.98	-31	-39.45	-47.77

Suite aux résultats, pour simuler les volumes irrigués à l'échelle des BV, nous avons fixé le maxZr à 1000 mm.

#### 4.3.2.2 Périmètres irrigués

Nous avons simulé les volumes totaux irrigués sur quatre ASA et les avons comparé aux volumes prélevés fournis par la CACG pour 2017 et 2018. Pour effectuer ces simulations nous avons utilisé les données pédologiques issues de GSM et la profondeur d'enracinement du  $RRP_{UTS}$ .

La CACG estime qu'il y a une perte d'eau moyenne de 12% due soit à des fuites lors du transport de l'eau dans les tuyaux (environ 1-2%) soit au système d'irrigation par aspersion (environ 3-10 %). Nous avons donc retiré 12% aux volumes d'irrigation annuels fournis par la CACG (issus de relevés compteurs).

Les volumes modélisés sont plus proches des volumes observés en 2017 qu'en 2018. En 2017, les volumes irrigués de l'ASA de Miradoux sont surestimés de  $0.42 \text{ hm}^3$  d'eau. Les volumes irrigués pour les deux autres ASA sont sous-estimés par le modèle. Pour 2018, nous observons également une plus forte sous-estimation des volumes, avec un biais de  $3 \text{ hm}^3$ .

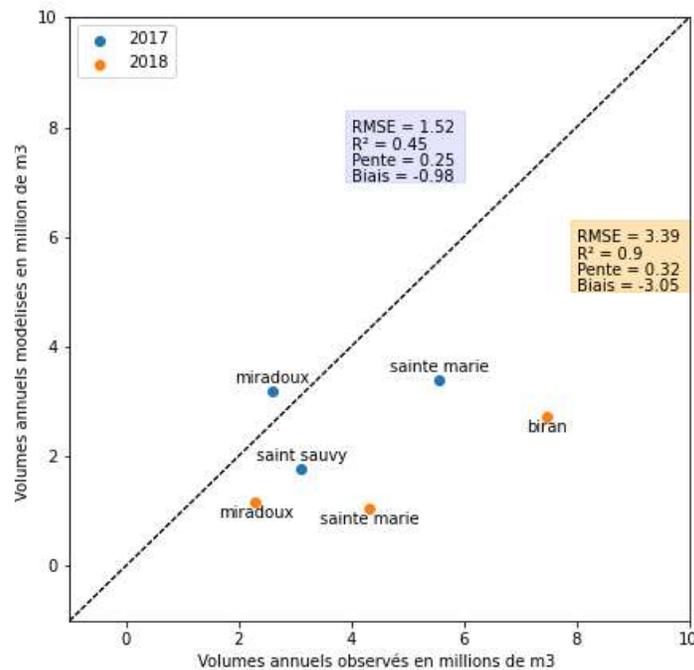


Figure 4.23 – **Comparaison des volumes totaux annuels observés et modélisés sur les ASA.** Les points bleus illustrent les résultats de l'année 2017 et ceux en orange de l'année 2018

Pour l'ASA de Saint-Sauvy en 2017, les volumes simulés sont légèrement sous-estimés comparé aux autres ASA simulés. La sous-estimation globale observée semble provenir d'une mauvaise paramétrisation du modèle pour les parcelles de soja. En effet, sur les ASA du département du Gers, le soja représente environ 50 % de la sole irriguée (Table 4.5). Et selon la FAO-56, les paramètres du modèle pour simuler le bilan hydrique du soja sont différents, avec un  $\max Z_r$  et un  $p$  plus faible. Cependant pour pouvoir modéliser les volumes d'irrigation annuels du soja, nous devons calibrer le modèle.

Une autre explication de la sous-estimation des volumes irrigués sur les ASA est une augmentation de la superficie des périmètres irrigués entre les années 2017 et 2018. En effet, la dynamique d'irrigation sur ce territoire est de l'ordre de + 5% et les périmètres irrigués transmis par la CACG date de 2017.

Table 4.5 – **Répartition des cultures irriguées sur chaque ASA étudié.** La surface de chaque culture est exprimée en ha et correspond à l'abréviation Surf. La proportion de chaque culture pour chaque ASA correspond au terme Prop. et est exprimée en %.

Culture	2017				2018			
	Maïs		Soja		Maïs		Soja	
ASA	Surf.	Prop.	Surf.	Prop.	Surf.	Prop.	Surf.	Prop.
Miradoux	30	35	55	65	26	27	77	80
Sainte Marie	54	37	94	64	33	34	64	65
Sainte Sauvy	34	51	31	47	Nan	Nan	Nan	Nan
Biran	Nan	Nan	Nan	Nan	110	58	80	42

### 4.3.3 Spatialisation à l'échelle du bassin versant

#### 4.3.3.1 Cas du bassin versant d'Adour Amont

La combinaison des images de télédétection avec un modèle agro-météorologique permet de fournir trois indicateurs essentiels pour aborder la gestion de la ressource en eau à l'échelle des bassins versants. Ces indicateurs sont : les surfaces irriguées, les volumes irrigués appliqués et les consommations en eau (ETR).

Les ETR ne peuvent pas être validées à l'échelle d'un bassin versant et il n'est pas non plus aisé de valider les surfaces et volumes irrigués à cette échelle. Néanmoins, nous disposons d'une estimation de volumes irrigués pour le BV Adour-Amont en 2017. Nous avons donc appliqué le modèle SAMIR sur l'ensemble des parcelles de maïs de ce BV. Les volumes totaux estimés par le modèle sont de l'ordre de  $13 \text{ hm}^3$ . Le volume prélevé issu de l'enquête de l'OUGC est de  $30 \text{ hm}^3$  (retour enquête : 40%).

Nous avons cartographié les quantités d'eau d'irrigation à l'échelle du bassin versant (Figure 4.24). Elles varient entre 30 mm et 180 mm. Nous observons une répartition Nord-Sud des parcelles de maïs irriguées. Les parcelles localisées au Nord de la zone d'étude, sont celles ayant des besoins en eau d'irrigation comprises entre 90 et 180 mm. Les parcelles localisées au Sud, proche du piémont, sont majoritairement non irriguées ou potentiellement irriguées, et les quantités d'eau d'irrigation des parcelles irriguées sont plus faibles, avec des doses totales  $\leq 60$  mm. Nous constatons également que sur les parcelles recevant une forte pluviométrie saisonnière ( $\geq 400$  mm) présentent des quantités d'eau d'irrigation faibles de l'ordre de 0 à 60 mm. Pour les zones ayant une faible pluviométrie, telles que le Nord et le centre est du bassin versant, les quantités d'eau d'irrigation sont plus importantes.

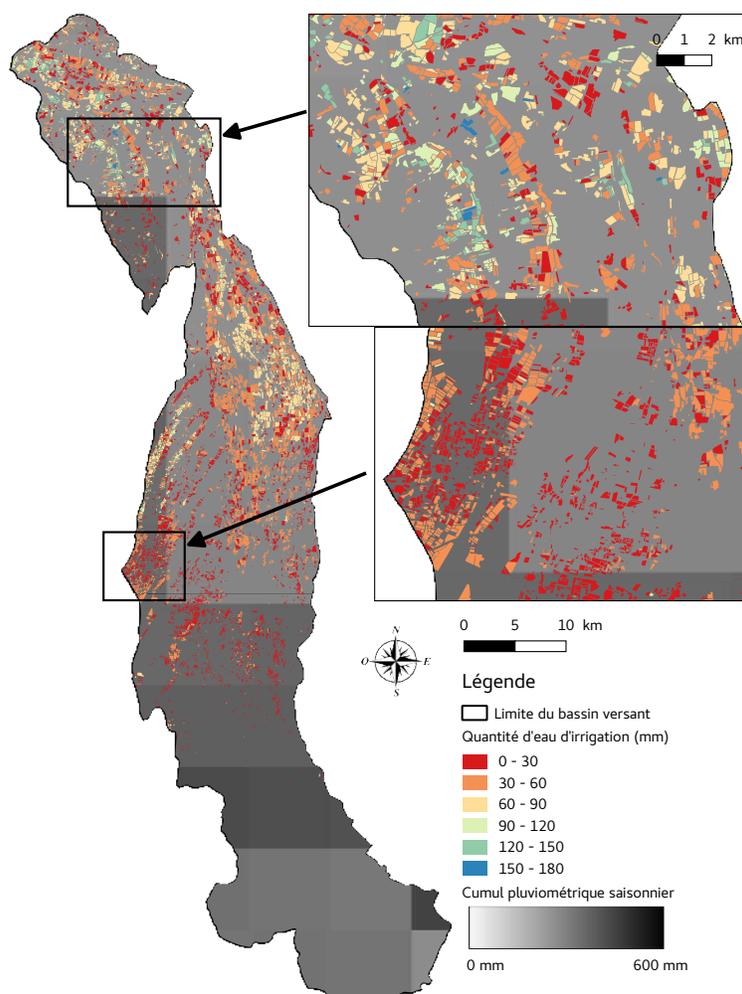


Figure 4.24 – **Cartographie des quantités d'eau d'irrigation du maïs irrigué issu du modèle SAMIR, sur le bassin versant de la Adour Amont en 2017**

Concernant la superficie totale de maïs irrigué, nous avons validé la cartographie des surfaces irriguées proposée par SAMIR en utilisant les données de références issues des 2 campagnes terrains effectuées par la CA 65 en 2017. Les résultats sont encourageants pour le maïs irrigué (Fscore de 81 %), mais mitigés pour le maïs pluvial (Fscore 26 %). La faible performance du modèle SAMIR pour détecter le maïs pluvial est liée à la surestimation de la RU et à la faible résolution spatiale des données pluviométrique. Nous avons constaté que les parcelles classées comme pluviales par le modèle SAMIR présentaient de plus fortes RU que pour les parcelles irriguées (170 mm contre 163 mm).

Étant donné, la surestimation du modèle sur le déclenchement des irrigations illustrée sur les parcelles des partenaires, nous avons décidé d'appliquer un seuil sur la quantité d'irrigation saisonnière. Ce seuil permet de définir une troisième classe de surfaces, nommée probable, elle correspond aux parcelles probablement irriguées, où la quantité d'eau d'irrigation apportée est inférieure à 60 mm. Ce seuil a été choisi car il correspond au RMSE des résultats précédents 4.3.2.1 et à l'apport d'eau de deux événements d'irrigations. Malheureusement, nous ne pouvons pas valider cette carte avec les 3 classes, néanmoins elle permet de fournir une incertitude sur la superficie du maïs irrigué à l'échelle du territoire, soit  $15\,194 \pm 7\,652$  ha. En comparant cette superficie avec celle obtenue avec la classification Random Forest (17 121 ha), nous constatons que un écart de 2 000 hectares entre les deux méthodes.

La carte 4.25 illustre, la cartographie des surfaces irriguées issue du modèle SAMIR.

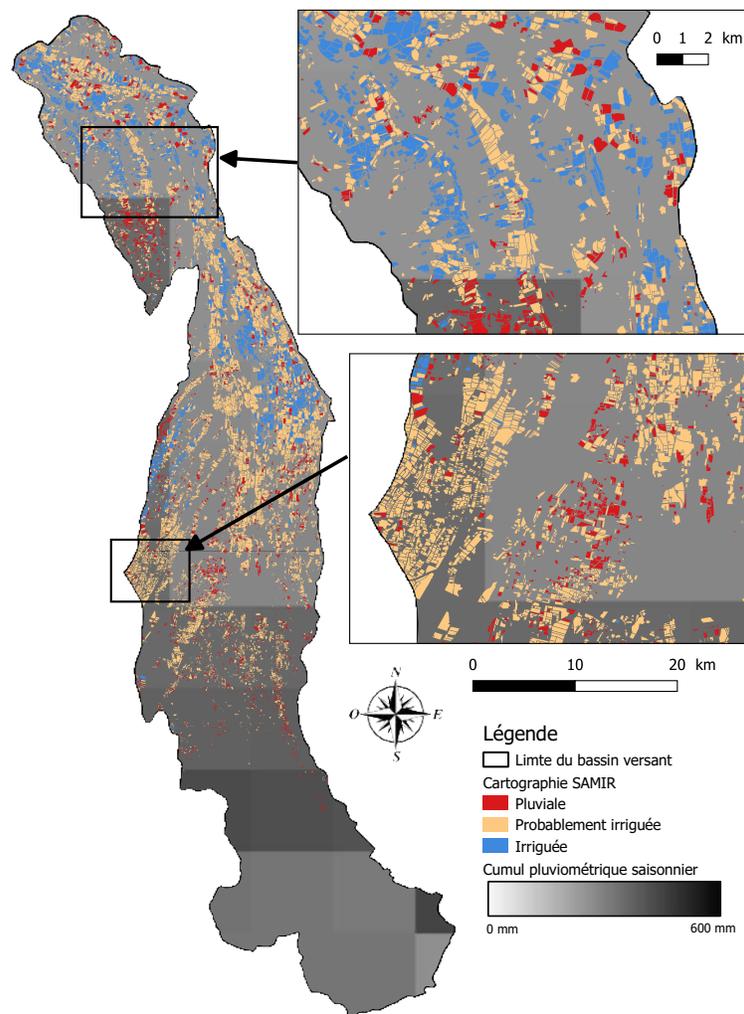


Figure 4.25 – **Classification du maïs irrigué issue du modèle SAMIR, avec l'application d'un seuil sur le bassin versant d'Adour Amont en 2017.**

#### 4.3.3.2 Cas du bassin versant de Neste

Nous avons également modélisé les quantités d'eau d'irrigation à l'échelle du bassin versant de la Neste sur le maïs en 2017. L'agrégation des résultats à l'échelle du bassin versant illustre une importante sous-estimation des quantités d'eau d'irrigation du maïs comparée à celle autorisée par l'OUGC, le modèle estime  $40 \text{ hm}^3$  contre  $148.33 \text{ hm}^3$  autorisés. Cette sous-estimation peut-être causée par l'absence du soja dans notre simulation et de la simplification du  $\text{maxZr}$  qui n'évolue pas en fonction du type de sol. L'ajout du soja dans la simulation permettrait de réduire la sous-estimation, car cette culture représente environ 20 % des prélèvements en eau sur ce territoire selon les estimations de la DRAAF [98].

Pour l'estimation des surfaces irriguées, le modèle estime que  $90 \pm 1 \%$  du maïs est irrigué soit  $28365 \pm 2874 \text{ ha}$  (Figure 4.26). Nous observons également une répartition Nord-sud des parcelles de maïs irrigué. Cette répartition des parcelles à l'échelle du bassin versant est principalement liée à la pluviométrie annuelle, plus importante au sud du bassin qu'au nord.

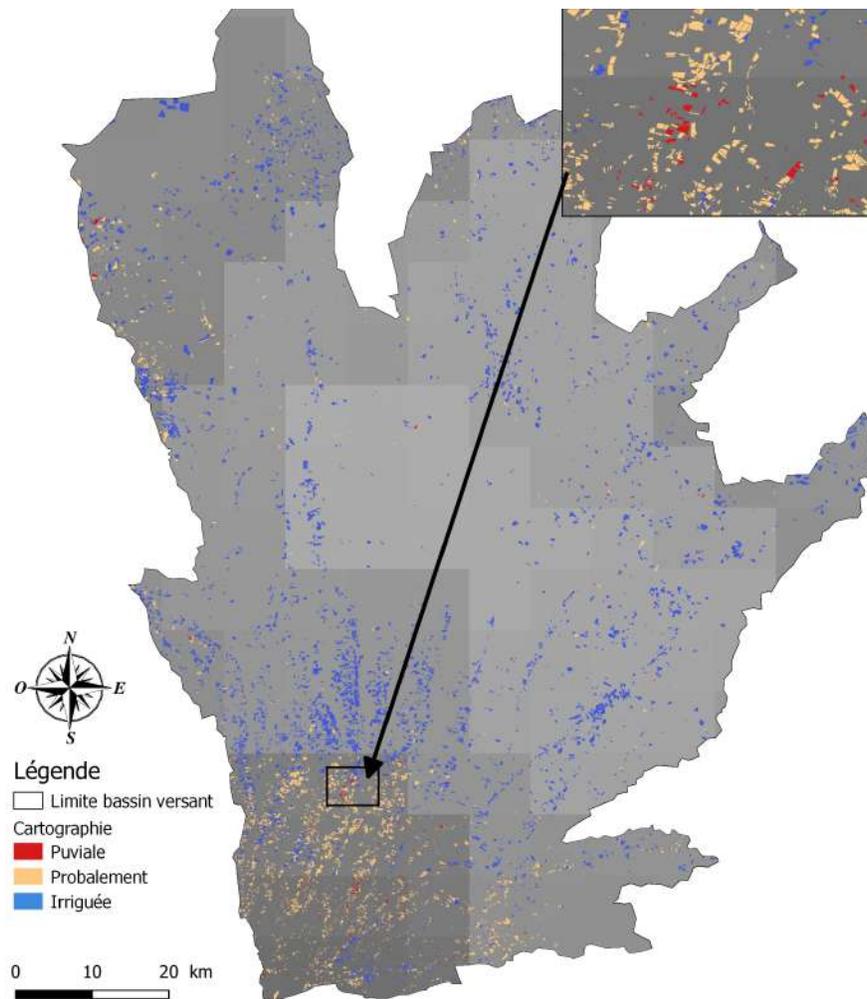


Figure 4.26 – Classification du maïs irrigué issue du modèle SAMIR, avec l'application d'un seuil sur le bassin versant de la Neste en 2017.

Pour les quantités d'eau d'irrigation souscrit par le modèle, à l'échelle parcellaire, les résultats sont illustrés sur la figure 4.27. Nous constatons sur celle-ci que les quantités à la parcelle correspondent aux recommandations des chambres d'agriculture et de l'OUGC, avec des quantités variant entre 0 et 300 mm pour les zones à forts déficits hydriques. Ces zones à forts déficits sont localisées sur des sols peu profonds caractérisés par des RU de 54 à 81 mm et des zones où la pluviométrie annuelle est inférieure à 350 mm sur l'ensemble de la saison de culture.

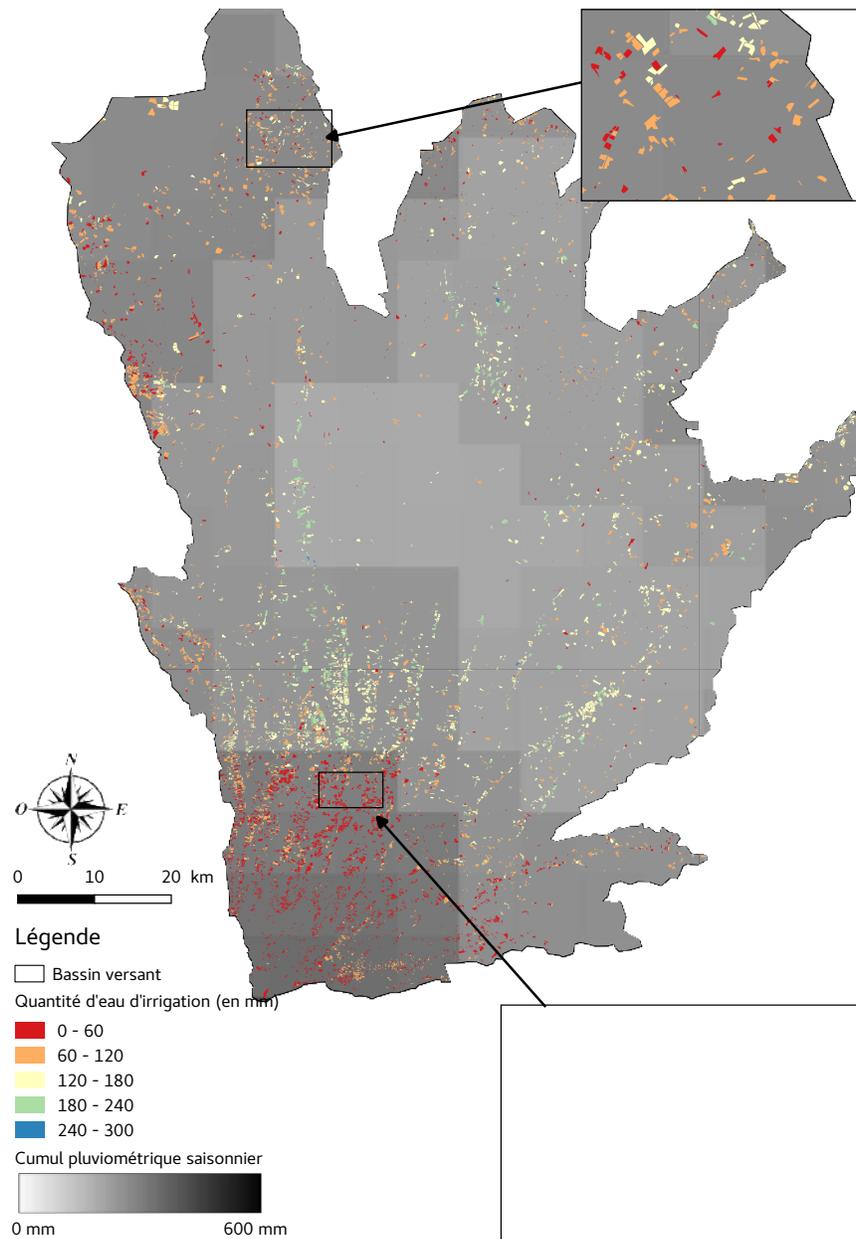


Figure 4.27 – **Cartographie des quantités d'eau d'irrigation du maïs irrigué issue du modèle SAMIR, sur le bassin versant de la Neste en 2017**

**Ce qu'il faut retenir**

- **Parcelle des partenaires** : L'utilisation des produits pédologiques seule (GSM et  $RRP_{UTS}$ ), conduisent tous deux à des estimations biaisées des quantités saisonnières d'irrigation, causé par une mauvaise estimation de la RU. En revanche l'utilisation conjointe de GSM et du  $RRP_{UTS}$  permet d'améliorer l'estimation des quantités saisonnières d'irrigations. Cependant, les données  $RRP_{UTS}$  ne sont pas toujours disponibles, donc fixer le paramètre  $maxZr$  à 1 000 mm semble être un bon compromis.
- **Périmètre irrigué** : Les volumes annuels estimés par le modèle sont sous-estimés par rapport à ceux fournis par la CACG. Cette sous-estimation est liée à une mauvaise initialisation du modèle pour estimer les volumes irrigués du soja, qui est représenté sur les ASA environ 50 % de l'assolement. L'évaluation du modèle sur cette culture est nécessaire pour améliorer l'estimation des volumes irrigués à l'échelle des périmètres irrigués.
- **Bassin versant** : La spatialisation du modèle à l'échelle des 2 BV semble reproduire de façon cohérente les variations spatiales des quantités d'eau d'irrigation selon la météo.

## 4.4 Conclusion

L'objectif du chapitre était d'estimer les besoins et consommations en eau du maïs sur de grandes surfaces et durant des années climatiques contrastées. Pour cela, nous avons utilisé le modèle SAMIR. Après avoir évalué le modèle sur la parcelle expérimentale de Lamothe, le modèle SAMIR a été appliqué sur des parcelles et des périmètres irrigués situés dans le Gers, ainsi que sur les 2 BV étudiés : Neste et Adour-Amont. Les mesures d'ETR de la station flux de la parcelle expérimentale ont été utilisées pour évaluer les modifications apportées sur l'estimation du coefficient évaporateur ( $K_r$ ) et sur la méthode d'estimation du  $F_{Cover}$ . Ces modifications ont conduit à de bonnes estimations de l'ETR journalier sur les 6 années étudiées (Biais = -0.16 mm ; RMSE = 0.58 mm). Les résultats montrent que le modèle SAMIR est capable de reproduire de façon satisfaisante les besoins en eau d'irrigation des 85 parcelles (Biais = 16 mm ; RMSE = 56 mm) lorsque la RU est estimée à partir des fonctions de pédotransfert fournies par GlobalSoilMap en utilisant les profondeurs d'enracinement maximales de la carte  $RRP_{UTS}$  fournies par L. Rigou.

Les résultats obtenus avec les données pédologiques sont mitigés, car les informations utiles pour caractériser la réserve facilement utilisable, ne sont pas disponibles. En effet, l'utilisation de la carte pédologique GlobalSoil-Map (GSM) a conduit à une sous-estimation des irrigations saisonnières (Biais = - 11 mm) qui semble être liée à la RU surestimée entraînant. L'utilisation des données  $RRP_{UTS}$  conduit à une surestimation des irrigations causée par une RU trop petite, liée à un biais expérimentateur. Cependant en combinant les deux données pédologiques, nous parvenons à améliorer les estimations des quantités saisonnières d'irrigation (Biais = 16 mm et RMSE = 57 mm).

A l'échelle des bassins versants, les résultats ne peuvent-être validés, car les organismes de gestion n'ont pas connaissance du volume total prélevé pour l'irrigation sur leur territoire. Néanmoins, nous avons pu constater que le modèle permettait de localiser les parcelles de maïs irrigués de manière satisfaisante, avec un Fscore de 80 % pour le maïs irrigué.



## 5.1 Synthèse des résultats

L'objectif de ma thèse était de développer des méthodes permettant de fournir un diagnostic des surfaces irriguées, des besoins et des consommations en eau à l'échelle des territoires. Une des applications de ce travail est de fournir des outils aux gestionnaires afin de les aider à mieux gérer la ressource en eau sur de grandes surfaces.

Pour répondre à cet objectif, deux modèles ont été utilisés. Le modèle de classification supervisé Random-Forest qui permet de cartographier les surfaces irriguées à partir des données satellites Sentinel-1 et 2 et le modèle SAMIR, qui simule le bilan hydrique des cultures. Une importante partie de mon travail de recherche a consisté à coupler ces modèles à des images satellitaires optiques et radars à haute résolution spatiale et temporelle. En complément de jeux de données satellitaires, de nombreuses données ont été utilisées pour la calibration et la validation du modèle (mesures in-situ, enquêtes agriculteurs, cartes de sols, données météorologiques). J'ai pu bénéficier d'un important jeu de données pour valider les estimations spatialisées des modèles, grâce aux campagnes de mesures réalisées sur le site expérimental de Lamothe et par les partenariats établis notamment dans le cadre de ma thèse.

La première partie de cette thèse portait sur la cartographie des surfaces irriguées. Ce travail a été réalisé avec la chaîne de traitement Iota<sup>2</sup>. La méthode de détection des surfaces irriguées utilisant les images Sentinel-1 & 2 et les données pluviométriques cumulées mensuellement a été validé sur le bassin versant Adour Amont à partir des campagnes terrains réalisées par la chambre d'agriculture des Hautes-Pyrénées sur les trois cultures majoritaires : le tournesol, le soja et le maïs, ces 2 dernières étant irriguées. Nous avons proposé une nouvelle méthodologie permettant de prendre en compte les divergences sur le développement de la canopée (vitesse et amplitude) entre différentes cultures et pratiques (irriguées et pluviales), tout en conservant les informations spectrales nécessaire pour distinguer les cultures irriguées et pluviales.

Le développement de la méthodologie de classification a permis dans un premier temps, d'évaluer l'importance du couplage de données optiques et radars pour détecter les surfaces irriguées et pluviales. En effet, l'utilisation conjointe de ces données a permis d'obtenir des meilleurs résultats par rapport aux classifications utilisant une seule source de donnée. Dans un second temps, nous avons analysé l'impact des cumuls mensuels sur la détection des surfaces irriguées en comparant différentes configurations du modèle de classifications. Les différentes configurations testées, ont permis d'illustrer l'efficacité de la méthodologie des cumuls par rapport à une méthode utilisant l'ensemble des données disponible, avec des Fscores équivalents entre les deux approches, soit un taux de détection supérieur à 80 % pour le maïs irrigué et le tournesol et ceux pour les deux années. Pour les autres cultures étudiées (soja (irrigué et pluvial) et maïs pluvial), les performances du modèle sont plus médiocres, avec des taux de détection de l'ordre de 40%. Les faibles performances de la méthode pour les classes moins représentées sur le territoire sont notamment dues à la donnée de référence mal labellisée et au faible nombre de données pour certaines classes, entraînant de fortes confusions entre les classes. En plus de l'évaluation des performances de classification, nous avons également analysé la consommation de la ressource informatique entre les différentes configurations. Suite à cette analyse, nous avons pu constater que, la méthode basée sur les cumuls mensuels était moins consommatrice de temps calcul que celle utilisant l'ensemble des données de télédétection disponibles conduisant à une réduction du temps de calcul d'un facteur 4.

En plus de données satellitaires, nous avons ajouté des données pluviométriques dans le processus de classification. L'analyse des résultats a montré que l'ajout de la donnée météorologique, s'est avéré pertinent, car il a permis de réduire les confusions des classes et d'augmenter les Fscores de l'ensemble des classes. Néanmoins,

cette donnée faiblement résolue spatialement a apporté également des incertitudes, principalement sur les zones où les précipitations sont hétérogènes.

En parallèle de ce travail de classification en fin de saison culture, la méthode a été évaluée en cours de campagne d'irrigation. Les résultats ont montré que cette méthode fournit une détection de 80 % du maïs irrigué dès le mois de juillet.

Cette méthode a également été appliquée sur un autre bassin versant afin d'évaluer sa robustesse de la méthode appliquée dans un contexte pédo-climatique différent. Cependant, la faible quantité de données de référence disponibles pour la validation ne nous a pas permis de conclure.

La seconde partie de ma thèse a consisté à modéliser les besoins et les consommations en eau sur le maïs irrigué. Pour cela, le modèle SAMIR, basé sur le modèle de la FAO-56 [153, 154] a été utilisé. Ce modèle à la particularité d'avoir été conçu pour être piloté par des données de télédétection. Pour évaluer les sorties de ce modèle nous avons utilisé six années de mesures de flux d'ETR sur la parcelle expérimentale du CESbio (ferme de Lamothe) ainsi que de relevés d'irrigation (dates et doses) fournis par la CACG. L'évaluation du modèle sur la parcelle expérimentale à partir des mesures d'ETR, a conduit à modifier le formalisme d'évaporation du sol (via la variable  $K_r$ ), ainsi que la méthode d'estimation du FCover.

Nous avons proposé d'utiliser le formalisme basé sur la texture du sol, récemment publié par Amazirh et al [160]. Les résultats montrent que les ETR issues de la méthode d'Amazirh et al sont similaires à celles de la FAO-56. Cependant, l'ajout de ce formalisme permet de s'affranchir du paramètre REW, qui est difficile à estimer et souvent fixé de manière arbitraire. Nous avons également évalué l'apport du FCover issu de données satellitaires. Les résultats ont été comparés à ceux obtenus avec une relation empirique NDVI-FCover proposée dans la version initiale de SAMIR. Cette méthode n'a pas conduit à des améliorations significatives des ETR mais elle est plus robuste dans la mesure où elle ne repose pas sur l'utilisation de données in-situ contrairement à la loi empirique qu'il faut recalibrer pour chaque nouveau site d'étude.

Une fois ce travail d'évaluation réalisé sur la parcelle de Lamothe, le modèle a été spatialisé sur 85 parcelles et 4 ASA situées dans le Gers. L'objectif était d'évaluer les volumes irrigués simulés et d'analyser l'impact de différentes méthodes d'estimation de la RU à partir de 2 cartes de sol : le RRP et GSM. Les résultats ont montré que les irrigations saisonnières estimées par le modèle à l'échelle des parcelles sont surestimées par rapport aux valeurs observées (Biais = 16 mm), lorsque la RU est estimée avec la carte GlobalSoilMap (GSM) et une profondeur d'enracinement maximale connue à dire d'expert. Lorsque que la réserve utile est estimée à partir de la profondeur de sol issue de GSM, les irrigations saisonnières sont sous-estimées, avec un biais de - 11 mm et un RMSE de 58 mm. L'utilisation de la carte du RRP<sub>UTS</sub> conduit à des quantités d'irrigations saisonnières fortement surestimées (43 mm). La cause de ces estimations serait due à une mauvaise estimation des points de flétrissement et capacité au champs issu de la table de Bruand.

A l'échelle des périmètres irrigués, les volumes simulés sont sous-estimés pour les deux années étudiées. Nous observons de meilleurs résultats en 2017, avec un biais de  $-0.61 \text{ hm}^3$  contre  $-2.68 \text{ hm}^3$  en 2018. Pour estimer ces volumes, nous avons considéré que l'ensemble des parcelles cultivées en été, était du maïs, car nous n'avons pas évalué le modèle sur les autres cultures, telles que la soja. Cette hypothèse semble entraîner une augmentation du biais en 2018 car la surface cultivée en soja sur les ASA a augmentée en 2018 comparé à 2017. Dans un second temps, cette sous-estimation en 2018 peut-être liée à une augmentation de la superficie des périmètres irrigués ( $\pm 5$ , selon la CA du Gers), que nous n'avons pas pu prendre en compte, car nous ne disposons que des contours des périmètres pour 2017 (Transmis par la CACG).

Pour finir, nous avons évalué la capacité du modèle à spatialiser les quantités d'eau d'irrigation sur deux sous-bassins versants (Adour Amont et Neste). Les résultats de ces simulations sont difficiles à valider car nous ne disposons pas d'information sur les volumes réellement prélevés. Nous disposons des volumes annuels souscrits. A titre d'information, les volumes totaux estimés à l'échelle de ces périmètres élémentaires sont de l'ordre  $13 \text{ hm}^3$  pour le bassin d'Adour amont et  $40 \text{ hm}^3$  pour la Neste.

## 5.2 Perspectives

L'utilisation des images satellitaires Sentinel-1 et Sentinel-2 couplé aux modèles de classification et/ou agro-météorologiques, sont essentielles pour la détection et le suivi des surfaces irriguées en zones tempérées. Leur gratuité et les hautes résolutions spatiales et temporelles, en font des données à fort potentiel pour contribuer à une gestion optimale de la ressource en eau à l'échelle des territoires. Mais le travail initié au cours de cette thèse n'est qu'une goutte d'eau parmi l'étendue des recherches qui restent à mener sur ce sujet. Plusieurs perspectives peuvent être envisagées.

### Exploitation des nouvelles données de télédétection.

L'arrivée prochaine des nouvelles missions spatiales (LSTM et TRISHNA), permettant l'acquisition de données thermique à haute résolution spatiale et temporelle, gratuites et couvrant l'ensemble du globe, ouvre de nouvelle perspective pour la détection et le suivi des surfaces irriguées [173]. En effet, ces missions proposeront des données d'évapotranspiration et de température de surfaces tous les 3 jours, avec une résolution spatiale de 50 m et une précision de mesure de l'ordre de  $0.3^{\circ}\text{C}$  sur une gamme de  $-20$  à  $+30^{\circ}\text{C}$ . L'utilisation de ces données thermiques permettront d'affiner le suivi de l'évapotranspiration (ET) à l'échelle parcellaire en capturant la variabilité de la température de la surface terrestre (LST) permettant des estimations plus robustes du bilan hydrique des cultures. L'estimation de la température de surface, par des données de télédétection permettra également de détecter le stress hydrique, tel que les récents travaux d'Olivera et al, [82] et par conséquent améliorer la fiabilité des estimations des irrigations à l'échelle parcellaire, mais aussi des cartographies des surfaces irriguées.

En plus des données thermiques, l'imagerie micro-ondes issue du capteur Sentinel-1 semble prometteuse pour estimer les besoins et les consommations en eau des cultures par des approches de modélisations agro-météorologiques. En effet, les récents travaux de Le page et al [60], Ouadi et al [174] et Zappa et al [175] semblent être intéressants pour améliorer la détection des événements d'irrigations en contraignant un modèle de bilan hydrique par l'humidité du sol capté par la polarisation VV du capteur SAR. En effet les résultats de l'étude de Zappa et al [175] montrent que la plupart des événements d'irrigation peuvent être détectés à l'aide des informations sur l'humidité du sol ( $F_{\text{score}} = 0.77$ ). Les estimations des quantités d'irrigation étaient en accord avec les données de référence ( $R = 0.64$ ). Néanmoins, l'utilisation de cette donnée dans le modèle reste limitée, car l'humidité estimée via les données radars (Sentinel-1) est restrictive, du fait de la faible profondeur de pénétration du signal dans le sol et de la saturation du signal lorsque la végétation est bien développée [176]. Cette donnée, entraîne également d'importantes modifications sur le modèle, en créant une couche de sol supplémentaire comme effectué par Le page et al [60].

Une autre source de données, me semble essentielle à exploiter aux vues des limites présentées par les données météorologiques. En effet, la faible résolution spatiale des données SAFRAN est à l'origine de nombreuses incertitudes, notamment dans les zones à forte hétérogénéité pluviométrique, tant sur la cartographie des surfaces irriguées, que sur la modélisation du bilan hydrique. Pour limiter ces incertitudes, l'utilisation de données avec une résolution spatiale plus fine, comme les données AROME [177] ou COMEPHORE [178] distribuées par Météo-France, doit être envisagée.

Dans un but de transfert de méthodologie vers des organismes de la gestion de la ressource en eau, les produits délivrés par le service Copernicus Global Land Service, permet d'utiliser les produits  $F_{\text{cover}}$  sans passer par de longs traitements informatiques. Mais la résolution spatiale (300 m) des produits distribués [<https://land.copernicus.eu/global/products/fcover>], ne sont pas appropriés pour de la modélisation à l'échelle parcellaire. Cependant, d'autres produits bio-géophysiques (LAI,  $F_{\text{Cover}}$  et FAPAR) sont en cours d'élaboration, dans le cadre du programme Copernicus. Ces produits sont issus des données Sentinel-2, permettant d'obtenir une cartographie à haute résolution spatiale (10 m) et temporelle sur la phénologie et la productivité de la végétation [<https://land.copernicus.eu/pan-european/biophysical-parameters/high-resolution-vegetation-phenology-and-productivity>]. Ces différents produits peuvent être utilisés dans des modèles agro-météorologiques comme SAMIR.

### **Exploiter de nouvelles méthodes de classification.**

La thèse a permis d'évaluer l'apport de données Sentinel-1 et Sentinel-2 dans le processus de classification supervisées, mais a mis en évidence la forte dépendance de ces méthodes aux données de référence. La mise au point de méthodes semi-supervisées ou auto-supervisées permettraient de pallier à ce problème récurrent de donnée de référence [179]. Ces méthodes permettent d'utiliser un nombre restreint de données de référence labellisées pour entraîner un modèle de classification à partir d'un ensemble de données non labellisées. Les récents travaux de Bazzi et al [180], appliquant ce type de méthode pour la détection des surfaces irriguées permet l'obtention des bonnes performance sur la détection du maïs irrigué et pluvial dans le centre de la France à partir de données Sentinel-1 et 2 et un nombre restreint de données de référence, soit 1000 échantillons répartis sur 4 années de mesures.

D'autres approches de classifications sont envisageables, comme l'utilisation d'algorithme de détection des formes, par segmentation. Ces approches permettent d'identifier les parcelles irriguées équipée de pivot d'irrigation, comme démontré par Saraiva et al, [181]. Mais ces approches ne peuvent être appliquées sur des territoires hétérogènes et où l'irrigation par pivot n'est pas majoritaire.

### **Prise en compte des pratiques agricoles et des stades phénologiques dans la modélisation du bilan hydrique.**

Au cours de mes travaux, nous avons été confrontés à la présence de cultures intermédiaires sur les parcelles modélisées, impactant l'estimation des irrigations saisonnières en déclenchant prématurément des irrigations. Pour palier à cette contrainte, nous avons ajouté une règle sur le déclenchement des irrigations à partir d'une date théorique de semis de culture, basé sur le calendrier cultural, fourni par les chambres d'agriculture. Cependant, cette date de semis est souvent mal méconnue et peut-être très variable selon les pratiques, les variétés et les conditions météorologiques.

Donc, pour améliorer la robustesse de cette approche, il est envisagé de prendre en compte les stades phénologiques et les pratiques culturales dans l'approche de modélisation du bilan hydrique. Pour cela, de récents travaux ont illustré le potentiel des données Sentinel-1 pour la détection des labours [182] et l'estimation d'une date de levée [176]. D'autres travaux s'appuyant sur des données optiques issues des nano-satellites de la constellation PlanetScope CubeSat [183], ont permis d'identifier les dates de semis avec un écart médian de 0 jour, avec un RMSE compris entre 0.9 et 1.9 jours. Une autre approche basée sur le concept de cumul de température en fonction de temps pourrait être envisagé pour estimer les stades phénologiques des cultures, comme proposé dans le modèle SAFYE [161]. Les données SAR (Sentinel-1) pourrait également être utilisé pour améliorer l'estimation des stades phénologiques en début de saison via la double polarisation VV/VH. Ces estimations permettraient de contraindre le module d'irrigation automatique, en favorisant le déclenchement de l'irrigation lors des périodes de forte sensibilité au stress hydrique et définir des priorités entre les parcelles.

En plus, d'une estimation de la date de semis, il serait intéressant d'intégrer l'impact des cultures intermédiaires (CI) dans la modélisation du bilan hydrique. En effet, les récents travaux menés dans le cadre du projet BAG'AGES, ont illustré que la destruction tardive de couvert intermédiaire (début avril selon les estimations effectuées par le modèle STICS) pouvait réduire la disponibilité en eau pour la culture suivante. Néanmoins, l'ajout de ces CI dans les agrosystèmes permet d'augmenter la concentration en matière organique (MO) dans le sol qui a un impact bénéfique, à long terme, sur la rétention de l'eau dans le sol, avec une augmentation de 10 à 30 % du volume selon les récents travaux de Eden et al [184]. Peu de modèles de culture comme SAMIR sur un faible nombre de paramètres et d'équations prennent en compte la présence et l'impact des CI sur l'estimation du bilan hydrique. La prise en compte de l'effet des CI sur le bilan hydrique des parcelles nécessite des données de validation qui sont aujourd'hui disponibles que très localement. Toutefois, un service opérationnel Copernicus Land Surface High Resolution « Agriculture17 » devrait fournir des informations via les satellites Sentinel 1 & 2 concernant les pratiques (CI, travail du sol, date de récolte) qui pourraient être exploitées pour la modélisation spatialisée des cultures.

**Améliorer l'estimation de la réserve utile et du contenu en eau.**

La réserve utile (RU) est une variable jouant un rôle clé dans le fonctionnement hydrique des plantes, mais sa mesure et son estimation sont difficiles et font l'objet de nombreuses recherches. Différentes méthodes sont étudiées, parmi lesquelles on peut citer les méthodes géostatistiques (RRP), celles basées sur l'inversion de modèles de cultures ou encore l'élaboration des nouvelles fonctions de pédotransfert, intégrant les propriétés extrinsèques du sol. Une première piste envisagée pour améliorer d'estimation de la RU dans le modèle SAMIR serait d'utiliser des fonctions de pédotransfert (PF) dites continues. En effet, les récents travaux de Dobarco et al [107] et Labidi et al [172] illustrent les bonnes performances des fonctions de PF continues par rapport à celle discontinues telle que celle de Bruand et al [88]. Elles permettent également de prendre en compte les variations de contenu en matière organique et la densité apparente impactant la capacité de rétention du sol [184].

Une autre piste d'amélioration envisageable est d'améliorer l'estimation du drainage dans les modèles de cultures. Cette amélioration nécessite de coupler le modèle agro-météorologique avec un modèle hydrologique.

**Valider sur d'autres sites et d'autres cultures.**

La thèse a permis d'évaluer l'approche de cartographie des surfaces irriguées sur différents bassins versants du Sud-ouest de la France grâce à l'implication des partenaires et des organismes de gestion de l'eau. Ces travaux ont été menés sur les cultures d'étés et principalement le maïs. Il serait intéressant d'évaluer cette approche sur d'autres cultures telles que le blé ou la vigne qui commencent à être irrigués.

Les ETR simulées par le modèle SAMIR ont été évaluées à l'aide du site expérimental de Lamothe. Grâce aux données satellitaires de la constellation Sentinel couvrant l'ensemble du globe depuis 2017, nous pourrions valider les estimations de l'ETR sur d'autres parcelles cultivées en maïs à partir des mesures d'ETR acquises sur différents sites du réseau ICOS. Ces données permettent également d'évaluer le modèle sur le soja, qui représente actuellement une part non négligeable des prélèvements en eau pour l'irrigation. Pour valider les estimations des irrigations saisonnières sur d'autres bassins versants soumis à de fortes restrictions en eau, nous pourrions envisager d'utiliser les résultats de l'enquête PKGC "Pratiques Culturelles En Grandes Cultures" menée par le ministère de l'agriculture et de l'alimentation. Cette enquête a été réalisée en 2017 et une nouvelle a eu lieu en 2021. Cette base de données permettrait d'augmenter la profondeur historique de ces données essentielle pour évaluer la robustesse de nos approches.



- [1] C. Mbow, C. Rosenzweig, L. Barioni, T. Benton, M. Herrero, M. Krishnapillai, E. Liwenga, P. Pradhan, M. Rivera-Ferre, T. Sapkota, *et al.*, "Food security, chapter 5," *Special Report on Climate Change and Land. IPCC : Intergovernmental Panel on Climate Change*, 2019.
- [2] D. Gerten, W. Lucht, S. Ostberg, J. Heinke, M. Kowarsch, H. Kreft, Z. W. Kundzewicz, J. Rastgooy, R. Warren, and H. J. Schellnhuber, "Asynchronous exposure to global warming : freshwater resources and terrestrial ecosystems," *Environmental Research Letters*, vol. 8, p. 034032, sep 2013.
- [3] J. Schewe, J. Heinke, D. Gerten, I. Haddeland, N. W. Arnell, D. B. Clark, R. Dankers, S. Eisner, B. M. Fekete, F. J. Colón-González, S. N. Gosling, H. Kim, X. Liu, Y. Masaki, F. T. Portmann, Y. Satoh, T. Stacke, Q. Tang, Y. Wada, D. Wisser, T. Albrecht, K. Frieler, F. Piontek, L. Warszawski, and P. Kabat, "Multimodel assessment of water scarcity under climate change," *Proceedings of the National Academy of Sciences*, vol. 111, no. 9, pp. 3245–3250, 2014.
- [4] IPCC, *Climate Change 2021 : The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge, United Kingdom and New York, NY, USA : Cambridge University Press, 2021.
- [5] C. général de l'alimentation de l'agriculture et des espaces ruraux, *Eau, agriculture et changement climatique : Statu quo ou anticipation ? Rapport n°16072*, 2017.
- [6] N. Brisson and F. Levrault, "Livre vert du projet climator 2007-2010. changement climatique, agriculture et forêt en france : simulations d'impacts sur les principales espèces," 2010.
- [7] J. Soubeyroux, J. Vidal, J. Najac, N. Kitova, M. Blanchard, P. Dandin, E. Martin, C. Pagé, and F. Habets, "Projet climsec impact du changement climatique en france sur la sécheresse et l'eau du sol," *Météo-France, Toulouse, France*, 2011.
- [8] J.-J. Seguin and W. Arnaud, *Exploitabilité des ressources en eaux souterraines en France. Résistance à la sécheresse des principaux aquifères à nappe libre*. BRGM/RP-55188-FR, 2006.
- [9] Food and A. Organization., *Future of Food and Agriculture 2018 : Alternative Pathways to 2050*. Food & Agriculture ORG, 2018.
- [10] A. Garrido, M. R. Llamas, C. Varela-Ortega, P. Novo, R. Rodríguez-Casado, and M. M. Aldaya, *Water footprint and virtual water trade in Spain : Policy implications*, vol. 35. Springer Science & Business Media, 2010.
- [11] B. R. Scanlon, C. C. Faunt, L. Longuevergne, R. C. Reedy, W. M. Alley, V. L. McGuire, and P. B. McMahon, "Groundwater depletion and sustainability of irrigation in the us high plains and central valley," *Proceedings of the national academy of sciences*, vol. 109, no. 24, pp. 9320–9325, 2012.
- [12] Food and A. O. of the United Nations, "Faostat."
- [13] R. Schaldach, J. Koch, T. A. der Beek, E. Kynast, and M. Flörke, "Current and future irrigation water requirements in pan-europe : An integrated analysis of socio-economic and climate scenarios," *Global and Planetary Change*, vol. 94, pp. 33–45, 2012.
- [14] D. Wisser, S. Frothing, E. M. Douglas, B. M. Fekete, C. J. Vörösmarty, and A. H. Schumann, "Global irrigation water demand : Variability and uncertainties arising from agricultural and climate data sets," *Geophysical Research Letters*, vol. 35, no. 24, 2008.

- [15] S. Siebert, P. Döll, J. Hoogeveen, J.-M. Faures, K. Frenken, and S. Feick, "Development and validation of the global map of irrigation areas," *Hydrology and Earth System Sciences*, vol. 9, no. 5, pp. 535–547, 2005.
- [16] S. Loubier, M. Campardon, and S. Morardet, "L'irrigation diminue-t-elle en france ? premiers enseignements du recensement agricole de 2010," *Sciences Eaux Territoires*, no. 2, pp. 12–19, 2013.
- [17] A. de l'Eau Adour Garonne, Acteon, CACG, Futuribles, and Irstea, *Rapport final : Garonne 2050*. Agence de l'Eau Adour Garonne, 2014.
- [18] J.-P. Cassagne, V. TRIPIANA, and M.-C. SABLİK, "Agreste mémento 2020, adour garonne," *Nan*, 2020.
- [19] F. Hendrickx and E. Sauquet, "Impact of warming climate on water management for the ariège river basin (france)," *Hydrological Sciences Journal*, vol. 58, no. 5, pp. 976–993, 2013.
- [20] L. Lhuissier, V. Lamblin, E. Sauquet, Y. Arama, F. Goulard, and P. Strosser, "Retour sur l'étude prospective garonne 2050," *La Houille Blanche*, vol. Nan, no. 6, pp. 30–35, 2016.
- [21] E. Martin, S. Gascoin, Y. Grusson, C. Murgue, M. Bardeau, F. Anctil, S. Ferrant, R. Lardy, P. Le Moigne, D. Leenhardt, *et al.*, "On the use of hydrological models and satellite data to study the water budget of river basins affected by human activities : examples from the garonne basin of france," *Surveys in Geophysics*, vol. 37, no. 2, pp. 223–247, 2016.
- [22] C. général de l'environnement et du développement durable, *Évaluation du plan national d'adaptation au changement climatique*. Rapport n°010178-01, 2015.
- [23] M. Sharman, "Application de la télédétection aux statistiques agricoles pour l'europe," 1990.
- [24] P. Fournet, "La télédétection au service de la statistique agricole," *Travaux de l'Institut de Géographie de Reims*, vol. 57, no. 1, pp. 49–52, 1984.
- [25] V. K. Boken, G. Hoogenboom, F. N. Kogan, J. E. Hook, D. L. Thomas, and K. A. Harrison, "Potential of using noaa-avhrr data for estimating irrigated area to help solve an inter-state water dispute," *International Journal of Remote Sensing*, vol. 25, no. 12, pp. 2277–2286, 2004.
- [26] D. Kamthonkiat, K. Honda, H. Turrall, N. Tripathi, and V. Wuwongse, "Discrimination of irrigated and rainfed rice in a tropical agricultural system using spot vegetation ndvi and rainfall data," *International Journal of Remote Sensing*, vol. 26, no. 12, pp. 2527–2547, 2005.
- [27] P. S. Thenkabail, M. Schull, and H. Turrall, "Ganges and indus river basin land use/land cover (lulc) and irrigated area mapping using continuous streams of modis data," *Remote Sensing of Environment*, vol. 95, no. 3, pp. 317–341, 2005.
- [28] M. Ozdogan and G. Gutman, "A new methodology to map irrigated areas using multi-temporal MODIS and ancillary data : An application example in the continental US," *Remote Sensing of Environment*, vol. 112, no. 9, pp. 3520–3537, 2008.
- [29] F. T. Portmann, S. Siebert, and P. Döll, "Mirca2000—global monthly irrigated and rainfed crop areas around the year 2000 : A new high-resolution data set for agricultural and hydrological modeling," *Global biogeochemical cycles*, vol. 24, no. 1, 2010.
- [30] M. S. Pervez and J. F. Brown, "Mapping irrigated lands at 250-m scale by merging modis data and national agricultural statistics," *Remote Sensing*, vol. 2, no. 10, pp. 2388–2412, 2010.
- [31] M. E. Hajj, N. Baghdadi, G. Belaud, M. Zribi, B. Cheviron, D. Courault, O. Hagolle, and F. Charron, "Irrigated grassland monitoring using a time series of terrasars-x and cosmo-skymed x-band sar data," *Remote Sensing*, vol. 6, no. 10, pp. 10002–10032, 2014.

- [32] M. Zohaib, H. Kim, and M. Choi, "Detecting global irrigated areas by using satellite and reanalysis products," *Science of The Total Environment*, vol. 677, pp. 679–691, 2019.
- [33] W. G. Bastiaanssen, D. J. Molden, and I. W. Makin, "Remote sensing for irrigated agriculture : examples from research and possible applications," *Agricultural water management*, vol. 46, no. 2, pp. 137–155, 2000.
- [34] M. Ozdogan, Y. Yang, G. Allez, C. Cervantes, M. Ozdogan, Y. Yang, G. Allez, and C. Cervantes, "Remote sensing of irrigated agriculture : Opportunities and challenges," *Remote Sensing*, vol. 2, no. 9, pp. 2274–2304, 2010.
- [35] H. Bazzi, N. Baghdadi, M. El Hajj, and M. Zribi, "Potential of sentinel-1 surface soil moisture product for detecting heavy rainfall in the south of france," *Sensors*, vol. 19, no. 4, 2019.
- [36] P. Thenkabail, V. Dheeravath, C. Biradar, O. R. Gangalakunta, P. Noojipady, C. Gurappa, M. Velpuri, M. Gumma, Y. Li, P. S. Thenkabail, V. Dheeravath, C. M. Biradar, O. R. P. Gangalakunta, P. Noojipady, C. Gurappa, M. Velpuri, M. Gumma, and Y. Li, "Irrigated area maps and statistics of india using remote sensing and national statistics," *Remote Sensing*, vol. 1, no. 2, pp. 50–67, 2009.
- [37] M. J. M. Cheema and W. G. M. Bastiaanssen, "Land use and land cover classification in the irrigated indus basin using growth phenology information from satellite data to support water management analysis," *Agricultural Water Management*, vol. 97, no. 10, pp. 1541–1552, 2010.
- [38] V. Dheeravath, P. S. Thenkabail, G. Chandrakantha, P. Noojipady, G. P. O. Reddy, C. M. Biradar, M. K. Gumma, and M. Velpuri, "Irrigated areas of india derived using MODIS 500 m time series for the years 2001–2003," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 65, no. 1, pp. 42–59, 2010.
- [39] M. K. Gumma, P. S. Thenkabail, F. Hideto, A. Nelson, V. Dheeravath, D. Busia, and A. Rala, "Mapping irrigated areas of ghana using fusion of 30 m and 250 m resolution remote-sensing data," *Remote Sensing*, vol. 3, no. 4, pp. 816–835, 2011.
- [40] A. K. Ambika, B. Wardlow, and V. Mishra, "Remotely sensed high resolution irrigated area mapping in india for 2000 to 2015," *Scientific Data*, vol. 3, p. 160118, 2016.
- [41] S. Bousbih, M. Zribi, M. El Hajj, N. Baghdadi, Z. Lili-Chabaane, Q. Gao, and P. Fanise, "Soil moisture and irrigation mapping in a semi-arid region, based on the synergetic use of sentinel-1 and sentinel-2 data," *Remote Sensing*, vol. 10, no. 12, p. 1953, 2018.
- [42] Q. Gao, M. Zribi, M. J. Escorihuela, N. Baghdadi, and P. Q. Segui, "Irrigation mapping using sentinel-1 time series at field scale," *Remote Sensing*, vol. 10, no. 9, p. 1495, 2018.
- [43] E. Jalilvand, M. Tajrishy, S. A. G. Z. Hashemi, and L. Brocca, "Quantification of irrigation water using remote sensing of soil moisture in a semi-arid region," *Remote Sensing of Environment*, vol. 231, p. 111226, 2019.
- [44] Y. Xie, T. J. Lark, J. F. Brown, and H. K. Gibbs, "Mapping irrigated cropland extent across the conterminous united states at 30 m resolution using a semi-automatic training approach on google earth engine," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 155, pp. 136 – 149, 2019.
- [45] J. L. Peña-Arancibia, T. R. McVicar, Z. Paydar, L. Li, J. P. Guerschman, R. J. Donohue, D. Dutta, G. M. Podger, A. I. J. M. van Dijk, and F. H. S. Chiew, "Dynamic identification of summer cropping irrigated areas in a large basin experiencing extreme climatic variability," *Remote Sensing of Environment*, vol. 154, pp. 139–152, 2014.
- [46] M. Shahriar Pervez, M. Budde, and J. Rowland, "Mapping irrigated areas in afghanistan over the past decade using MODIS NDVI," *Remote Sensing of Environment*, vol. 149, pp. 155–165, 2014.

- [47] J. Inglada, M. Arias, B. Tardy, O. Hagolle, S. Valero, D. Morin, G. Dedieu, G. Sepulcre, S. Bontemps, P. Defourny, B. Koetz, J. Inglada, M. Arias, B. Tardy, O. Hagolle, S. Valero, D. Morin, G. Dedieu, G. Sepulcre, S. Bontemps, P. Defourny, and B. Koetz, "Assessment of an operational system for crop type map production using high temporal and spatial resolution satellite optical imagery," *Remote Sensing*, vol. 7, no. 9, pp. 12356–12379, 2015.
- [48] S. Valero, D. Morin, J. Inglada, G. Sepulcre, M. Arias, O. Hagolle, G. Dedieu, S. Bontemps, P. Defourny, B. Koetz, S. Valero, D. Morin, J. Inglada, G. Sepulcre, M. Arias, O. Hagolle, G. Dedieu, S. Bontemps, P. Defourny, and B. Koetz, "Production of a dynamic cropland mask by processing remote sensing image series at high temporal and spatial resolutions," *Remote Sensing*, vol. 8, no. 1, p. 55, 2016.
- [49] M. Immitzer, F. Vuolo, C. Atzberger, M. Immitzer, F. Vuolo, and C. Atzberger, "First experience with sentinel-2 data for crop and tree species classifications in central europe," *Remote Sensing*, vol. 8, no. 3, p. 166, 2016.
- [50] R. Sonobe, Y. Yamaya, H. Tani, X. Wang, N. Kobayashi, and K.-i. Mochizuki, "Assessing the suitability of data from sentinel-1a and 2a for crop classification," *GIScience & Remote Sensing*, vol. 54, no. 6, pp. 918–938, 2017.
- [51] F. Vuolo, M. Neuwirth, M. Immitzer, C. Atzberger, and W.-T. Ng, "How much does multi-temporal sentinel-2 data improve crop type classification?," *International Journal of Applied Earth Observation and Geoinformation*, vol. 72, pp. 122–130, 2018.
- [52] M. F. Vogels, S. M. De Jong, G. Sterk, H. Douma, and E. A. Addink, "Spatio-temporal patterns of smallholder irrigated agriculture in the horn of africa using geobia and sentinel-2 imagery," *Remote Sensing*, vol. 11, no. 2, p. 143, 2019.
- [53] L. Brocca, A. Tarpanelli, P. Filippucci, W. Dorigo, F. Zaussinger, A. Gruber, and D. Fernández-Prieto, "How much water is used for irrigation? a new approach exploiting coarse resolution satellite soil moisture products," *International journal of applied earth observation and geoinformation*, vol. 73, pp. 752–766, 2018.
- [54] F. Zaussinger, W. Dorigo, A. Gruber, A. Tarpanelli, P. Filippucci, and L. Brocca, "Estimating irrigation water use over the contiguous united states by combining satellite and reanalysis soil moisture data," *Hydrology and Earth System Sciences*, vol. 23, no. 2, pp. 897–923, 2019.
- [55] H. Bazzi, N. Baghdadi, I. Fayad, M. Zribi, H. Belhouchette, and V. Demarez, "Near real-time irrigation detection at plot scale using sentinel-1 data," *Remote Sensing*, vol. 12, no. 9, 2020.
- [56] R. Fieuzal, B. Duchemin, L. Jarlan, M. Zribi, F. Baup, O. Merlin, O. Hagolle, and J. Garatuza-Payan, "Combined use of optical and radar satellite data for the monitoring of irrigation and soil moisture of wheat crops," *Hydrology and Earth System Sciences*, vol. 15, no. 4, pp. 1117–1129, 2011.
- [57] S. Ferrant, A. Selles, M. Le Page, P.-A. Herrault, C. Pelletier, A. Al-Bitar, S. Mermoz, S. Gascoin, A. Bouvet, M. Saqalli, B. Dewandel, Y. Caballero, S. Ahmed, J.-C. Maréchal, Y. Kerr, S. Ferrant, A. Selles, M. Le Page, P.-A. Herrault, C. Pelletier, A. Al-Bitar, S. Mermoz, S. Gascoin, A. Bouvet, M. Saqalli, B. Dewandel, Y. Caballero, S. Ahmed, J.-C. Maréchal, and Y. Kerr, "Detection of irrigated crops from sentinel-1 and sentinel-2 data to estimate seasonal groundwater use in south india," *Remote Sensing*, vol. 9, no. 11, p. 1119, 2017.
- [58] V. Demarez, F. Helen, C. Marais-Sicre, and F. Baup, "In-season mapping of irrigated crops using landsat 8 and sentinel-1 time series," *Remote Sensing*, vol. 11, no. 2, p. 118, 2019.
- [59] H. Bazzi, N. Baghdadi, D. Ienco, M. El Hajj, M. Zribi, H. Belhouchette, M. J. Escorihuela, and V. Demarez, "Mapping irrigated areas using sentinel-1 time series in catalonia, spain," *Remote Sensing*, vol. 11, no. 15, p. 1836, 2019.

- [60] M. Le Page, L. Jarlan, M. M. El Hajj, M. Zribi, N. Baghdadi, and A. Boone, "Potential for the detection of irrigation events on maize plots using sentinel-1 soil moisture products," *Remote Sensing*, vol. 12, no. 10, 2020.
- [61] Y. Zhang, C. Li, X. Zhou, and B. Moore III, "A simulation model linking crop growth and soil biogeochemistry for sustainable agriculture," *Ecological modelling*, vol. 151, no. 1, pp. 75–108, 2002.
- [62] C. de Wit, R. Brouwer, and F. Penning de Vries, "The simulation of photosynthetic systems," in *Proceedings of the IBP/PP technical meeting, Trebon, 14-21 September 1969*, pp. 47–70, Pudoc, 1970. Prediction and measurement of photosynthetic productivity : proceedings of the IBP/PP technical meeting; Conference date : 14-09-1969 Through 21-09-1969.
- [63] R. Hadria, B. Duchemin, A. Lahrouni, S. Khabba, S. Er-Raki, J. Ezzahar, B. Mougénot, G. Dedieu, A. Chehbouni, P. Maisongrande, *et al.*, "Spatialisation du modèle de culture stics en région semi aride du haouz à partir d'images satellites optiques haute résolution," in *2. WATMED, Congrès Méditerranéen des Ressources en Eau dans le Bassin Méditerranéen*, Université Cadi Ayyad, 2005.
- [64] M.-P. M.-P. Lefebvre, *Spatialisation de modèles de fonctionnement hydromécanique des sols appliquée à la prévision des risques de tassement à l'échelle de la France*. Theses, Université d'Orléans, Jan. 2010. Diplôme : Dr. d'Université.
- [65] E. Burel, *Modélisation des hétérogénéités de la réserve utile et du développement des cultures au sein d'un sous-bassin versant en Midi-Pyrénées*. PhD thesis, Université Toulouse III Paul Sabatier, 2018.
- [66] H. L. Penman, "Natural evaporation from open water, bare soil and grass," *Proceedings of the Royal Society of London. Series A. Mathematical and Physical Sciences*, vol. 193, no. 1032, pp. 120–145, 1948.
- [67] S. J. Maas, "Parameterized model of gramineous crop growth : I. leaf area and dry mass simulation," *Agronomy Journal*, vol. 85, no. 2, pp. 348–353, 1993.
- [68] J. Liu, E. Pattey, J. R. Miller, H. McNairn, A. Smith, and B. Hu, "Estimating crop stresses, aboveground dry biomass and yield of corn using multi-temporal optical data combined with a radiation use efficiency model," *Remote Sensing of Environment*, vol. 114, no. 6, pp. 1167–1177, 2010.
- [69] R. Delécolle, S. Maas, M. Guérif, and F. Baret, "Remote sensing and crop production models : present trends," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 47, no. 2, pp. 145–161, 1992.
- [70] D. Courault, V. Demarez, M. Guérif, M. Le Page, V. Simonneaux, S. Ferrant, and A. Veloso, "4 - contribution of remote sensing for crop and water monitoring," in *Land Surface Remote Sensing in Agriculture and Forest* (N. Baghdadi and M. Zribi, eds.), pp. 113–177, Elsevier, 2016.
- [71] J. C. Mailhol, A. A. Olufayo, and P. Ruelle, "Sorghum and sunflower evapotranspiration and yield from simulated leaf area index," *Agricultural water management*, vol. 35, no. 1-2, pp. 167–182, 1997.
- [72] B. Duchemin, O. Hagolle, B. Mougénot, I. Benhadj, R. Hadria, V. Simonneaux, J. Ezzahar, J. Hoedjes, S. Khabba, M. H. Kharrou, G. Boulet, G. Dedieu, S. Er-Raki, R. Escadafal, A. Oliosio, and A. G. Chehbouni, "Agrometeorological study of semi-arid areas : an experiment for analysing the potential of time series of formosat-2 images (tensift-marrakech plain)," *International Journal of Remote Sensing*, vol. 29, no. 17-18, pp. 5291–5299, 2008.
- [73] B. Duchemin, P. Maisongrande, G. Boulet, and I. Benhadj, "A simple algorithm for yield estimates : Evaluation for semi-arid irrigated winter wheat monitored with green leaf area index," *Environmental Modelling & Software*, vol. 23, no. 7, pp. 876–892, 2008.
- [74] M. Battude, A. Al Bitar, A. Brut, T. Tallec, M. Huc, J. Cros, J.-J. Weber, L. Lhuissier, V. Simonneaux, and V. Demarez, "Modeling water needs and total irrigation depths of maize crop in the south west of france using high spatial and temporal resolution satellite imagery," *Agricultural Water Management*, vol. 189, pp. 123–136, 2017.

- [75] P. Steduto, T. C. Hsiao, D. Raes, and E. Fereres, "Aquacrop—the fao crop model to simulate yield response to water : I. concepts and underlying principles," *Agronomy Journal*, vol. 101, no. 3, pp. 426–437, 2009.
- [76] E. Nana, C. Corbari, and D. Bocchiola, "A model for crop yield and water footprint assessment : Study of maize in the po valley," *Agricultural Systems*, vol. 127, pp. 139–149, 2014.
- [77] J. Constantin, M. Willaume, C. Murgue, B. Lacroix, and O. Therond, "The soil-crop models stics and aqyield predict yield and soil water content for irrigated crops equally well with limited data," *Agricultural and Forest Meteorology*, vol. 206, pp. 55–68, 2015.
- [78] N. Sánchez, J. Martínez-Fernández, A. Calera, E. Torres, and C. Pérez-Gutiérrez, "Combining remote sensing and in situ soil moisture data for the application and validation of a distributed water balance model (hidromore)," *Agricultural Water Management*, vol. 98, no. 1, pp. 69–78, 2010.
- [79] R. Moreno, E. Arias, J. Sánchez, D. Cazorla, J. Garrido, and J. Gonzalez-Piqueras, "Hidromore 2 : An optimized and parallel version of hidromore," in *2017 8th International Conference on Information and Communication Systems (ICICS)*, pp. 1–6, IEEE, 2017.
- [80] V. Simonneaux, M. Le Page, D. Helson, J. Metral, S. Thomas, B. Duchemin, M. Cherkaoui, H. Kharrou, B. Berjami, and A. Chehbouni, "Estimation spatialisée de l'Évapotranspiration des cultures irriguées par télédétection. Application à la gestion de l'Irrigation dans la plaine du Haouz (Marrakech, Maroc).," *Science et changements planétaires / Sécheresse*, vol. 20, no. 1, pp. 123–130, 2009.
- [81] S. Er-Raki, A. Chehbouni, and B. Duchemin, "Combining satellite remote sensing data with the fao-56 dual approach for water use mapping in irrigated wheat fields of a semi-arid region," *Remote Sensing*, vol. 2, no. 1, pp. 375–387, 2010.
- [82] L. Olivera-Guerra, O. Merlin, S. Er-Raki, S. Khabba, and M. J. Escorihuela, "Estimating the water budget components of irrigated crops : Combining the fao-56 dual crop coefficient with surface temperature and vegetation index data," *Agricultural Water Management*, vol. 208, pp. 120–131, 2018.
- [83] Y. Chen, D. Lu, L. Luo, Y. Pokhrel, K. Deb, J. Huang, and Y. Ran, "Detecting irrigation extent, frequency, and timing in a heterogeneous arid agricultural region using modis time series, landsat imagery, and ancillary data," *Remote Sensing of Environment*, vol. 204, pp. 197–211, 2018.
- [84] S. Saadi, V. Simonneaux, G. Boulet, B. Raimbault, B. Mougnot, P. Fanise, H. Ayari, and Z. Lili-Chabaane, "Monitoring irrigation consumption using high resolution ndvi image time series : Calibration and validation in the kairouan plain (tunisia)," *Remote Sensing*, vol. 7, no. 10, pp. 13005–13028, 2015.
- [85] S. Saadi, *Estimation spatialisée de l'évapotranspiration réelle et des volumes d'irrigation à l'aide de modèles de bilans hydrique et énergétique forcés par des données de la télédétection optique (VIS/PIR/IRT)*. PhD thesis, Université de Toulouse, Université Toulouse III-Paul Sabatier, 2018.
- [86] M. Jamagne, B. JC, *et al.*, "Quelques données sur la variabilité dans le milieu naturel de la réserve en eau des sols.," 1977.
- [87] J. Wösten and A. Nemes, "Pedotransfer functions for europe," in *Development of Pedotransfer Functions in Soil Hydrology*, vol. 30 of *Developments in Soil Science*, pp. 431–435, Elsevier, 2004.
- [88] A. Bruand, O. Duval, and I. Cousin, "Estimation des propriétés de rétention en eau des sols à partir de la base de données solhydro : Une première proposition combinant le type d'horizon, sa texture et sa densité apparente.," *Etude et gestion des Sols*, vol. 11, no. 3, pp. 3–323, 2004.
- [89] J.-E. Bergez, P. Debaeke, J.-M. Deumier, B. Lacroix, D. Leenhardt, P. Leroy, and D. Wallach, "Moderato : an object-oriented decision tool for designing maize irrigation schedules," *Ecological Modelling*, vol. 137, no. 1, pp. 43–60, 2001.
- [90]

- [91] R. Torres, P. Snoeij, D. Geudtner, D. Bibby, M. Davidson, E. Attema, P. Potin, B. Rommen, N. Floury, M. Brown, I. N. Traver, P. Deghaye, B. Duesmann, B. Rosich, N. Miranda, C. Bruno, M. L'Abbate, R. Croci, A. Pietropaolo, M. Huchler, and F. Rostan, "GMES sentinel-1 mission," *Remote Sensing of Environment*, vol. 120, pp. 9–24, 2012.
- [92] M. Drusch, U. Del Bello, S. Carlier, O. Colin, V. Fernandez, F. Gascon, B. Hoersch, C. Isola, P. Laberinti, P. Martimort, A. Meygret, F. Spoto, O. Sy, F. Marchese, and P. Bargellini, "Sentinel-2 : ESA's optical high-resolution mission for GMES operational services," *Remote Sensing of Environment*, vol. 120, pp. 25–36, 2012.
- [93] F. Baup, R. Fieuzal, and J. Betbeder, "Estimation of soybean yield from assimilated optical and radar data into a simplified agrometeorological model," in *2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, pp. 3961–3964, IEEE, 2015.
- [94] R. Fieuzal and F. Baup, "Estimation of sunflower yield using multi-spectral satellite data (optical or radar) in a simplified agro-meteorological model," in *2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, pp. 4001–4004, IEEE, 2015.
- [95] J. Betbeder, R. Fieuzal, and F. Baup, "Assimilation of lai and dry biomass data from optical and sar images into an agro-meteorological model to estimate soybean yield," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 9, no. 6, pp. 2540–2553, 2016.
- [96] M. El-Hajj, N. Baghdadi, B. Cheviron, G. Belaud, M. Zribi, *et al.*, "Integration of remote sensing derived parameters in crop models : application to the pilote model for hay production.," *Agricultural Water Management*, vol. 176, pp. 67–79, 2016.
- [97] Y. Pageot, F. Baup, J. Inglada, N. Baghdadi, and V. Demarez, "Detection of irrigated and rainfed crops in temperate areas using sentinel-1 and sentinel-2 time series," *Remote Sensing*, vol. 12, no. 18, 2020.
- [98] D. R. E. A. L. d'Occitanie, *Bassin Adour-Garonne : Réforme des volumes prélevables, Fiches par Organisme Unique de Gestion Collective (OUGC)*. DREAL Occitanie, 2020.
- [99] E. Auquièrre, X. Blaes, and P. Defourny, "Crop growth monitoring by sar time series : Canopy closing date detection for maize and sugar beet," in *n/a*, 1998.
- [100] M. Ameline, R. Fieuzal, J. Betbeder, J.-F. Berthoumieu, and F. Baup, "Combined use of agrometeorological model and multi-temporal satellite data (optical and radar) for monitoring corn biophysical parameters," Universitat de Valencia, 2017.
- [101] O. Hagolle, M. Huc, D. Villa Pascual, and G. Dedieu, "A multi-temporal and multi-spectral method to estimate aerosol optical thickness over land, for the atmospheric correction of formosat-2, landsat, ven $\mu$ s and sentinel-2 images," *Remote Sensing*, vol. 7, no. 3, pp. 2668–2691, 2015.
- [102] Y. Durand, E. Brun, L. Merindol, G. Guyomarc'h, B. Lesaffre, and E. Martin, "A meteorological estimation of relevant parameters for snow models," *Annals of glaciology*, vol. 18, pp. 65–71, 1993.
- [103] P. A. Sanchez, S. Ahamed, F. Carré, A. E. Hartemink, J. Hempel, J. Huising, P. Lagacherie, A. B. McBratney, N. J. McKenzie, M. d. L. Mendonça-Santos, B. Minasny, L. Montanarella, P. Okoth, C. A. Palm, J. D. Sachs, K. D. Shepherd, T.-G. Vågen, B. Vanlauwe, M. G. Walsh, L. A. Winowiecki, and G.-L. Zhang, "Digital soil map of the world," *Science*, vol. 325, no. 5941, pp. 680–681, 2009.
- [104] D. D. Arrouays, A. B. McBratney, B. Minasny, J. W. Hempel, G. Heuvelink, R. MacMillan, A. Hartemink, P. P. Lagacherie, and N. J. McKenzie, "The GlobalSoilMap project specifications," in *GlobalSoilMap : Basis of the global spatial soil information system*, p. 478 p., CRC Press (Taylor & Francis Group), 2014.
- [105] D. Arrouays, P. Roudier, Z. Libohova, and A. B. McBratney, "The GlobalSoilMap project," in *2. Global Soil Security Conference*, (Paris, France), Dec. 2016.

- [106] D. Arrouays, M. G. Grundy, A. E. Hartemink, J. W. Hempel, G. B. Heuvelink, S. Y. Hong, P. Lagacherie, G. Lelyk, A. B. McBratney, N. J. McKenzie, M. d.L. Mendonca-Santos, B. Minasny, L. Montanarella, I. O. Odeh, P. A. Sanchez, J. A. Thompson, and G.-L. Zhang, "Chapter three - globalsoilmap : Toward a fine-resolution global grid of soil properties," vol. 125 of *Advances in Agronomy*, pp. 93–134, Academic Press, 2014.
- [107] M. Román Dobarco, H. Bourennane, D. Arrouays, N. P. Saby, I. Cousin, and M. P. Martin, "Uncertainty assessment of GlobalSoilMap soil available water capacity products : A french case study," *Geoderma*, vol. 344, pp. 14–30, 2019.
- [108] D. Baize and B. Jabiol, *Guide pour la description des sols*. Quae, 1995.
- [109] J. Moncrieff, J. Massheder, H. De Bruin, J. Elbers, T. Friborg, B. Heusinkveld, P. Kabat, S. Scott, H. Soegaard, and A. Verhoef, "A system to measure surface fluxes of momentum, sensible heat, water vapour and carbon dioxide," *Journal of Hydrology*, vol. 188, pp. 589–611, 1997.
- [110] D. D. Baldocchi, "Assessing the eddy covariance technique for evaluating carbon dioxide exchange rates of ecosystems : past, present and future," *Global change biology*, vol. 9, no. 4, pp. 479–492, 2003.
- [111] M. Aubinet, T. Vesala, and D. Papale, *Eddy covariance : a practical guide to measurement and data analysis*. Springer Science & Business Media, 2012.
- [112] I. S. Bowen, "The ratio of heat losses by conduction and by evaporation from any water surface," *Physical review*, vol. 27, no. 6, p. 779, 1926.
- [113] O. Dare-Idowu, L. Jarlan, V. Le-Dantec, V. Rivalland, E. Ceschia, A. Boone, and A. Brut, "Hydrological functioning of maize crops in southwest france using eddy covariance measurements and a land surface model," *Water*, vol. 13, no. 11, 2021.
- [114] Y. Chen, D. Lu, L. Luo, Y. Pokhrel, K. Deb, J. Huang, and Y. Ran, "Detecting irrigation extent, frequency, and timing in a heterogeneous arid agricultural region using modis time series, landsat imagery, and ancillary data," *Remote Sensing of Environment*, vol. 204, pp. 197–211, 2018.
- [115] J. Dong, R. K. Kaufmann, R. B. Myneni, C. J. Tucker, P. E. Kauppi, J. Liski, W. Buermann, V. Alexeyev, and M. K. Hughes, "Remote sensing estimates of boreal and temperate forest woody biomass : carbon pools, sources, and sinks," *Remote Sensing of Environment*, vol. 84, no. 3, pp. 393 – 410, 2003.
- [116] C. Keeling, C. Tucker, G. Asrar, and R. Nemani, "Increased plant growth in the northern high latitudes from 1981 to 1991," *Nature.*, vol. 386, no. 6626, pp. 698–702, 1997.
- [117] B. Tardy, *Méthodes d'exploitation de données historiques pour la production de cartes d'occupation des sols à partir d'images de télédétection et en absence de données de référence de la période à cartographier*. PhD thesis, 2019. Thèse de doctorat dirigée par Inglada, Jordi Surfaces et interfaces continentales, Hydrologie Toulouse 3 2019.
- [118] V. Vapnik, "Pattern recognition using generalized portrait method," *Automation and remote control*, vol. 24, pp. 774–780, 1963.
- [119] D. A. Mouat, G. G. Mahin, and J. Lancaster, "Remote sensing techniques in the analysis of change detection," *Geocarto International*, vol. 8, no. 2, pp. 39–50, 1993.
- [120] L. Breiman, "Random forests," *Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001.
- [121] V. F. Rodriguez-Galiano, B. Ghimire, J. Rogan, M. Chica-Olmo, and J. P. Rigol-Sanchez, "An assessment of the effectiveness of a random forest classifier for land-cover classification," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 67, pp. 93–104, 2012.

- [122] C. Pelletier, S. Valero, J. Inglada, N. Champion, and G. Dedieu, "Assessing the robustness of random forests to map land cover with high resolution satellite image time series over large areas," *Remote Sensing of Environment*, vol. 187, pp. 156–168, 2016.
- [123] D. Ketchum, K. Jencso, M. P. Maneta, F. Melton, M. O. Jones, and J. Huntington, "Irrmapper : A machine learning approach for high resolution mapping of irrigated agriculture across the western u.s.," *Remote Sensing*, vol. 12, no. 14, 2020.
- [124] H. Zurqani, J. Allen, C. Post, C. Pellett, and T. Walker, "Mapping and quantifying agricultural irrigation in heterogeneous landscapes using google earth engine," *Remote Sensing Applications : Society and Environment*, vol. 23, p. 100590, 2021.
- [125] B. Efron and R. J. Tibshirani, *An introduction to the bootstrap*. CRC press, 1994.
- [126] L. Breiman, "Bagging predictors," *Machine learning*, vol. 24, no. 2, pp. 123–140, 1996.
- [127] R. G. Congalton, "A review of assessing the accuracy of classifications of remotely sensed data," *Remote Sensing of Environment*, vol. 37, no. 1, pp. 35–46, 1991.
- [128] C. Pelletier, S. Valero, J. Inglada, N. Champion, C. Marais Sicre, G. Dedieu, C. Pelletier, S. Valero, J. Inglada, N. Champion, C. Marais Sicre, and G. Dedieu, "Effect of training class label noise on classification performances for land cover mapping with satellite image time series," *Remote Sensing*, vol. 9, no. 2, p. 173, 2017.
- [129] J. Cohen, "A coefficient of agreement for nominal scales," *Educational and psychological measurement*, vol. 20, no. 1, pp. 37–46, 1960.
- [130] M.-C. Girard and C.-M. Girard, *Traitement des données de télédétection-2e éd. : Environnement et ressources naturelles*. Dunod, 2010.
- [131] J. Inglada, A. Vincent, M. Arias, B. Tardy, D. Morin, and I. Rodes, "Operational high resolution land cover map production at the country scale using satellite image time series," *Remote Sensing*, vol. 9, no. 1, p. 95, 2017.
- [132] M. Grizonnet, J. Michel, V. Poughon, J. Inglada, M. Savinaud, and R. Cresson, "Orfeo toolbox : Open source processing of remote sensing images," *Open Geospatial Data, Software and Standards*, vol. 2, no. 1, p. 15, 2017.
- [133] B. D. Wardlow, S. L. Egbert, and J. H. Kastens, "Analysis of time-series MODIS 250 m vegetation index data for crop classification in the US Central Great Plains," *REMOTE SENSING OF ENVIRONMENT*, vol. 108, pp. 290–310, JUN 15 2007.
- [134] B. Zheng, S. W. Myint, P. S. Thenkabail, and R. M. Aggarwal, "A support vector machine to identify irrigated crop types using time-series landsat NDVI data," *International Journal of Applied Earth Observation and Geoinformation*, vol. 34, pp. 103–112, 2015.
- [135] C. J. Tucker, "Red and photographic infrared linear combinations for monitoring vegetation," *Remote sensing of Environment*, vol. 8, no. 2, pp. 127–150, 1979.
- [136] A. Huete, K. Didan, T. Miura, E. P. Rodriguez, X. Gao, and L. G. Ferreira, "Overview of the radiometric and biophysical performance of the modis vegetation indices," *Remote sensing of environment*, vol. 83, no. 1-2, pp. 195–213, 2002.
- [137] B.-c. Gao, "NDWI—a normalized difference water index for remote sensing of vegetation liquid water from space," *Remote Sensing of Environment*, vol. 58, no. 3, pp. 257–266, 1996.
- [138] A. Gitelson and M. N. Merzlyak, "Spectral reflectance changes associated with autumn senescence of aesculus hippocastanum l. and acer platanoides l. leaves. spectral features and relation to chlorophyll estimation," *Journal of Plant Physiology*, vol. 143, no. 3, pp. 286–292, 1994.

- [139] D. A. Sims and J. A. Gamon, "Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages," *Remote sensing of environment*, vol. 81, no. 2-3, pp. 337–354, 2002.
- [140] P. Patel, H. S. Srivastava, S. Panigrahy, and J. S. Parihar, "Comparative evaluation of the sensitivity of multi-polarized multi-frequency sar backscatter to plant density," *International Journal of Remote Sensing*, vol. 27, no. 2, pp. 293–305, 2006.
- [141] A. Jacome, M. Bernier, K. Chokmani, Y. Gauthier, J. Poulin, and D. De Sève, "Monitoring volumetric surface soil moisture content at the la grande basin boreal wetland by radar multi polarization data," *Remote Sensing*, vol. 5, no. 10, pp. 4919–4941, 2013.
- [142] A. Amazirh, O. Merlin, S. Er-Raki, Q. Gao, V. Rivalland, Y. Malbeteau, S. Khabba, and M. J. Escorihuela, "Retrieving surface soil moisture at high spatio-temporal resolution from a synergy between sentinel-1 radar and landsat thermal data : A study case over bare soil," *Remote sensing of environment*, vol. 211, pp. 321–337, 2018.
- [143] S. Chauhan and H. S. Srivastava, "Comparative evaluation of the sensitivity of multi-polarized sar and optical data for various land cover classes," *Int. J. Adv. Remote Sens. GIS Geogr*, vol. 4, pp. 1–14, 2016.
- [144] A. Veloso, S. Mermoz, A. Bouvet, T. Le Toan, M. Planells, J.-F. Dejoux, and E. Ceschia, "Understanding the temporal behavior of crops using sentinel-1 and sentinel-2-like data for agricultural applications," *Remote Sensing of Environment*, vol. 199, pp. 415–426, 2017.
- [145] C. Igel, V. Heidrich-Meisner, and T. Glasmachers, "Shark," *Journal of Machine Learning Research*, vol. 9, pp. 993–996, 2008.
- [146] A. N. French, D. J. Hunsaker, C. A. Sanchez, M. Saber, J. R. Gonzalez, and R. Anderson, "Satellite-based ndvi crop coefficients and evapotranspiration with eddy covariance validation for multiple durum wheat fields in the us southwest," *Agricultural Water Management*, vol. 239, p. 106266, 2020.
- [147] E. Carpintero, A. Andreu, P. J. Gómez-Giráldez, Á. Blázquez, and M. P. González-Dugo, "Remote-sensing-based water balance for monitoring of evapotranspiration and water stress of a mediterranean oak–grass savanna," *Water*, vol. 12, no. 5, 2020.
- [148] I. Cousin, *Estimation of the soil Available Water Content by direct measurements and crop-model inversion, from the plot to the territory scales*. Projet ANR-14-CE01-0011, RUEdesSOLS, 2019.
- [149] J. Constantin, V. Picheny, L. H. Nassar, and J.-E. Bergez, "A method to assess the impact of soil available water capacity uncertainty on crop models with a tipping-bucket approach," *European Journal of Soil Science*, vol. 71, no. 3, pp. 369–381, 2020.
- [150] M. Claverie, *Estimation spatialisée de la biomasse et des besoins en eau des cultures à l'aide de données satellitaires à hautes résolutions spatiale et temporelle : application aux agrosystèmes du sud-ouest de la France*. PhD thesis, Université Paul Sabatier - Toulouse 3, 2012.
- [151] C. H. B. Priestley and R. J. TAYLOR, "On the assessment of surface heat flux and evaporation using large-scale parameters," *Monthly weather review*, vol. 100, no. 2, pp. 81–92, 1972.
- [152] A. Perrier, "Importance des définitions de l'évapotranspiration dans le domaine pratique de la mesure, de l'estimation of de la notion de coefficients culturaux. xv'," *Journal of Hydraulics*, pp. 1–7, 1978.
- [153] R. G. Allen, L. S. Pereira, D. Raes, M. Smith, *et al.*, "Crop evapotranspiration-guidelines for computing crop water requirements-fao irrigation and drainage paper 56," *Fao, Rome*, vol. 300, no. 9, p. D05109, 1998.
- [154] R. G. Allen, L. S. Pereira, M. Smith, D. Raes, and J. L. Wright, "Fao-56 dual crop coefficient method for estimating evaporation from soil and application extensions," *Journal of irrigation and drainage engineering*, vol. 131, no. 1, pp. 2–13, 2005.

- [155] G. Gosse, A. Perrier, and B. Itier, "Etude de l'évapotranspiration réelle d'une culture de blé dans le bassin parisien," *Ann. agron*, vol. 28, no. 5, pp. 521–541, 1977.
- [156] E. Devonec and A. P. Barros, "Exploring the transferability of a land-surface hydrology model," *Journal of Hydrology*, vol. 265, no. 1, pp. 258–282, 2002.
- [157] J. P. Lhomme, N. Boudhina, M. M. Masmoudi, and A. Chehbouni, "Estimation of crop water requirements : extending the one-step approach to dual crop coefficients," *Hydrology and Earth System Sciences*, vol. 19, no. 7, pp. 3287–3299, 2015.
- [158] Y. Zhang and M. Wegehenkel, "Integration of modis data into a simple model for the spatial distributed simulation of soil water content and evapotranspiration," *Remote sensing of Environment*, vol. 104, no. 4, pp. 393–408, 2006.
- [159] O. Merlin, V. G. Stefan, A. Amazirh, A. Chanzy, E. Ceschia, S. Er-Raki, P. Gentine, T. Talleg, J. Ezzahar, S. Bircher, *et al.*, "Modeling soil evaporation efficiency in a range of soil and atmospheric conditions using a meta-analysis approach," *Water Resources Research*, vol. 52, no. 5, pp. 3663–3684, 2016.
- [160] A. Amazirh, O. Merlin, S. Er-Raki, E. Bouras, and A. Chehbouni, "Implementing a new texture-based soil evaporation reduction coefficient in the fao dual crop coefficient method," *Agricultural Water Management*, vol. 250, p. 106827, 2021.
- [161] M. Battude, *Estimation des rendements, des besoins et consommations en eau du maïs dans le sud-ouest de la France : apport de la télédétection à hautes résolutions spatiale et temporelle*. PhD thesis, Université Paul Sabatier - Toulouse 3, 2017.
- [162] L. Olivera-Guerra, O. Merlin, and S. Er-Raki, "Irrigation retrieval from landsat optical/thermal data integrated into a crop water balance model : A case study over winter wheat fields in a semi-arid region," *Remote Sensing of Environment*, vol. 239, p. 111627, 2020.
- [163] S. Er-Raki, A. Chehbouni, N. Guemouria, B. Duchemin, J. Ezzahar, and R. Hadria, "Combining fao-56 model and ground-based remote sensing to estimate water consumptions of wheat crops in a semi-arid region," *Agricultural Water Management*, vol. 87, no. 1, pp. 41–54, 2007.
- [164] O. Merlin, A. Al Bitar, V. Rivalland, P. Béziat, E. Ceschia, and G. Dedieu, "An analytical model of evaporation efficiency for unsaturated soil surfaces with an arbitrary thickness," *Journal of Applied Meteorology and Climatology*, vol. 50, no. 2, pp. 457–471, 2011.
- [165] F. Baret, O. Hagolle, B. Geiger, P. Bicheron, B. Miras, M. Huc, B. Berthelot, F. Niño, M. Weiss, O. Sainain, *et al.*, "Lai, fapar and fcover cyclopes global products derived from vegetation : Part 1 : Principles of the algorithm," *Remote sensing of environment*, vol. 110, no. 3, pp. 275–286, 2007.
- [166] M. Weiss and F. Baret, "S2toolbox level 2 products : Lai, fapar, fcover," *Institut National de la Recherche Agronomique (INRA), Avignon*, 2016.
- [167] F. Camacho, J. Cernicharo, R. Lacaze, F. Baret, and M. Weiss, "Geov1 : Lai, fapar essential climate variables and fcover global time series capitalizing over existing products. part 2 : Validation and inter-comparison with reference products," *Remote Sensing of Environment*, vol. 137, pp. 310–329, 2013.
- [168] F. Filipponi, E. Valentini, A. Nguyen Xuan, C. A. Guerra, F. Wolf, M. Andrzejak, and A. Taramelli, "Global modis fraction of green vegetation cover for monitoring abrupt and gradual vegetation changes," *Remote Sensing*, vol. 10, no. 4, 2018.
- [169] F. Camacho, C. Latorre, R. Lacaze, J. Sanchez-Zapero, F. Baret, and M. Weiss, "Protocol for building a consistent database for accuracy assessment of lai, fapar and fcover satellite products : The imagines database. remote sens," *preparation Remote Sens.(in preparation)*, 2021.

- [170] C. Toureiro, R. Serralheiro, S. Shahidian, and A. Sousa, "Irrigation management with remote sensing : Evaluating irrigation requirement for maize under mediterranean climate condition," *Agricultural Water Management*, vol. 184, pp. 211–220, 2017.
- [171] A. Aklilu Tesfaye and B. Gessesse Awoke, "Evaluation of the saturation property of vegetation indices derived from sentinel-2 in mixed crop-forest ecosystem. spat," *Inf. Res*, 2020.
- [172] A. Labidi, A. Bouthier, and I. Cousin, "Comment évaluer simplement la réserve utile d'un sol ?," 2017.
- [173] C. Massari, S. Modanesi, J. Dari, A. Gruber, G. J. M. De Lannoy, M. Girotto, P. Quintana-Seguí, M. Le Page, L. Jarlan, M. Zribi, N. Ouaadi, M. Vreugdenhil, L. Zappa, W. Dorigo, W. Wagner, J. Brombacher, H. Pelgrum, P. Jaquot, V. Freeman, E. Volden, D. Fernandez Prieto, A. Tarpanelli, S. Barbetta, and L. Brocca, "A review of irrigation information retrievals from space and their utility for users," *Remote Sensing*, vol. 13, no. 20, 2021.
- [174] N. Ouaadi, L. Jarlan, S. Khabba, J. Ezzahar, and O. Merlin, "Surface soil moisture data assimilation for irrigation amounts and timing estimation in semi-arid regions," in *EGU General Assembly Conference Abstracts*, EGU General Assembly Conference Abstracts, pp. EGU21–14594, Apr. 2021.
- [175] L. Zappa, S. Schlaffer, B. Bauer-Marschallinger, C. Nendel, B. Zimmerman, and W. Dorigo, "Detection and quantification of irrigation water amounts at 500 m using sentinel-1 surface soil moisture," *Remote Sensing*, vol. 13, no. 9, p. 1727, 2021.
- [176] M. Ameline, *Diagnostic hydrique et estimation de la production de la culture de maïs : vers la mise en place d'un service tout temps*. PhD thesis, Université Paul Sabatier - Toulouse 3, 2019.
- [177] F. Bouttier, "Arome, avenir de la prévision régionale," *La météorologie*, 2007.
- [178] P. Tabary, J. Desplats, K. Do Khac, F. Eideliman, C. Gueguen, and J.-C. Heinrich, "The New French Operational Radar Rainfall Product. Part II : Validation," *Weather and Forecasting*, vol. 22, pp. 409–427, 06 2007.
- [179] C. Rosenberg, M. Hebert, and H. Schneiderman, "Semi-supervised self-training of object detection models," 2005.
- [180] H. Bazzi, N. Baghdadi, G. Amin, I. Fayad, M. Zribi, V. Demarez, and H. Belhouchette, "An operational framework for mapping irrigated areas at plot scale using sentinel-1 and sentinel-2 data," *Remote Sensing*, vol. 13, no. 13, p. 2584, 2021.
- [181] M. Saraiva, E. Protas, M. Salgado, and C. Souza, "Automatic mapping of center pivot irrigation systems from satellite images using deep learning," *Remote Sensing*, vol. 12, no. 3, 2020.
- [182] G. Satalino, F. Mattia, A. Balenzano, F. P. Lovergine, M. Rinaldi, A. P. De Santis, S. Ruggieri, D. A. Nafria Garcia, V. Paredes Gomez, E. Ceschia, M. Planells, T. Le Toan, A. Ruiz, and J. F. Moreno, "SENTINEL-1 & SENTINEL-2 DATA FOR SOIL TILLAGE CHANGE DETECTION," in *IGARSS 2018 - 2018 IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM*, IEEE International Symposium on Geoscience and Remote Sensing IGARSS, pp. 6627–6630, Inst Elect & Elect Engineers ; Inst Elect & Elect Engineers Geoscience & Remote Sensing Soc ; European Space Agcy, 2018. 38th IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Valencia, SPAIN, JUL 22-27, 2018.
- [183] Y. Sadeh, X. Zhu, K. Chenu, and D. Dunkerley, "Sowing date detection at the field scale using cubesats remote sensing," *Computers and Electronics in Agriculture*, vol. 157, pp. 568–580, 2019.
- [184] M. Eden, H. H. Gerke, and S. Houot, "Organic waste recycling in agriculture and related effects on soil water retention and plant available water : a review," *Agronomy for Sustainable Development*, vol. 37, no. 2, p. 11, 2017.

# Liste des illustrations

1.1	<b>Part du territoire français impacté par les mesures de restrictions des usages en eau sur la période de 2012 à 2019.</b> Les zones en rouges illustrent la part du territoire confrontée à des mesures de crise, en orange à des mesures d'alerte renforcée et en jaune à des mesures d'alerte. source : CGEDD, 2019 . . . . .	8
1.2	<b>Prélèvements en eau pour l'irrigation en France en 2013 par régions. Exprimé en hm<sup>3</sup></b> . . . . .	9
1.3	<b>Carte du déséquilibre quantitatif en eau à l'échelle des périmètres élémentaires du bassin versant Adour-Garonne, Extrait du SDAGE Adour Garonne 2016-2021</b> . . . . .	14
2.1	<b>Localisation des zones d'études,</b> Les bassins versants étudiés d'Adour-Amont en bleu, Neste en orange et Tarn Aval en rouge . . . . .	16
2.2	<b>Répartition des occupations du sol agricole en été sur les bassins versants,</b> données issues du Registre parcellaire Graphique . . . . .	17
2.3	<b>Diagramme ombrothermique de la zone d'étude</b> Figure 3.17a illustre l'année 2017 et la figure 3.17b correspond à 2018. Pluviométrie mensuelle (en bleu) et température moyenne mensuelle (en rouge) issues de la base de données SAFRAN . . . . .	17
2.4	<b>Carte de la pression de prélèvement pour l'irrigation; source DRAAF 2019,</b> les bassins versants colorés correspondent aux trois zones étudiées. . . . .	18
2.5	<b>Schéma du procédé d'acquisition des images S1 mode IW</b> . . . . .	19
2.6	<b>Chaîne de traitement S1-tiling pour le traitement des données Sentinel-1, par Thierry Koleck</b>	20
2.7	<b>Localisation des zones d'étude, selon les emprises des tuiles Sentinel-2 issues de la plateforme Theia</b> . . . . .	21
2.8	<b>Calendrier d'acquisition des images Sentinel-2 sur les années 2017 et 2018, en fonction des tuiles utilisées</b> . . . . .	21
2.9	<b>Imbrication des données pédologiques entre les données du RRP et celles avec la spatia- lisation des UTS</b> . . . . .	23
2.10	<b>Carte des profondeurs maximale d'enracinement et de réserve utile, sur le département du Gers,</b> carte produite à partir de la spatialisation des UTS. . . . .	23
2.11	<b>Distribution des types de sols dérivés des produits pédologiques, avec la carte des UTS (à gauche), et GSM (à droite) basés sur le système de classification du triangle de l'Aisne.</b> La couleur des cercles correspond aux nombres de parcelles ayant les mêmes caractéristiques pédologiques. . . . .	24
2.12	<b>Méthodologique d'extraction de la donnée pédologique</b> . . . . .	25
2.13	<b>Localisation des différents jeux de données dans le Gers.</b> Les polygones bleus indiquent les parcelles de référence suivies par la CACG. Les limites des parcelles enquêtées sont en noir et les périmètres irrigués (ASA) en vert. . . . .	27
2.14	<b>Dispositif de mesure de l'humidité du sol depuis 2012 (en bleu) et profondeur de prélève- ment (en rouge)</b> (source : Tiphaine Tallec) . . . . .	29
2.15	<b>Carte des mesures de profondeur d'enracinement sur la parcelle expérimentale de Lamothe, relevé effectué par l'ESA Purpan,</b> Le contour de la parcelle coloré en jaune. . . . .	29
3.1	<b>Diagramme de la chaîne de traitement (IOTA<sup>2</sup>).</b> Les carrés bleus illustrent les entrées et sorties des différents algorithmes, et les carrés verts illustrent les différents algorithmes utilisés au cours du processus [illustration d'origine : [Inglada et al. [47]] . . . . .	33

3.2	<b>Matrice de confusion théorique issue de Pelletier et al [128]</b> , Les couleurs correspondent aux classes labellisées et classées. Les nombres indiqués sur la diagonale correspondent au nombre de pixels correctement classés. Les autres nombres en dehors de la diagonale expriment les confusions entre les classes. . . . .	34
3.3	<b>Organigramme de la méthodologie.</b> Les carrés gris représentent les données initiales. Les carrés jaunes sont les images des indices cumulés mensuellement après traitement par l'algorithme, qui est représenté par un carré rouge. Les carrés verts correspondent aux différents scénarios testés. Les carrés bleus représentent les différentes cartes des classificateurs, c'est-à-dire les classifications et les cartes de confiance. . . . .	35
3.4	<b>Dynamique des indices optiques (NDVI [a et c] et NDWI [b et d]) pour les cultures de maïs, de soja et de tournesol</b> , Les courbes en trait plein représentent le maïs, la ligne pointillée représente le soja, avec le bleu irriguée et le rouge pluviale pour les deux cultures. La courbe noire représente le tournesol. L'enveloppe autour des courbes correspond à l'intervalle de confiance à 95 %. . . . .	37
3.5	<b>Dynamique des polarisations SAR (VV [a et c] et VH [c et d]) pour les cultures de maïs, de soja et de tournesol</b> , Les courbes en trait plein représentent le maïs, la ligne pointillée représente le soja, avec le bleu irriguée et le rouge pluviale pour les deux cultures. La courbe noire représente le tournesol. L'enveloppe autour des courbes correspond à l'intervalle de confiance à 95 %. . . . .	38
3.6	<b>Dynamique temporelle des indices cumulés (NDVI, NDWI, VV, et VH) pour toutes les cultures en 2017.</b> La courbe bleue illustre la dynamique du maïs irrigué, celle en jaune du tournesol. Le maïs pluvial est représenté par une courbe rouge, le soja irrigué par une courbe verte et le soja pluvial par courbe noire . . . . .	39
3.7	<b>Performance globale pour chaque scénario.</b> Les barres orange et bleu correspondent respectivement à la précision globale et au Kappa. La figure 3.17a illustre les résultats obtenus en 2017 et la figure 3.17b correspond à ceux obtenus en 2018 sur l'Adour Amont. . . . .	41
3.8	<b>Fscore par classe en fonction des 3 scénarios</b> , Les barres orange et bleu correspondant respectivement aux années 2017 et 2018 . . . . .	43
3.9	<b>Confusion selon les scénarios.</b> Le titre de chaque sous-graphe correspond à la classe réelle et les étiquettes de l'axe horizontal font référence aux classes prédites. . . . .	44
3.10	<b>Carte de confiance pour l'année 2017. La figure (a) illustre le scénario 3 et la figure (b) illustre le scénario 4.</b> . . . . .	45
3.11	<b>Fscore par classe en fonction de la méthodologie pour l'année 2017</b> , les barres orange correspondent à la méthodologie avec cumul mensuels, et les barres bleues illustrent les résultats par classe pour la méthodologie sans les cumuls . . . . .	47
3.12	<b>Fscore par classe en fonction de la méthodologie pour l'année 2018</b> , les barres orange correspondent à la méthodologie avec cumul mensuels, et les barres bleues illustrent les résultats par classe pour la méthodologie sans les cumuls . . . . .	47
3.13	<b>Carte de confiance pour les scénarios optique &amp; SAR cumulés et non cumulés en 2017</b> . . . . .	48
3.14	<b>Performance globale pour l'approche cours de saison.</b> Les barres orange et bleu correspondent respectivement à la précision globale et au Kappa. . . . .	49
3.15	<b>Fscore par classe en fonction des données mensuelles ajoutées.</b> . . . . .	50
3.16	<b>Classification du maïs irrigué et pluvial au cours du temps sur l'année 2017</b> . . . . .	51
3.17	<b>Performance globale pour chaque classe</b> , Les barres orange et bleu correspondent respectivement à la précision globale et au Kappa. La figure 3.17a illustre les résultats obtenus en 2017 et la figure 3.17b correspond à ceux obtenus en 2018 sur le Tarn Aval. . . . .	52
3.18	<b>Fscore par classe en fonction des 3 scénarios</b> , Les barres orange et bleu correspondant respectivement aux années 2017 et 2018 . . . . .	53
3.19	<b>Confusion selon les scénarios.</b> Le titre de chaque sous-graphe correspond à la classe réelle et les étiquettes de l'axe horizontal font référence aux classes prédites. . . . .	54
4.1	<b>Répartition du maïs sur le territoire français en 2016, source SCEES</b> . . . . .	59
4.2	<b>Schéma du bilan hydrique d'une culture</b> , source : Martin Claverie [150] . . . . .	60

4.3	<b>Évolution du coefficient cultural (Kc) en trois phases : Kc initial, Kc de mi-saison et Kc de fin de saison</b> (source : Allen et al [153]) . . . . .	61
4.4	<b>Schéma modélisant les transferts d'eau entre sol, végétation et atmosphère dans SAMIR</b> , par Simonneaux et al [80] . . . . .	63
4.5	<b>Méthode d'estimation du coefficient Kr</b> , selon la FAO-56 : source Allen et al [153] . . . . .	65
4.6	<b>Schéma conceptuel du modèle SAMIR</b> . Les carrés verts illustrent les entrées du modèle, quant aux carrés rouges, ils correspondent aux sorties de celui-ci. Le carré en pointillé illustre le fonctionnement du module d'irrigation de manière schématique. . . . .	66
4.7	<b>Caractéristiques hydriques et d'évaporation en fonction des différents types de sol</b> , issues de la FAO-56 [153] . . . . .	67
4.8	<b>ETR mesurées et modélisées, selon la méthode FAO ou Merlin et al</b> Les points bleus correspondent aux résultats issus du formalisme FAO. Les points rouges correspondent aux résultats issus du formalisme de Merlin et al [159,160] . . . . .	70
4.9	<b>Dynamique du coefficient Kr en fonction du déficit en eau dans l'horizon évaporateur (De)</b> , Les points bleus illustrent l'approche développée par Merlin et les points orange correspondent à la méthode FAO-56. . . . .	71
4.10	<b>Dynamique du contenu en eau du sol issues des sondes à différentes profondeurs</b> . Les courbes bleue, orange et verte correspondent respectivement à l'humidité du sol à 0, 5 et 10 cm de profondeur. . . . .	71
4.11	<b>Comparaison des ETR observés et modélisés, en fonction de l'initialisation de la réserve utile en début d'année</b> . La courbe et les points rouges correspondent aux résultats issus de l'initialisation de la RU vide (RU = 0%). Les points et la courbe bleus illustrent les résultats issus de la simulation avec la RU pleine (RU =100 %). Quant à la courbe noire elle représente la dynamique journalière de l'ETR observé par la station. Les intervalles de confiance sont illustrés par les courbes en pointillées pour l'ETR observé et en bleu et rouge en fonction de l'initialisation de la RU. . . . .	72
4.12	<b>Photographie de la parcelle de Lamothe le 25 juin 2014</b> . ©CESBio . . . . .	73
4.13	<b>Dynamique du coefficient Ks, des déficits en eau dans l'horizon racinaire, en fonction du remplissage de la RU en début de simulation</b> . Les courbes en pointillés correspondent au coefficient de stress (Ks). Les courbes en trait plein correspond au déficit en eau dans l'horizon racinaire et celle avec un trait discontinu au contenu en eau facilement accessible par la plante soit RAW. La couleur bleu correspond aux simulations avec une réserve utile pleine et celle en rouge à une réserve utile vide. . . . .	74
4.14	<b>Comparaison des ETR observés et modélisés, en fonction de l'initialisation de la réserve utile en début de simulation</b> . La courbe et les points bleus correspondent aux résultats issus de l'initialisation de la RU pleine (RU = 100%). Les points et la courbe rouges illustrent les résultats issus de la simulation avec la RU initialisé avec l'année N-1 (RU = N-1 %). Quant à la courbe noire elle représente la dynamique journalière de l'ETR observée par la station. Les intervalles de confiance sont illustrés par les courbes en pointillées pour l'ETR observé et en bleu et rouge en fonction de l'initialisation de la RU. . . . .	75
4.15	<b>Comparaison des ETR observées et modélisées, en fonction deux méthodes de calcul du Fcover</b> . Les points bleus illustrent les résultats issus des simulations utilisant la $F_{cover_{emp}}$ . Quant aux points rouges, ce sont les résultats avec le $F_{cover_{sat}}$ qui sont illustrés. . . . .	76
4.16	<b>Comparaison des ETR observées et modélisées, en fonction de maxZr sur la parcelle de Lamothe</b> , Les différents couleurs des points représentent la comparaison des ETR journalières (modélisées vs observées) en fonction de la profondeur d'enracinement maximale, avec en bleu maxZr = 800 mm, en vert 1000 mm et en rouge 1500 mm. Les courbes illustrent les dynamiques journalières des ETR en fonction de maxZr, et celles en pointillés correspondent aux dynamiques de Ks. Les intervalles de confiance sont illustrés par les courbes en pointillés bleue, rouge et verte en fonction de la valeur de maxZr . . . . .	77

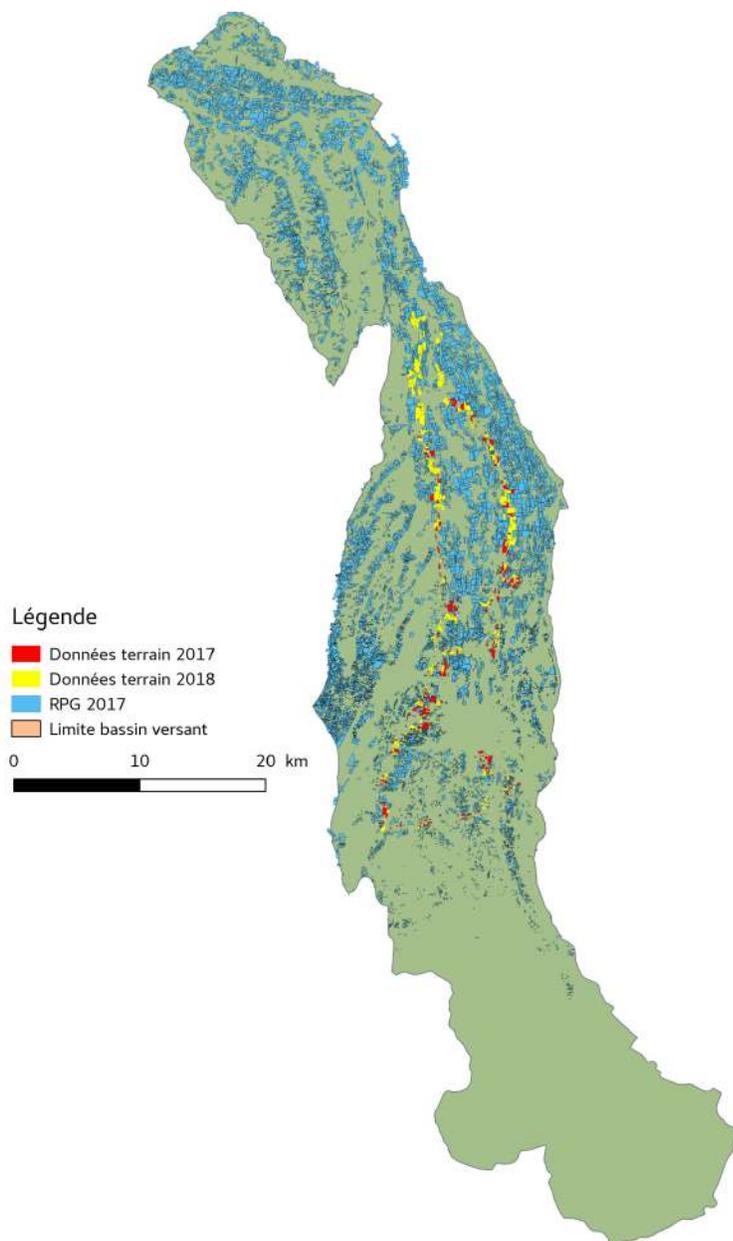
4.17	<b>Dynamique de l'humidité du sol de la parcelle de Lamothe en 2014</b> ,Les courbes bleu, jaune et vert, illustrent la dynamique des humidités du sol à différentes profondeurs. La courbe rouge illustre la dynamique du Ks modélisée par SAMIR. . . . .	78
4.18	<b>Dynamique de l'humidité du sol de la parcelle de Lamothe en 2008</b> , Les courbes bleu, jaune et vert, illustrent la dynamique des humidités du sol à différentes profondeurs. La courbe rouge correspond au coefficient de stress hydrique (Ks), Les croix et les ronds illustrent les événements d'irrigation (observés en rouge et simulés en vert) . . . . .	79
4.19	<b>Comparaison des irrigations saisonnières observées et modélisées en fonction des données pédologiques</b> a) Utilisation des données GSM, soit les fonctions de pédo-transfert et la profondeur de sol), b) Utilisation des données RRP <sub>UTS</sub> , soit les fonctions de pédo-transfert de Bruand et la profondeur d'enracinement maximale et c) Combinaison des données pédologiques avec les fonctions de pédo-transfert de GSM et la profondeur d'enracinement maximale du RRP <sub>UTS</sub> . . . . .	81
4.20	<b>Répartition des RU modélisées (a) et des maxZr et profondeur de sol (b) en fonction des données pédologiques.</b> Les barres bleues correspondent aux RU modélisées et à la profondeur de sol à partir des données pédologiques de GSM et quant aux barres rouges, elles illustrent les RU modélisées et les maxZr issues des des données pédologiques du RRP <sub>UTS</sub> . Les barres vertes correspondent aux RU modélisées selon les fonctions de pédotransfert de GSM et maxZr des données RRP <sub>UTS</sub> . . . . .	82
4.21	<b>Valeurs de profondeur d'enracinement maximale (maxZr), et fraction d'épuisement de l'eau du sol (p), pour les cultures d'été.</b> . . . . .	83
4.22	<b>Comparaison des irrigations saisonnières observées sur les parcelles des partenaires et ceux modélisées en fonction du forçage de maxZr selon la table 22 de la FAO-56 et des données GSM.</b> . . . . .	83
4.23	<b>Comparaison des volumes totaux annuels observés et modélisés sur les ASA.</b> Les points bleus illustrent les résultats de l'année 2017 et ceux en orange de l'année 2018 . . . . .	84
4.24	<b>Cartographie des quantités d'eau d'irrigation du maïs irrigué issus du modèle SAMIR, sur le bassin versant de la Adour Amont en 2017</b> . . . . .	86
4.25	<b>Classification du maïs irrigué issue du modèle SAMIR, avec l'application d'un seuil sur le bassin versant d'Adour Amont en 2017.</b> . . . . .	87
4.26	<b>Classification du maïs irrigué issue du modèle SAMIR, avec l'application d'un seuil sur le bassin versant de la Neste en 2017.</b> . . . . .	88
4.27	<b>Cartographie des quantités d'eau d'irrigation du maïs irrigué issue du modèle SAMIR, sur le bassin versant de la Neste en 2017</b> . . . . .	89
5.2	<b>Dynamique temporelle des indices cumulées (NDVI, NDWI, VV, et VH) pour toutes les cultures en 2018.</b> La courbe bleue illustre la dynamique du maïs irrigué, celle en jaune du tournesol. Le maïs pluvial est représenté par une courbe rouge, le soja irrigué par une courbe verte et le soja pluvial par courbe noire . . . . .	119

2.1	<b>Principales caractéristiques des bandes spectrales des satellites Sentinel-2 (A &amp; B)</b> . . . .	19
2.2	<b>Distribution du jeu de données de référence sur le bassin Adour Amont en 2017 et 2018</b> .	26
2.3	<b>Distribution du jeu de données de référence sur le bassin Tarn Aval en 2017 et 2018</b> . . . .	26
2.4	<b>Propriétés hydriques du site expérimental de Lamothe à 2 profondeurs</b> . . . . .	29
3.1	<b>Calendrier théorique des cultures d'été étudiées</b> , Les carrés verts illustrent la période théorique où la culture est semée, et les carrés bruns la période où la culture est récoltée. . . . .	36
3.2	<b>Résumé des différents scénarios testés, avec le nombre de primitives sur la période d'avril à novembre.</b> . . . . .	40
3.3	<b>Nombre de pixels pour l'apprentissage et la validation du modèle, pour chaque classe et pour chaque année</b> . . . . .	41
3.4	<b>Ressources informatiques pour les étapes d'apprentissage et de classification, pour chaque scénario.</b> Le temps CPU correspond au temps de calcul sur un processeur nécessaire pour produire le résultat. La RAM exprimée en Gigabites correspond à la quantité de mémoire vive nécessaire pour obtenir le résultat. . . . .	42
3.5	<b>Confiance moyenne pour les années 2017 et 2018, avec les écarts types associés, exprimés en %</b> . . . . .	45
3.6	<b>Résumé des surfaces par classe pour les scénarios 4, 5 et le RPG pour les années 2017 et 2018.</b> Elles sont exprimées en hectares. Le terme diff. fait référence à la différence entre la superficie du scénario et celle du RPG. Il est exprimé en pourcentage . . . . .	46
3.7	<b>Utilisation de la ressource informatique en fonction des différents scénarios cumulés et non cumulés en 2017.</b> Le temps CPU correspond au temps de calcul sur un processeur nécessaire pour produire le résultat. La RAM exprimée en Gigabites correspond à la quantité de mémoire vive nécessaire pour obtenir le résultat. . . . .	49
3.8	<b>Résumé des surfaces par classe pour les scénarios 4, 5 et le RPG pour les années 2017 . Elles sont exprimées en hectares.</b> . . . . .	55
4.1	<b>Liste des paramètres du modèle SAMIR, avec leurs annotations, leurs définitions et la source de la donnée</b> , les données en gras correspondent à celles utilisées pour la spatialisation	69
4.2	<b>Initialisation des paramètres du modèle selon les cas d'étude.</b> . . . . .	69
4.3	<b>Nombre d'irrigation simulées vs Irrigation observées sur la parcelle expérimentale en fonction de la profondeur d'enracinement maximale (maxZr)</b> . . . . .	78
4.4	<b>Valeurs des métriques d'évaluation issues de simulations avec différentes valeurs de maxZr, conseillées par le FAO-56.</b> . . . . .	83
4.5	<b>Répartition des cultures irriguées sur chaque ASA étudié.</b> La surface de chaque culture est exprimée en ha et correspond à l'abréviation Surf. La proportion de chaque culture pour chaque ASA correspond au terme Prop. et est exprimée en %. . . . .	85

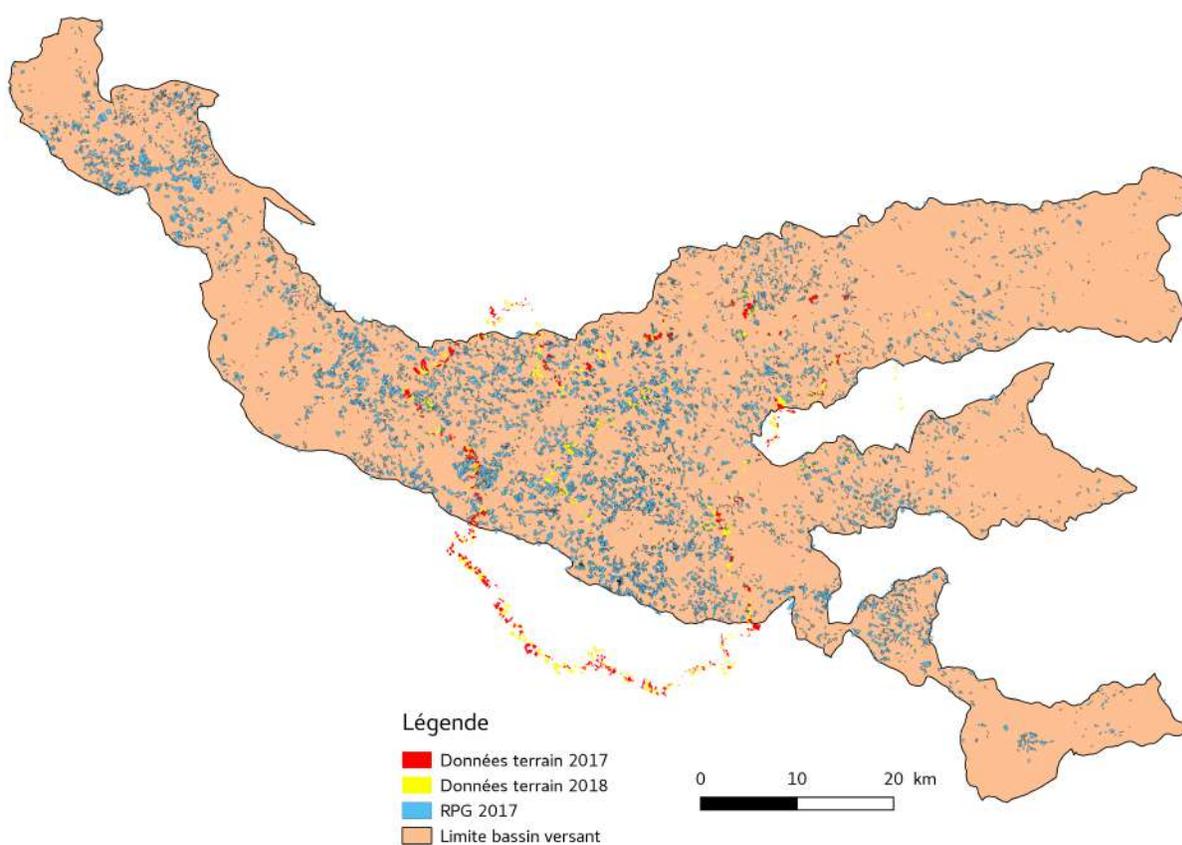
# Annexes

**Annexe 1 : Localisation des parcelles de références pour la classification sur chaque bassin versant**

[Annexe : 1]Annexe : 1

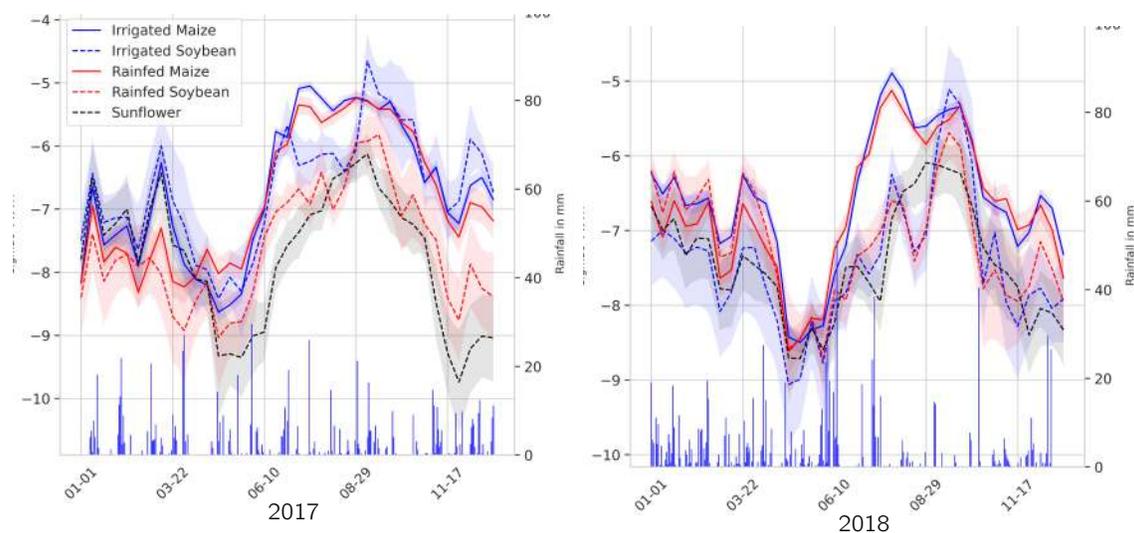


**Localisation des parcelles échantillonnées lors des tournées terrain de la Chambre d'agriculture des Hautes-Pyrénées sur le bassin versant Adour Amont.** Les parcelles en bleues correspondent à celle de RPG de l'année 2017. Les autres parcelles en rouges et jaunes illustrent les parcelles échantillonnées en 2017 et 2018



**Localisation des parcelles échantillonnées lors des tournées terrain de la Chambre d'agriculture du Tarn sur le bassin versant Tarn Aval.** Les parcelles en bleues correspondent à celle de RPG de l'année 2017. Les autres parcelles en rouges et jaunes illustrent les parcelles échantillonnées en 2017 et 2018

## Annexe 2 : Dynamique temporelle de VV/VH en 2017 et 2018



**Dynamique du ratio VV/VH pour les cultures de maïs, de soja et de tournesol.** Les courbes en trait plein représentent le maïs, la ligne pointillée représente le soja, avec le bleu irrigué et le rouge pluvial pour les deux cultures. La courbe noire représente le tournesol. L'enveloppe autour des courbes correspond à l'intervalle de confiance à 95 %

### Annexe 3 : Dynamique temporelle des indices cumulés (NDVI, NDWI, VV, et VH) pour toutes les cultures en 2018

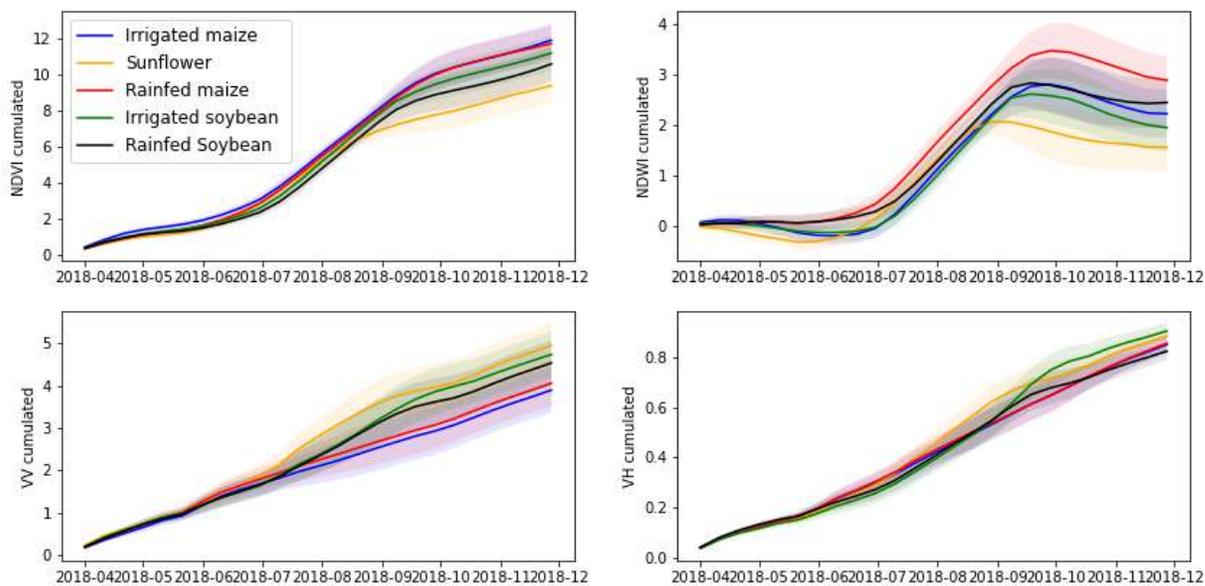
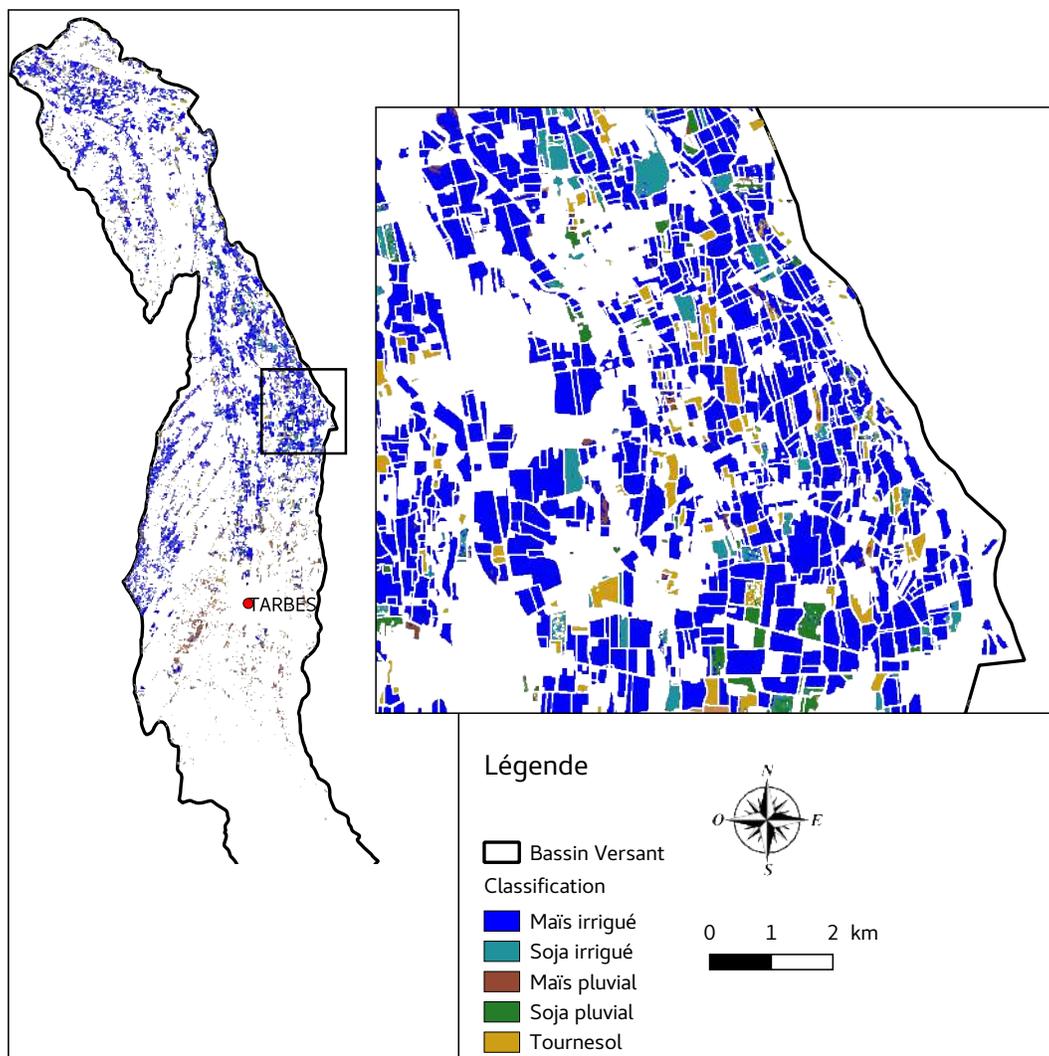
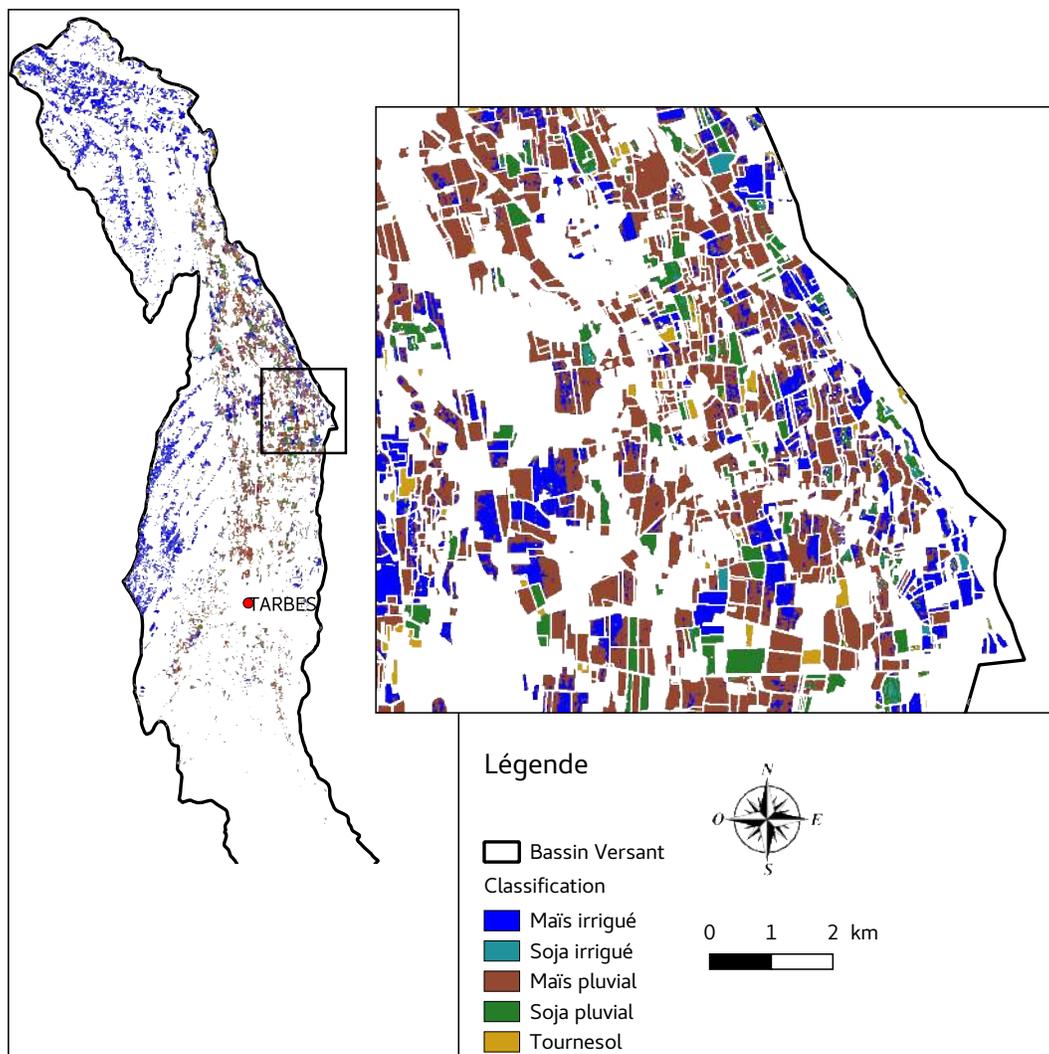


Figure 5.2 – **Dynamique temporelle des indices cumulés (NDVI, NDWI, VV, et VH) pour toutes les cultures en 2018.** La courbe bleue illustre la dynamique du maïs irrigué, celle en jaune du tournesol. Le maïs pluvial est représenté par une courbe rouge, le soja irrigué par une courbe verte et le soja pluvial par courbe noire

## Annexe 4 : Cartographie des surfaces irriguées sur le bassin Adour Amont en 2017 et 2018



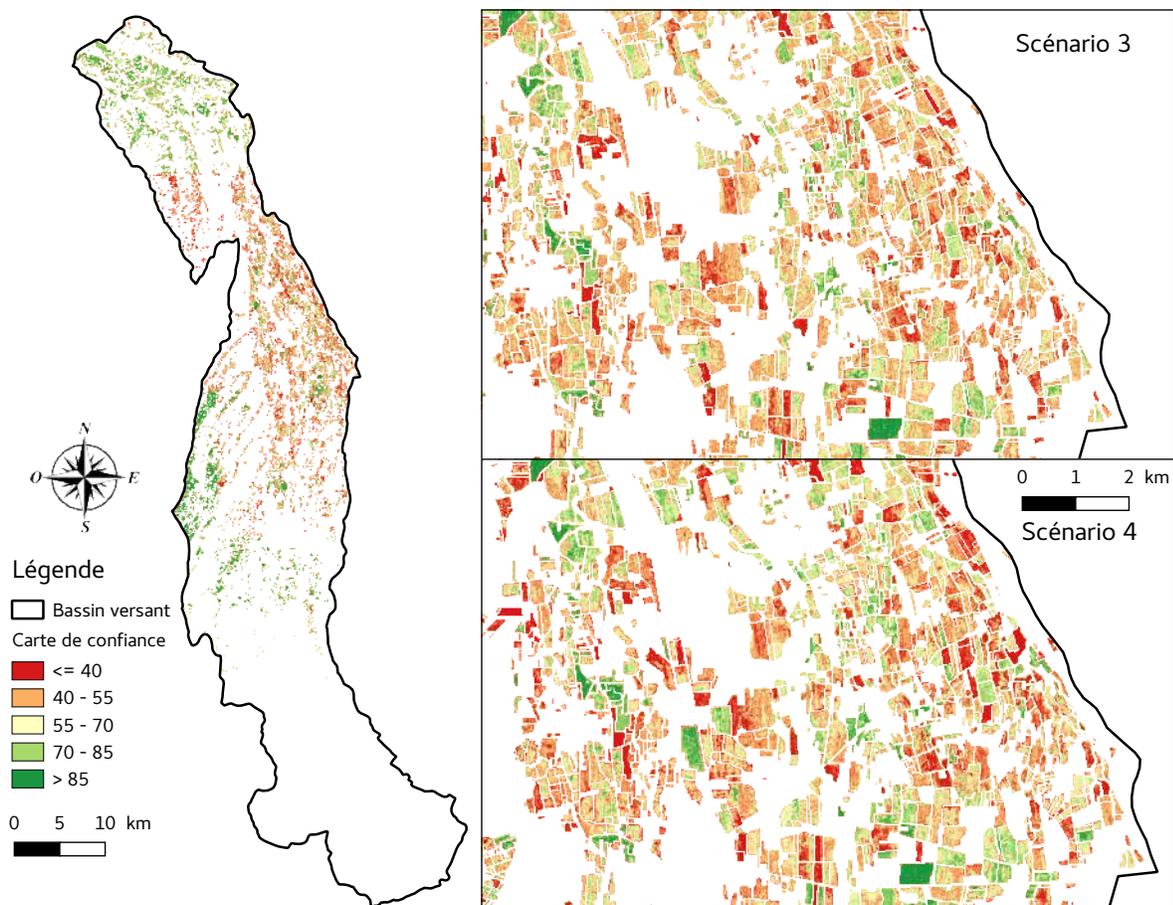
Carte des surfaces irriguées sur le bassin versant Adour amont en 2017, réalisée à partir de la méthodologie des cumuls mensuels d'indices



**Carte des surfaces irriguées sur le bassin versant Adour amont en 2018, réalisée à partir de la méthodologie des cumuls mensuels d'indices**

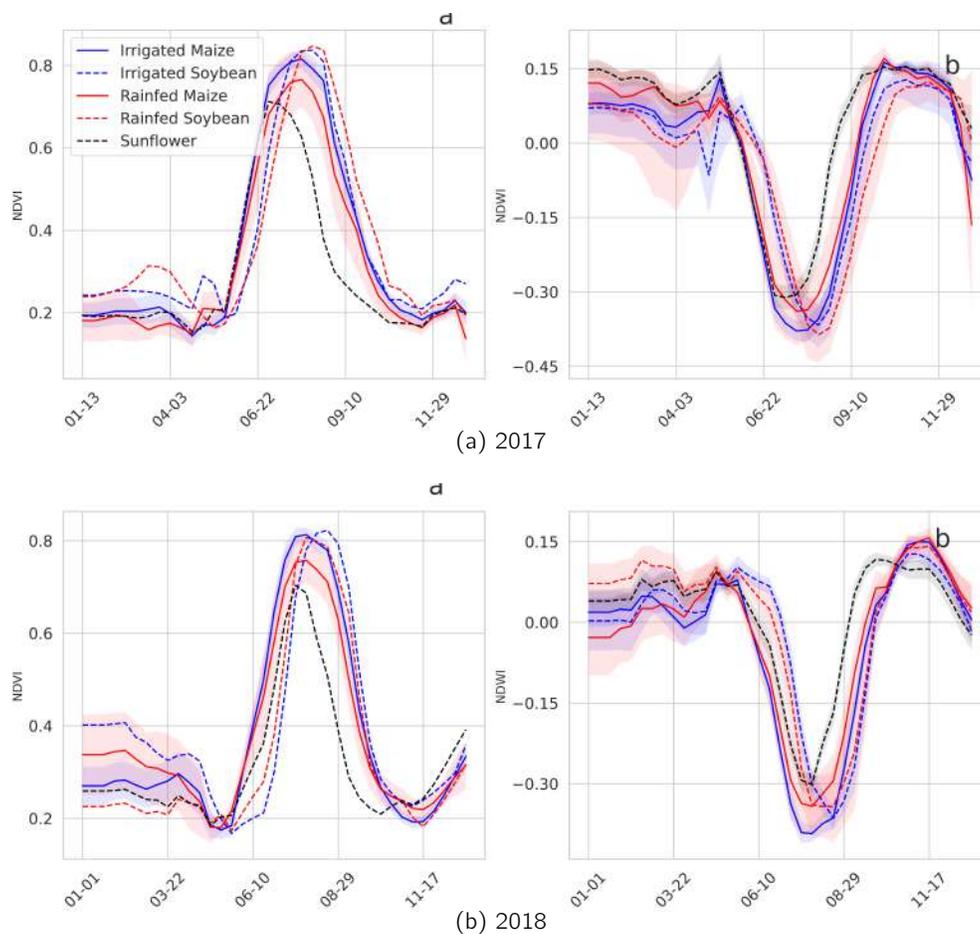
Cette annexe présente la carte des surface irriguées en 2017 et 2018 sur le bassin versant de l'Adour Amont. Cette carte a été obtenue avec la méthodologies des cumuls mensuels d'indices de végétations, des polarisation SAR et des précipitations. Nous constatons une nette diminution du nombre de parcelles de maïs irrigués entre 2017 et 2018.

## Annexe 5 : Carte de confiance pour 2018, sur la bassin versant Adour Amont

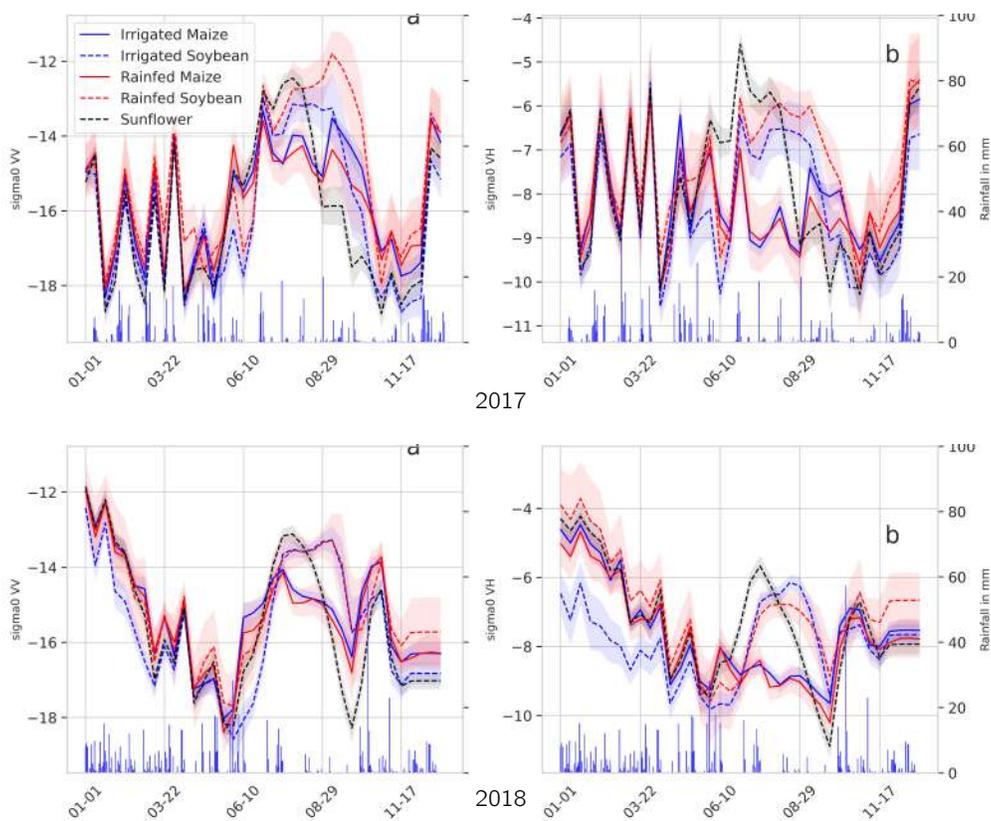


Carte de confiance sur l'Adour Amont en 2018

## Annexe 6 : Dynamique temporelle des indices de végétation et des polarisations SAR sur le bassin Versant Tarn Aval

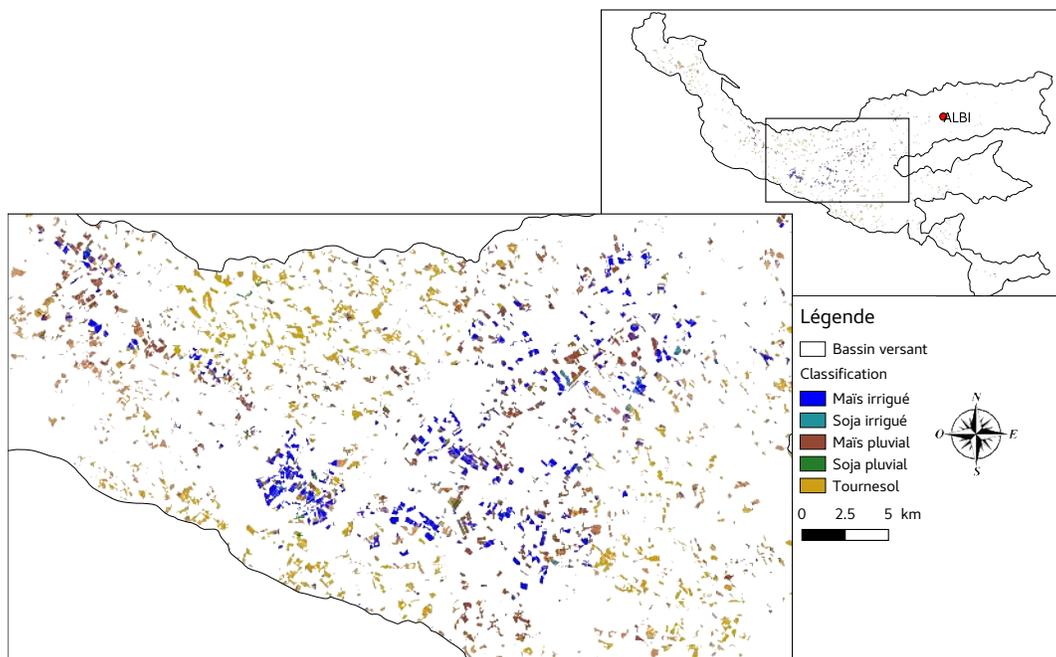


**Dynamique des indices optiques (NDVI [a et c] et NDWI [b et d]) pour les cultures de maïs, de soja et de tournesol.** Les courbes en trait plein représentent le maïs, la ligne pointillée représente le soja, avec le bleu irrigué et le rouge pluvial pour les deux cultures. La courbe noire représente le tournesol. L'enveloppe autour des courbes correspond à l'intervalle de confiance à 95 %.

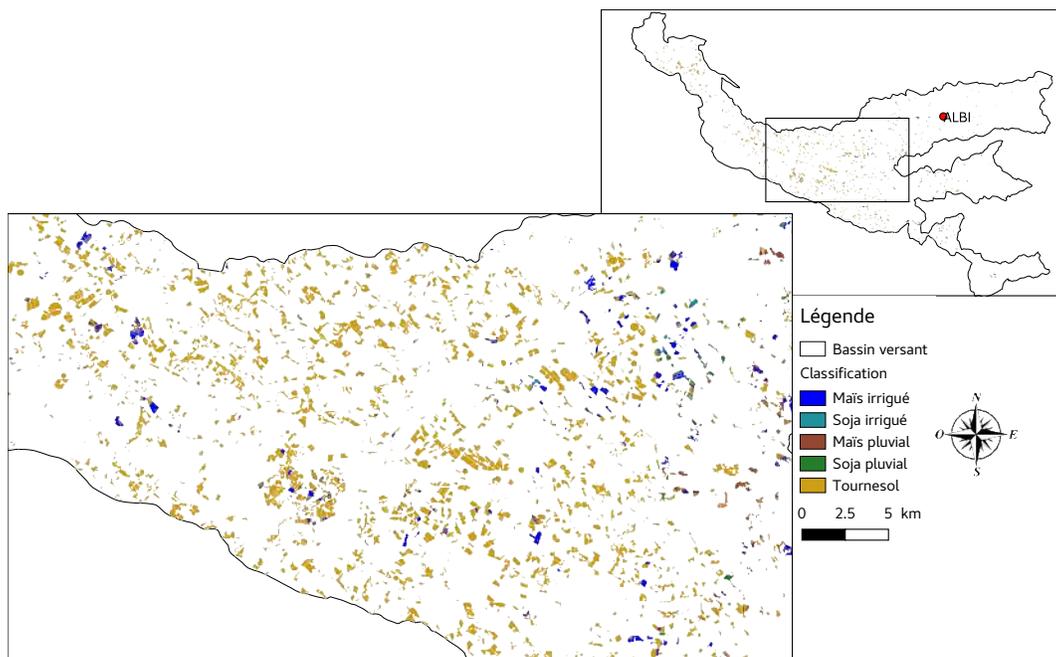


**Dynamique des polarisations SAR (VV [a et c] et VH [c et d]) pour les cultures de maïs, de soja et de tournesol**, Les courbes en trait plein représentent le maïs, la ligne pointillée représente le soja, avec le bleu irrigué et le rouge pluvial pour les deux cultures. La courbe noire représente le tournesol. L'enveloppe autour des courbes correspond à l'intervalle de confiance à 95 %.

## Annexe 7 : Cartographie des surfaces irriguées sur le bassin Tarn Aval en 2017 et 2018

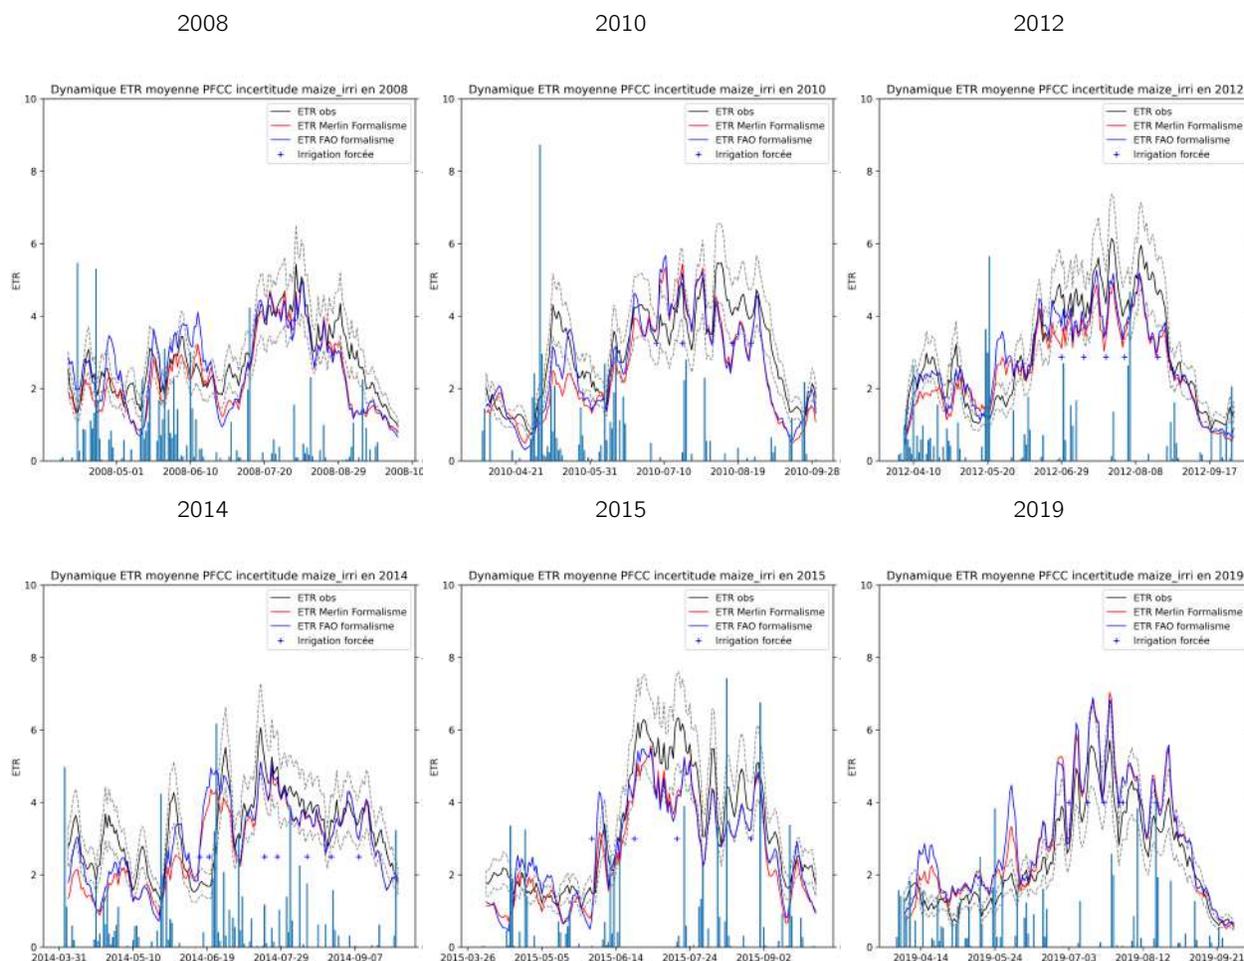


Carte des surfaces irriguées sur le bassin versant Tarn Aval en 2017, réalisée à partir de la méthodologie des cumuls mensuels d'indices



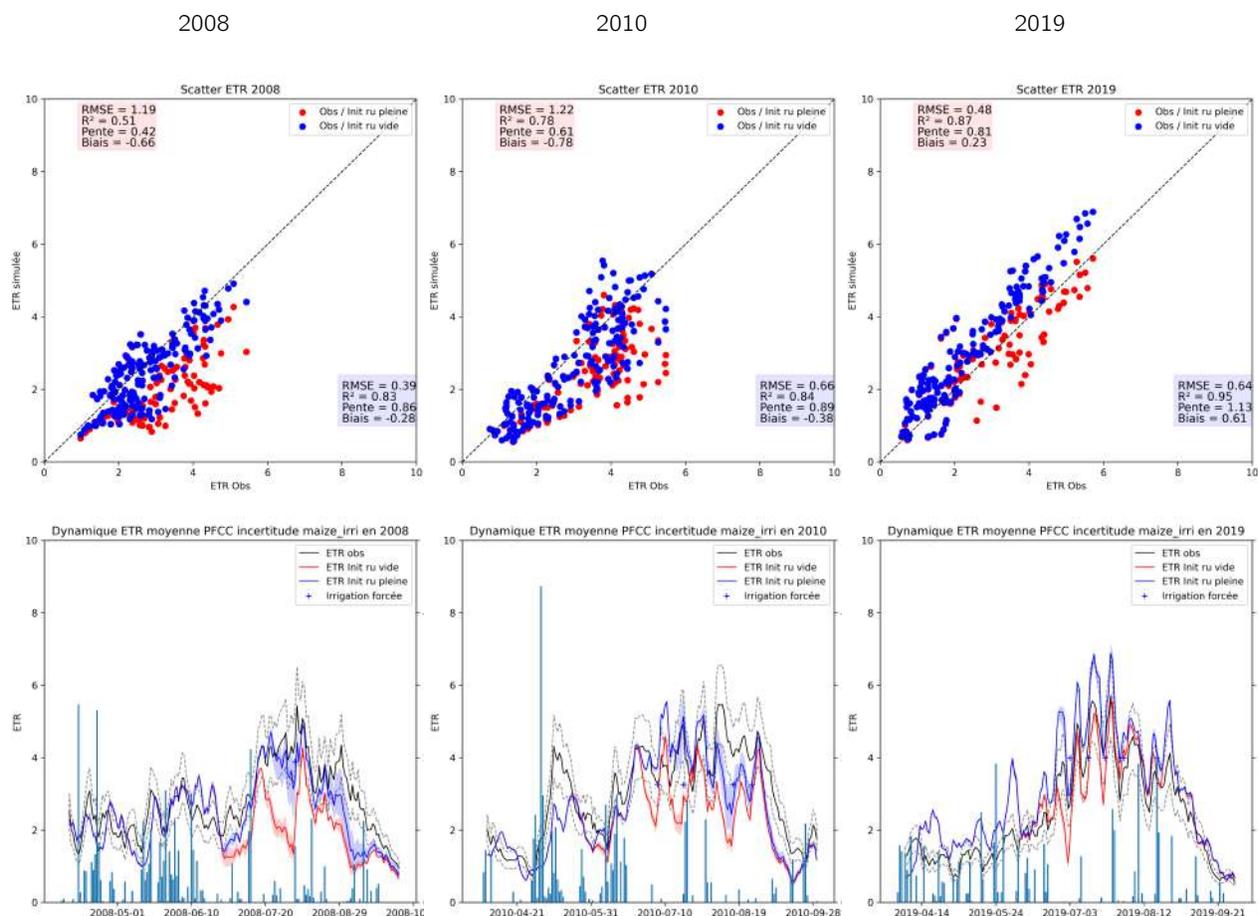
Carte des surfaces irriguées sur le bassin versant Tarn Aval en 2018, réalisée à partir de la méthodologie des cumuls mensuels d'indices

## Annexe 8 : Dynamique des ETR en fonction des deux formalismes (FAO-56 et Merlin)



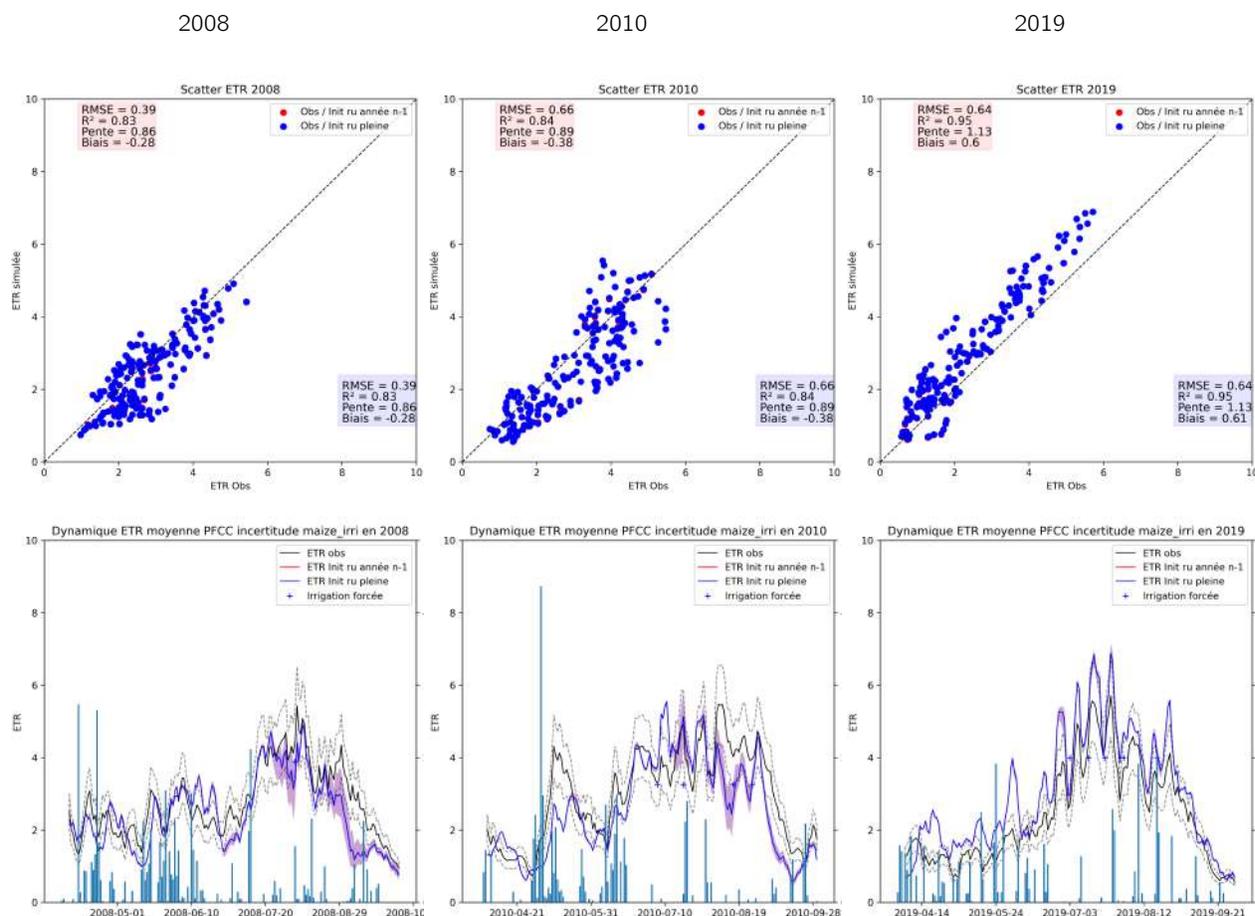
**Dynamique des ETR observés et modélisés, en fonction du formalisme utilisé.** La courbe rouge correspond aux résultats issus du formalisme de Merlin. La courbe bleue illustre les résultats issus du formalisme de la FAO-56. Quant à la courbe noire elle représente la dynamique journalière de l'ETR observé par la station. Les intervalles de confiance sont illustrés par les courbes en pointillées pour l'ETR observé

## Annexe 9 : Impact de l'initialisation de la réserve utile sur l'évapotranspiration, entre une RU vide et pleine en début de simulation



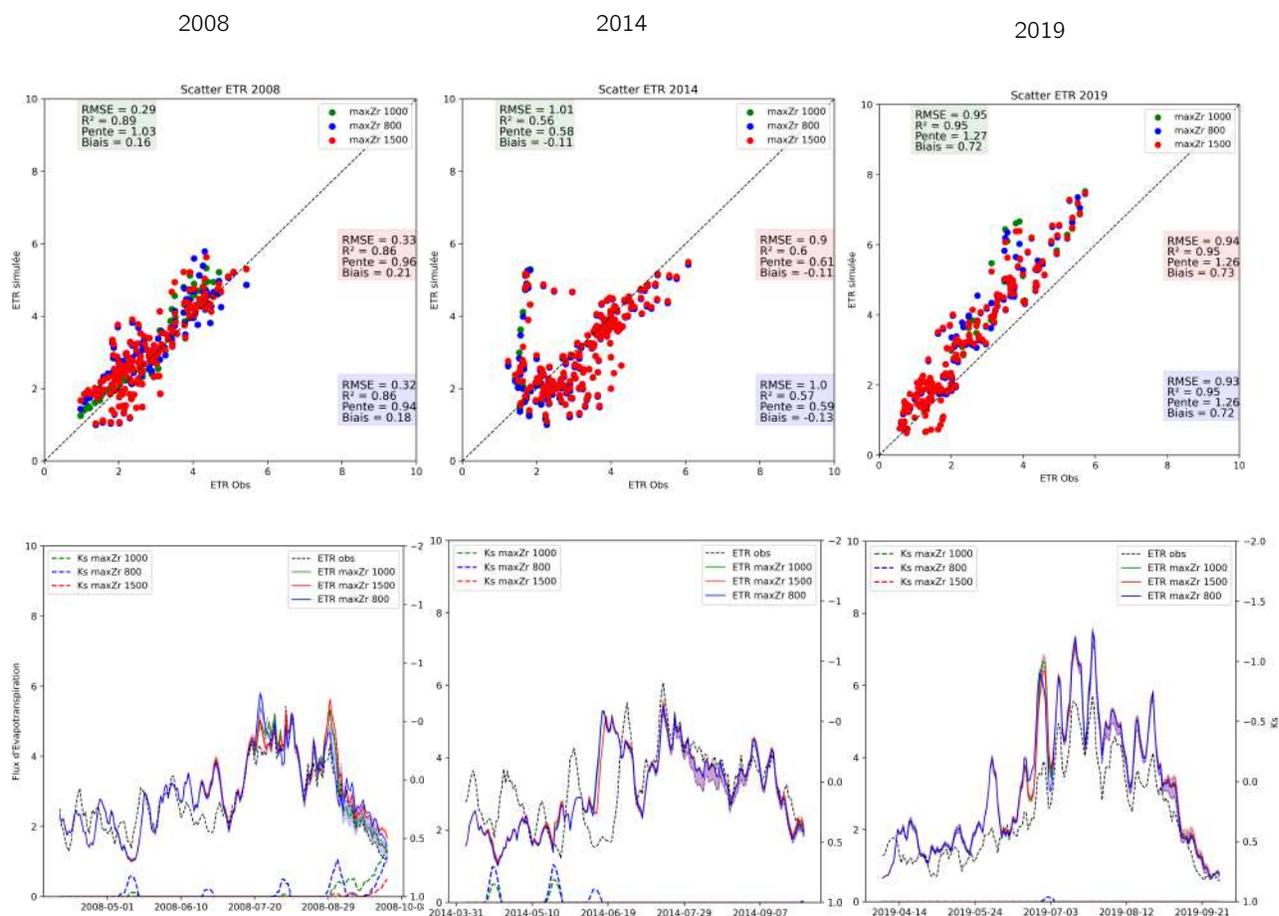
**Comparaison des ETR observés et modélisés, en fonction de l'initialisation de la réserve utile en début de simulation.** La courbe et les points rouges correspondent aux résultats issus de l'initialisation de la RU vide (RU = 0%). Les points et la courbe bleus illustrent les résultats issus de la simulation avec la RU pleine (RU = 100%). Quant à la courbe noire elle représente la dynamique journalière de l'ETR observé par la station. Les intervalles de confiance sont illustrés par les courbes en pointillées pour l'ETR observé et en bleu et rouge en fonction de l'initialisation de la RU.

## Annexe 10 : Impact de l'initialisation de la réserve utile sur l'évapotranspiration, Comparaison des ETR observés et modélisé



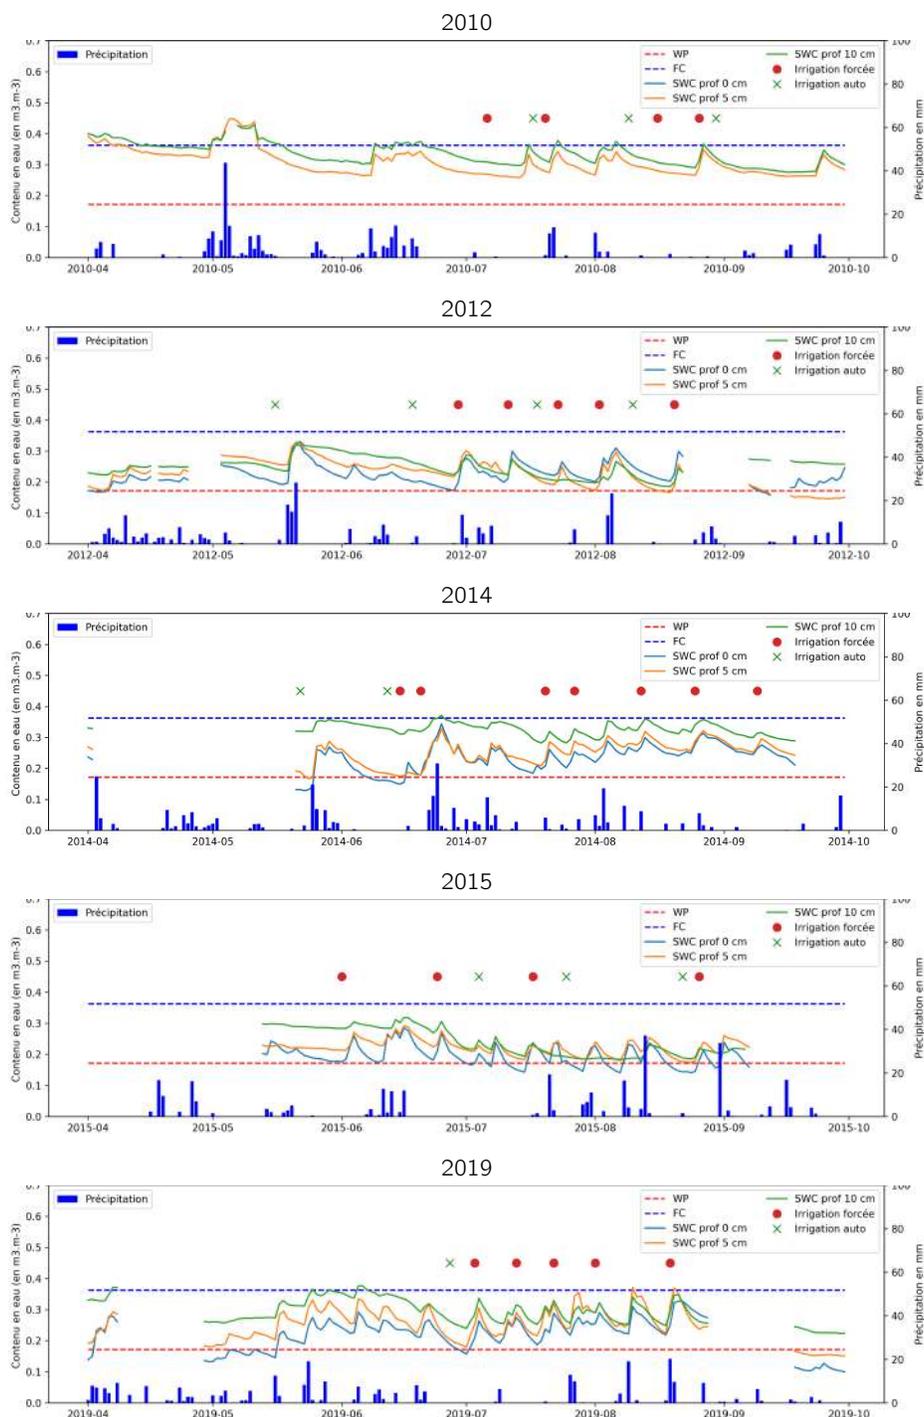
**Comparaison des ETR observés et modélisés, en fonction de l'initialisation de la réserve utile en début de simulation.** La courbe et les points rouges correspondent aux résultats issus de l'initialisation de la RU vide (RU = 0%). Les points et la courbe bleus illustrent les résultats issus de la simulation avec la RU pleine (RU = 100%). Quant à la courbe noire elle représente la dynamique journalière de l'ETR observé par la station. Les intervalles de confiance sont illustrés par les courbes en pointillées pour l'ETR observé et en bleu et rouge en fonction de l'initialisation de la RU.

## Annexe 11 : Variation de la profondeur d'enracinement, impact sur les ETR modélisés



**Comparaison des ETR observées et modélisées, en fonction de maxZr sur la parcelle de Lamothe**, Les différents couleurs des points représentent la comparaison des ETR journaliers (modélisées vs observées) en fonction de la profondeur d'enracinement maximale, avec en bleu maxZr = 800 mm, en vert 1000 mm et en rouge 1500 mm. Les courbes illustrent les dynamiques journalières des ETR en fonction de maxZr, et celles en pointillées correspond aux dynamiques de Ks. Les intervalles de confiance sont illustrés par les courbes en pointillées bleue, rouge et verte en fonction de la valeur de maxZr

## Annexe 12 : Dynamique des sondes d'humidité du sol en surface sur la parcelle expérimentale



**Dynamique de l'humidité du sol de la parcelle de Lamothe**, Les courbes bleu, jaune et vert, illustre la dynamique des humidités du sol à différentes profondeurs. La courbe rouge correspond au coefficient de stress hydrique (Ks), Les croix et les rondes illustrent les événements d'irrigation (observés en rouge et simulés en vert)



Article

# Detection of Irrigated and Rainfed Crops in Temperate Areas Using Sentinel-1 and Sentinel-2 Time Series

Yann Pageot <sup>1,\*</sup>, Frédéric Baup <sup>1</sup>, Jordi Inglada <sup>1</sup>, Nicolas Baghdadi <sup>2</sup> and Valérie Demarez <sup>1</sup>

<sup>1</sup> Centre d'Études Spatiales de la Biosphère, Université de Toulouse, CNES/CNRS/IRD/INRA/UPS, 18 av. Edouard Belin, bpi 2801, CEDEX 9 31401 Toulouse, France; frederic.baup@iut-tlse3.fr (F.B.); jordi.inglada@cesbio.eu (J.I.); valerie.demarez@cesbio.cnes.fr (V.D.)

<sup>2</sup> TETIS, INRAE, University of Montpellier, 500 rue François Breton, CEDEX 5 34093 Montpellier, France; nicolas.baghdadi@teledetection.fr

\* Correspondence: yann.pageot@cesbio.cnes.fr

Received: 10 August 2020; Accepted: 15 September 2020; Published: 17 September 2020



**Abstract:** The detection of irrigated areas by means of remote sensing is essential to improve agricultural water resource management. Currently, data from the Sentinel constellation offer new possibilities for mapping irrigated areas at the plot scale. Until now, few studies have used Sentinel-1 (S1) and Sentinel-2 (S2) data to provide approaches for mapping irrigated plots in temperate areas. This study proposes a method for detecting irrigated and rainfed plots in a temperate area (southwestern France) jointly using optical (Sentinel-2), radar (Sentinel-1) and meteorological (SAFRAN) time series, through a classification algorithm. Monthly cumulative indices calculated from these satellite data were used in a Random Forest classifier. Two data years have been used, with different meteorological characteristics, allowing the performance of the method to be analysed under different climatic conditions. The combined use of the whole cumulative data (radar, optical and weather) improves the irrigated crop classifications (Overall Accuracy (OA)  $\approx 0.7$ ) compared to the classifications obtained using each data separately (OA  $< 0.5$ ). The use of monthly cumulative rainfall allows a significant improvement of the Fscore of irrigated and rainfed classes. Our study also reveals that the use of cumulative monthly indices leads to performances similar to those of the use of 10-day images while considerably reducing computational resources.

**Keywords:** irrigation; summer crops; random forest; high spatial and temporal resolution; temperate areas

## 1. Introduction

Human activities have an impact on the different components of the hydrosphere, and 80% of the world's population is now facing water shortages that will worsen with global warming [1]. Faced with this emergency situation, it is necessary to develop adaptation strategies to allow access to water resources for the entire population and to maintain agricultural activity. One of the adaptation strategies that has been favoured is irrigation. FAO estimates that 80% of the food needs in 2025 will be covered by irrigated agriculture [2] and more than 324 million hectares are equipped for irrigation in the world [3]. However, the use of irrigation has led to conflicts on water uses that are likely to worsen in a context of climate change. Rational and collective management of water resources has therefore become crucial. To achieve this objective, explicit information on agricultural practices and on the amount of water needed for crops over large areas is needed [4]. In this context, remote sensing observation could play an essential role. Many studies have proposed methodologies based on remote sensing images to derive useful indicators for water management [4–6]. Many of them have used

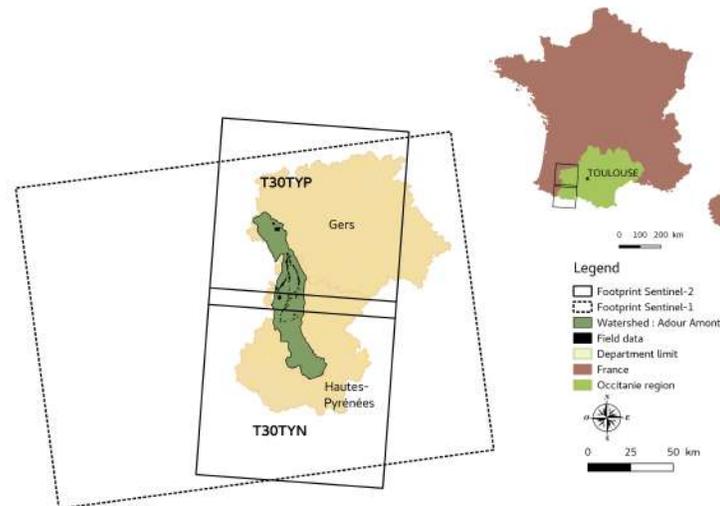
multispectral and multi-temporal remote sensing images to map irrigated areas [7–14], demonstrating the high potential of remote sensing data. However, most of these studies are conducted in semi-arid areas [15–23]. Very little research is carried out in temperate areas, which also suffer from water scarcity. In France, for example, each year, about twenty departments (Nomenclature of Territorial Units for Statistics level 3) apply water restrictions. This number increases in the driest years: 73 departments (among 101) in the summer of 2019. In temperate areas, the detection of irrigated plots is difficult because of the smaller differences in observed phenology between irrigated and rainfed crops compared to what is observed in semi-arid zones [24,25]. This smaller difference is related to local agricultural practices and pedoclimatic conditions.

The launch of the Sentinel constellation gives a new opportunity for the mapping of land cover and agricultural practices [26,27]. Numerous studies have shown that using temporally dense optical time series can improve crop mapping over different climates [28–32]. Vogels et al. [33] used a new approach to map irrigated areas in the Horn of Africa: a Sentinel 2 time series. However, as optical imagery is affected by cloud cover, the performance of the crop mapping with such data can be reduced in some cases, particularly for temperate or tropical areas [33]. Other recent studies [34–39] have shown that the joint use of optical and radar data improves the robustness of the mapping methods [21,35,37]. Nevertheless, all the studies mentioned above deal with the mapping of irrigated areas in arid or semi-arid climatic areas. There are few works on mapping irrigated crops in temperate areas with high spatial and temporal resolution. Demarez et al. [36] demonstrated that combining high spatial and temporal optical imagery (Landsat-8) and SAR (Synthetic Aperture Radar) imagery (Sentinel-1) allows to improve the detection of irrigated areas in the southwest of France. However, in this study the main limiting factor was the temporal resolution of the Landsat-8 images.

In this work, we propose a new methodology for distinguishing irrigated and rainfed crops at plot scale in temperate areas using the joint use of optical (Sentinel-2), radar (Sentinel-1) and meteorological (SAFRAN) data. The novelty comes from the combined use of vegetation, polarisation and meteorological indices. The study area is located in southwest France, and the summer crops to be classified are maize (both irrigated and rainfed), soybean (both irrigated and rainfed) and sunflower (rainfed). As only part of the summer crops was irrigated in the study area, one challenging point was to distinguish between irrigated and rainfed plots of the same species. In order to make this discrimination, we relied on the phenological development of the vegetation cover as an explanatory variable. Different scenarios were used to evaluate the performance of classification models as a function of the various types and number of features. Different scenarios were evaluated using ground truth data collected in 2017 and 2018. These two years were characterised by contrasted meteorological conditions, which allowed to analyse the performance of the method under various climatic conditions.

## 2. Study Site and Dataset

The study site is a watershed (Adour Amont) located in the southwestern France, west of Toulouse (city). It covers 1500 km<sup>2</sup>, as shown in Figure 1. The climate is temperate with continental and oceanic influences. It is characterised by a hot summer (mean  $T^{\circ} = 22^{\circ}\text{C}$ ) and a wet spring (mean rainfall = 108 mm) [40]. In this region, the minimum rainfall occurs between July and October, which corresponds to the maximum development of summer crops, as shown in Table 1, making irrigation mandatory. Maize, soybean and sunflower represent, respectively, 82%, 9% and 8% of the summer crops, i.e., 36% of the whole cultivated crops, according to the agricultural Land Parcel Information System “Registre Parcellaire Graphique” (RPG) provided by the French Services and Payments Agency [41]. The RPG contains information on crop types but no information on agricultural practices. Only maize and soybean are irrigated and the irrigation water needs represent 30 million m<sup>3</sup> over the season [42]. The two years studied are characterised by different weather conditions over the cropping period. The year 2017 can be defined as a dry year, as it has a total rainfall of 424 mm compared to 573 mm in 2018.



**Figure 1.** Location of the study area with footprints of the Sentinel-1, Sentinel-2 images and field data.

**Table 1.** Theoretical cropping calendar of the studied summer crops: the green squares illustrate the theoretical period when the crop is sown, and the brown squares illustrate the period when the crop is harvested.

	Growing Year											
	Jan.	Feb.	Mar.	April	May	June	July	Aug.	Sept.	Oct.	Nov.	Dec.
Maize												
Soybean												
Sunflower												

### 2.1. The Reference Dataset

The reference dataset was established from field campaigns carried out at two stages of the growing season: after sowing (May) and at flowering (July). The identification of the irrigation practices was based on the presence of irrigation equipment or through declarative information carried out by the farmer. The reference dataset consisted of 832 plots in 2017 (557 irrigated and 275 rainfed) and 942 plots in 2018 (680 irrigated and 262 rainfed) as shown the Table 2. Within the dataset, irrigated maize is the most represented crop with 60% of the plots sampled in 2017 and 48% in 2018. Irrigated soybean is the least represented crop in the dataset with 3% in 2017 and 5.6% of the plots sampled in 2018. This low sampling of irrigated and rainfed soybean is explained by the low representativeness of this crop in the territory (<10%), contrary to maize which represents 82% of the agricultural plots cultivated in summer crops in 2017 and 84% in 2018. Maize and soybean areas are increasing, while sunflower areas are decreasing between the two years, according to the RPG. The plots are located on gentle slopes (less than 5%) and on alluvial soil [43]. The dataset represented 21% of the total area of the summer crops in the territory.

**Table 2.** Distribution of reference dataset by class for 2017 and 2018.

Class Label	Number of Plots		Total Area Sampled (ha)		Distribution (%)		RPG (%)	
	2017	2018	2017	2018	2017	2018	2017	2018
Maize irrigated	526	639	943	727	60	48.1	82.8	84
Maize rainfed	198	175	302	500	19.2	33.1		
Soybean irrigated	31	41	54	85	3.4	5.6	8.2	9.6
Soybean rainfed	27	38	77	151	4.9	10		
Sunflower	50	49	120	40	7.6	2.7	8.6	5.5

## 2.2. Sentinel-2

The Sentinel-2 (S2A-S2B) images were processed to level 2A with the MAJA processing chain [44,45], allowing to obtain surface reflectances at top of canopy (TOC). This process presented in Hagolle et al. and Baetens et al. [44,45], allows the detection of clouds and their shadows, the correction of the atmospheric effects of the images from an estimation of the aerosol optical thickness (AOT) and water vapour. This process can be applied to time series of images. 100 images were processed in 2017 and 124 in 2018, corresponding to the tiles T30TYN and T30TYP, on Theia website [<https://theia.cnes.fr/>]. The average number of cloudy pixels was 31% in 2017 and 37% in 2018 over the whole time series, with cloudiness reaching over 85% in June (spring). The obtained images were temporally aggregated to regular 10-day interval composite datasets using the gapfilling module Orfeo Toolbox 6.7 (OTB) [46]. This temporal resampling relies on a distance-weighted linear interpolation of the clear acquisition dates of the optical satellites taking into account cloud and cloud shadow masks, which is necessary to study very large areas, as it limits the impact of satellite tracks, clouds and their shadows [28,47].

## 2.3. Sentinel-1

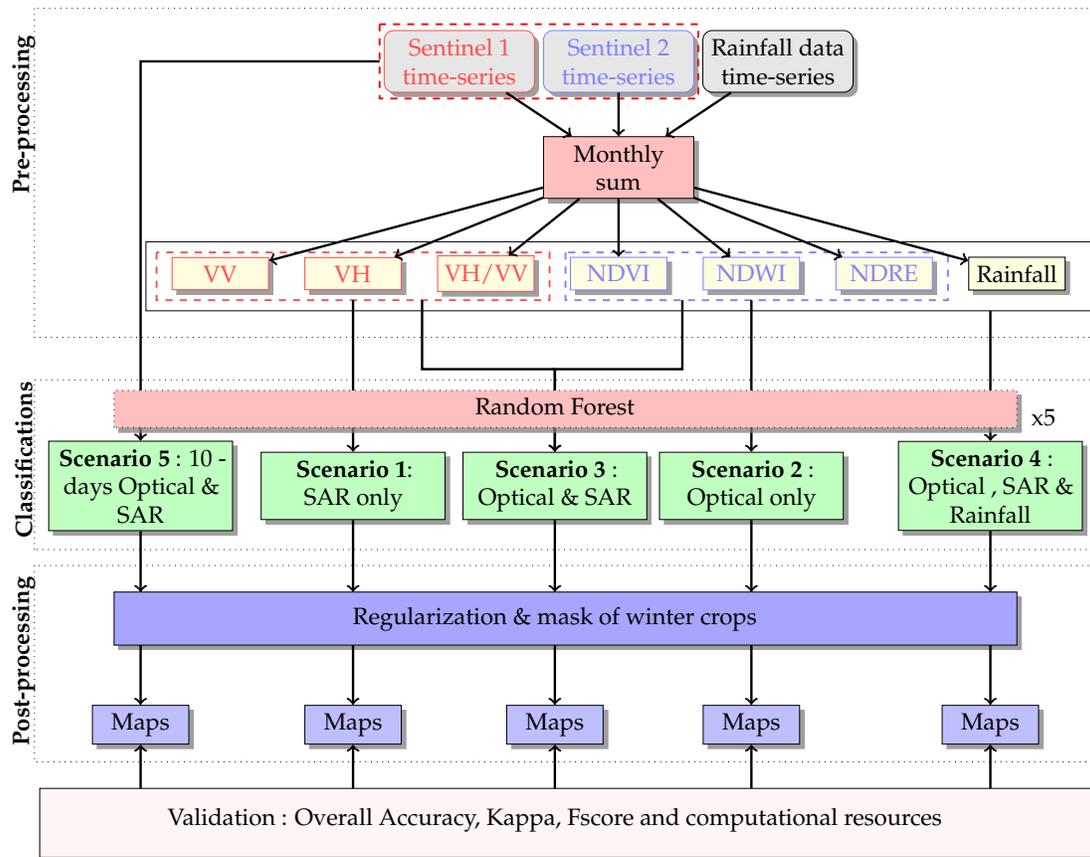
The Sentinel-1 images came from the C-SAR instrument onboard two Sentinel 1 satellites (S1A-S1B) (Interferometric Wide Swath mode, IWS-GRD [26]). This mode provides dual-polarisation (VV and VH) imagery, at resolution of 20 m, with a swath of 250 km. The images were radiometrically (Multilooking filter  $2 \times 2$ ) and geometrically corrected using the OTB software [46]. Only Sentinel-1 images acquired in ascending mode (acquisition time: 6.00 pm) and between April and November were used (i.e., one image every 6 days, i.e., 79 images in 2017 and 100 in 2018). The ascending mode (orbit  $n^{\circ}30$ ) was used in the study, to limit the impact of morning dew and freezing dew, which can lead to artefacts in the SAR signal. Like Sentinel-2 images, the SAR images were orthorectified on the S2 grid and with the same pixel size. In addition to the orthorectification process, the SAR images were linearly interpolated every 10 days to maintain the same temporality in the satellite data between Sentinel-1 and Sentinel-2.

## 2.4. Meteorological Data

Rainfall data from the SAFRAN database [40] were used in the classification process. It is defined in mm/day. SAFRAN is a system for atmospheric analysis of surface meteorological variables based on the use of homogeneous climatic zones and capable of taking into account altitudinal variations. These data are spatially interpolated to cover all of mainland France with a regular grid of  $(8 \times 8)$  km.

## 3. Methods

Figure 2 illustrates the methodology used. It includes 4 main steps: (1) preprocessing of the initial images, which enables the calculation of cumulative monthly indices from time series; (2) pixel classification based on cumulative monthly indices; (3) postprocessing of the classifications, with the aim of removing of isolated pixels; and (4) validation of the resulting maps.



**Figure 2.** The workflow of the methodology used in this study. The grey squares represent the initial data. The yellow squares are the stacks of monthly cumulative indices after processing by the algorithm, represented by a red square. The green squares correspond to the different scenarios tested. The blue squares represent different maps from the classifiers, i.e., classifications and confidence maps.

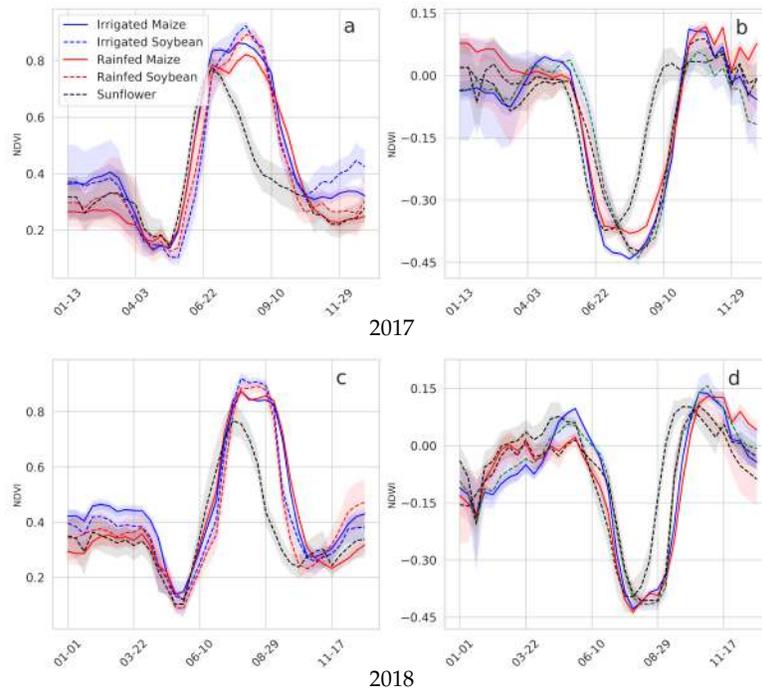
### 3.1. Feature Computation

#### 3.1.1. Optical Features

As shown on Table 3, the optical features involved into the classification process are the Normalized Difference Vegetation Index (NDVI), the Normalized Difference Red-Edge (NDRE) and the Normalized Difference Water Index (NDWI). These indices were selected as they are sensitive to various characteristics of the plants: the fraction of green vegetation cover [48,49], the foliar pigment [50,51] and the plant water content [52], respectively. Figure 3 illustrates the dynamics of vegetation cover growth between irrigated and rainfed crops. A significant difference is observed at full growth ( $NDVI > 0.8$  and  $NDWI < -0.40$ ). This difference is stronger in 2017. It decreases when entering the senescent phase. The growing cycle is quite synchronous for all crops, as shown in the Table 1. For sunflowers, the growth cycle is different than for other crops, with lower growth peaks.

**Table 3.** Optical and radar features.

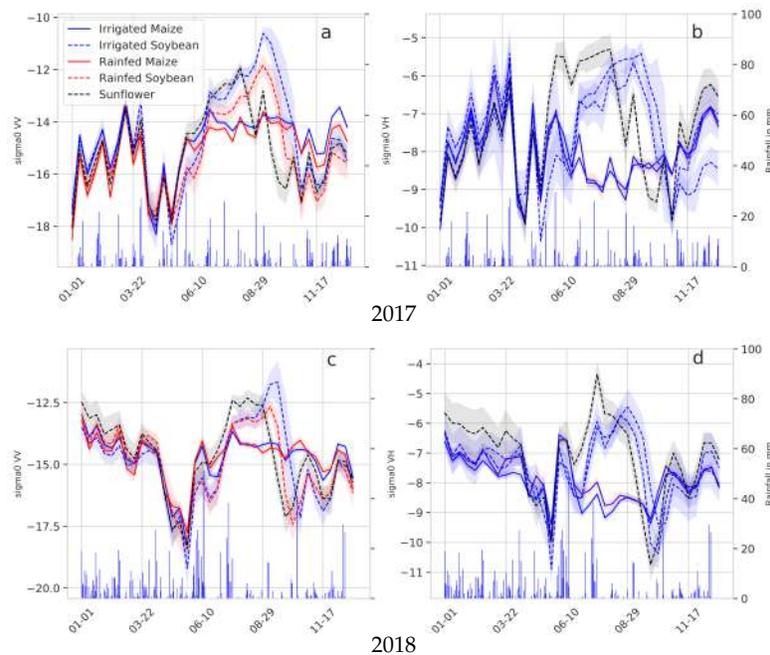
Name	Description	Equation
NDVI	Normalized Difference Vegetation Index	$(\text{NIR} - \text{Red})/(\text{NIR} + \text{Red})$
NDRE	Normalized Difference Red-Edge	$(\text{NIR} - \text{Red-Edge})/(\text{NIR} + \text{Red-Edge})$
NDWI	Normalized Difference Water Index	$(\text{NIR} - \text{SWIR})/(\text{NIR} + \text{SWIR})$
VV	Vertical—Vertical Polarisation	-
VH	Vertical—Horizontal Polarisation	-
VH/VV	Ratio	-



**Figure 3.** Dynamics of optical indices (Normalized Difference Vegetation Index (NDVI) (a,c) and Normalized Difference Water Index (NDWI) (b,d)) for maize, soybean and sunflower crops. The solid line curves represent maize, the dotted line represents soybean, with irrigated blue and rainfed red for both crops. The black curve represents sunflower. The envelope around the curves corresponds to the 95% confidence interval.

### 3.1.2. Radar Features

VV and VH polarisations were used into the classification. They are, respectively, sensitive to soil moisture [53–55] and to the volume scattering of vegetation [53,56]. As SAR backscatter time profiles in both polarisations are noisy by environmental factors, we used the VV/VH ratio which partially compensates these effects. The dynamics of SAR polarisations differ between rainfed and irrigated crops, as shown in Figure 4. This difference is more marked throughout the season than for optical indices. Moreover, there is a clear difference in the amplitude of the SAR signal between the two types of crops (soybean and maize) at full growth.



**Figure 4.** Dynamics of SAR polarisations (VV (a,c) and VH (b,d)) for maize, soybean and sunflower crops, The solid line curves represent maize, the dotted line represents soybean, with irrigated blue and rainfed red for both crops. The black curve represents sunflower. The envelope around the curves corresponds to the 95% confidence interval.

### 3.1.3. Cumulative Indices

The use of multispectral (optical and radar) and multi-temporal images products leads to an increase in the number of features, to be processed, and consequently increase the redundancy of spectral information and the computation time of the classification process. To avoid these effect, we computed cumulative monthly indices, correspond to the sum of the spectral information of each feature (rainfall, optical and radar). We used gap filling for simplicity. The use of cumulative indices sounds pertinent as they are related to the plant functioning. Indeed, many authors have demonstrated the link between plant development of the plant and the cumulative spectral indices provided by remote sensing data [57–59]. For this study, we assumed that the irrigation have an impact of several irrigation events (4 to 5 irrigations) on crop development could be captured using the cumulative indices over the growing season. Indeed, we assume that the speed and amplitude of crop development differs between irrigated and non-irrigated crops at the end of the season.

### 3.2. Classification

The algorithm used for the classification process is the Random Forest (RF) [60]. It was selected for its robustness, because it is easier to parametrise and has good performances [29,30,61–64]. The Random Forest library used is the one provided by Shark [65] available through the supervised classification framework of Orfeo Toolbox 6.7 [46]. The number of trees was set to 100, the maximum depth to 25 and max-features to  $\sqrt{\text{number features}}$ .

The pixel classification procedure has been fully automated by the Iota2 processing chain developed by CESBio and available as free software [<https://framagit.org/iota2-project/iota2.git>]. Each classification was evaluated using the reference data set, which was randomly divided into two parts: 50% of the plots were used for the training phase and 50% were used for validation. This division into two parts avoids an optimistic estimate of the performance of the classification, as it ensures that correlated pixels from the same plot will not be used for training and validation. This division into two

parts is performed for each run. RF classifiers can perform poorly when the number of training pixels for each class is unbalanced. To address this problem, the maximum number of training pixels per class has been limited to 10,000. Limiting the maximum number of pixels also reduces the training time of the classifier. For those classes where fewer pixels were available, all the pixels in the training set were used. In our case, the soybean classes (irrigated and rainfed) had less than 10,000 training pixels because this crop is poorly represented in the territory.

### 3.3. Scenarios

Several scenarios were evaluated:

- Scenario 1: with monthly cumulative SAR features only (VH, VV, VH/VV) referenced as “SAR only” in Figure 2,
- Scenario 2: with monthly cumulative Sentinel 2 features only (NDVI, NDRE, NDWI) referenced as “Optical only” in Figure 2,
- Scenario 3: with monthly cumulative optical and SAR features referenced as “Optical and SAR” in Figure 2,
- Scenario 4: scenario 3 with in addition cumulative rainfall referenced as “Optical, SAR and Rainfall” in Figure 2,
- Scenario 5: 10-day Optical, SAR features referenced as “10-day Optical and SAR” in Figure 2.

The total number of features over the entire study period of each scenario is given the Table 4.

**Table 4.** Summary of the different scenarios tested, with the number of features over the period from April to November.

	ID	Scenario	Number of Features
Cumulative	1	SAR only	24
	2	Optical only	24
	3	Optical and SAR	48
	4	Optical, SAR and rainfall data	56
Not cumulative	5	10-day Optical and SAR	385

### 3.4. Validation

Each metric was averaged over the five runs to obtain a mean value and a confidence interval per scenario and to measure robustness against the sample selection noise. The global performance was evaluated using the Kappa coefficient (1) and the Overall Accuracy (OA). The Kappa coefficient expresses a relative difference between the observed agreement  $P_o$  and the random agreement which can be expected if the classifier was random,  $P_e$ . The Overall Accuracy (OA), is the total number of correctly classified pixels divided by the total number of validation pixels.

$$Kappa = \frac{P_o - P_e}{1 - P_e} \quad (1)$$

with  $P_o = \frac{1}{n} \sum_{i=1}^r n_{ii}$  and  $P_e = \frac{1}{n^2} \sum_{i=1}^r n_i n_i$ , The performance of the different scenarios was evaluated using the reference datasets. Table 5 shows the number of pixels used for learning and validation of the classification model for each class. In view of the strong imbalance between the two datasets (Training and Validation), we know that the overall accuracy may be biased by the majority classes. To limit this bias, we decided to use another metric at the class level.

The performance of each class was evaluated using the Fscore (2).

$$Fscore = 2 \times \frac{Accuracy \times Recall}{Accuracy + Recall} \quad (2)$$

where

- Accuracy is the ratio between the correctly classified pixels and the sum of all pixels classified as this class, and
- Recall is the ratio between the correctly classified pixels and the total number of reference data pixels of that class.

The central processing unit (CPU) time and allocated Random Access Memory (RAM) were also analysed in order to define a trade-off between classifier performance and use of computational resources. This evaluation was carried out for the two steps of the classification process: the model learning and the classification steps.

**Table 5.** Number of pixels for learning and validation of the model, for each class and for each year.

Class Label	2017		2018	
	Training	Validation	Training	Validation
Irrigated Maize	10,000	51,731	10,000	33,651
Rainfed Maize	10,000	12,606	10,000	24,899
Irrigated Soybean	3388	2173	3844	4973
Rainfed Soybean	3461	4437	7319	7464
Sunflower	6502	4853	2173	1662

### 3.5. Confidence Map

The map of irrigated areas contains for each pixel the label selected by the classifier, which is a majority vote on the labels selected by all the decision trees in the forest. The probability of each class can be estimated as the proportion of trees in the forest that chose that label. It is therefore possible to associate a confidence to the decision using the probability of the majority class. Although this confidence estimate may be valuable to the user, it should be kept in mind that it is an estimate of the classifier itself, and may therefore be erroneous. The correlation between confidence and classification quality was assessed by Inglada et al. [47].

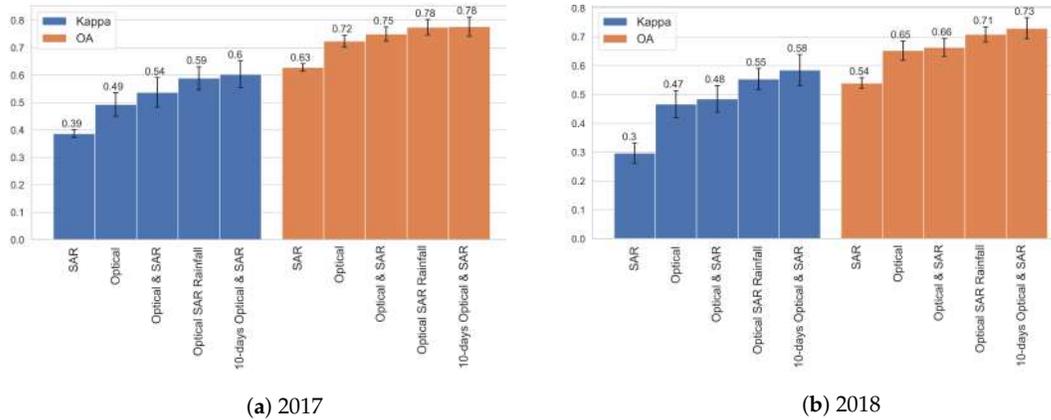
### 3.6. Postprocessing

A regularisation was applied to the final classification in order to remove isolated pixels. This procedure filters the input labelled image using majority vote in a  $3 \times 3$  neighbourhood. The majority vote takes the most representative value of all identified pixels and then sets the centre pixel to this majority label value [46]. The winter crops were also masked using the RPG of the classified year.

## 4. Results

### 4.1. Performance of Each Scenario

The global performances of the classifications are shown in Figure 5. The best results are obtained with the 10-days scenario 5.



**Figure 5.** Performance for each scenarios. The orange and blue bars correspond to Overall accuracy and Kappa respectively. (a) illustrates the results obtained in 2017 and (b) corresponds to those obtained in 2018.

The classifications with cumulative indices lead to performances slightly inferior to the 10-days classifications (OA = 0.78 in 2017), while significantly reducing the RAM usage and CPU time, as shown in the Table 6. RAM is reduced by a factor of 2 for the learning phase. The CPU time is reduced by a factor of 2 for the learning step and by a factor of 4 for the classification step. Therefore, scenario 4 may be considered a good trade-off between accuracy and computational resources. However, we should note that Kappa values ( $\approx 0.6$ ) are quite low even for the best configuration. For the further analysis, we retained the scenarios combining optical and radar features (scenarios 3, 4 and 5) as were supposed to be more robust to various meteorological conditions.

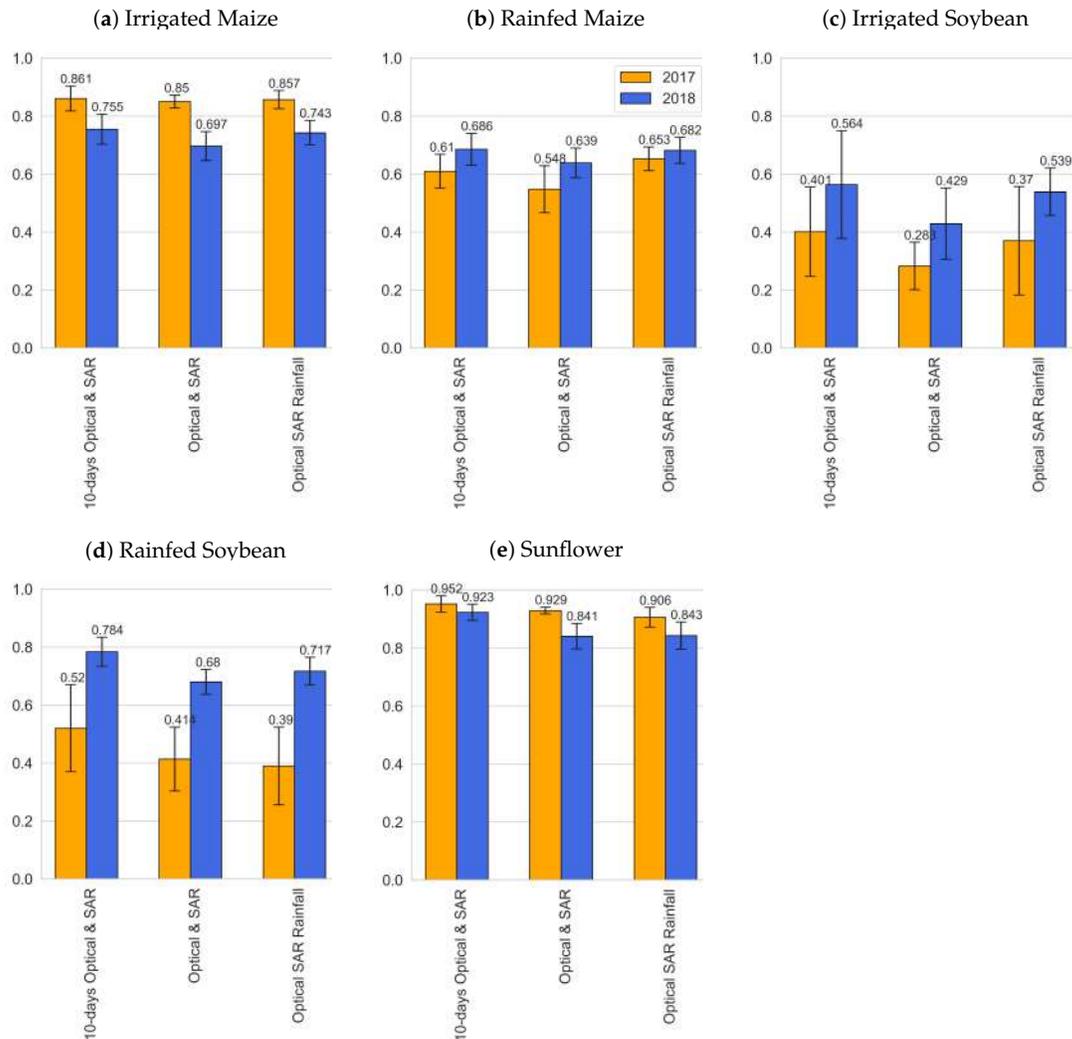
**Table 6.** Computational resources for the learning and classification stages, for each scenario.

Scenario	ID	Nb. of Features	CPU Time (in Hours)		RAM (in GB)	
			Model Learning	Classification	Model Learning	Classification
SAR	1	24	4.5	176	0.21	19
Optical	2	24	2.2	150	0.14	19
Optical & SAR	3	48	4.5	181	0.23	21
Optical SAR and Rainfall	4	54	3.5	164	0.22	21
10-days Optical & SAR	5	385	6.6	739	0.57	22

#### 4.2. Fscore Results

Figure 6 shows the Fscores for the three scenarios. The best performances are observed for sunflower for both years (Fscore > 0.9), irrigated maize in 2017 (Fscore > 0.85) and irrigated soybean in 2018 (Fscore > 0.68). The lowest scores are observed for the irrigated soybean in 2017 ( $0.28 < \text{Fscore} < 0.4$ ). Intermediate Fscore (0.4 to 0.8) are observed for the rainfed maize and rainfed soybean. The same trends are observed for all scenarios.

Except for sunflower, adding rainfall into the cumulative method (Scenarios 3 and 4) improves the Fscore and allows to reach performance comparable to the 10-day scenario (Scenario 5).



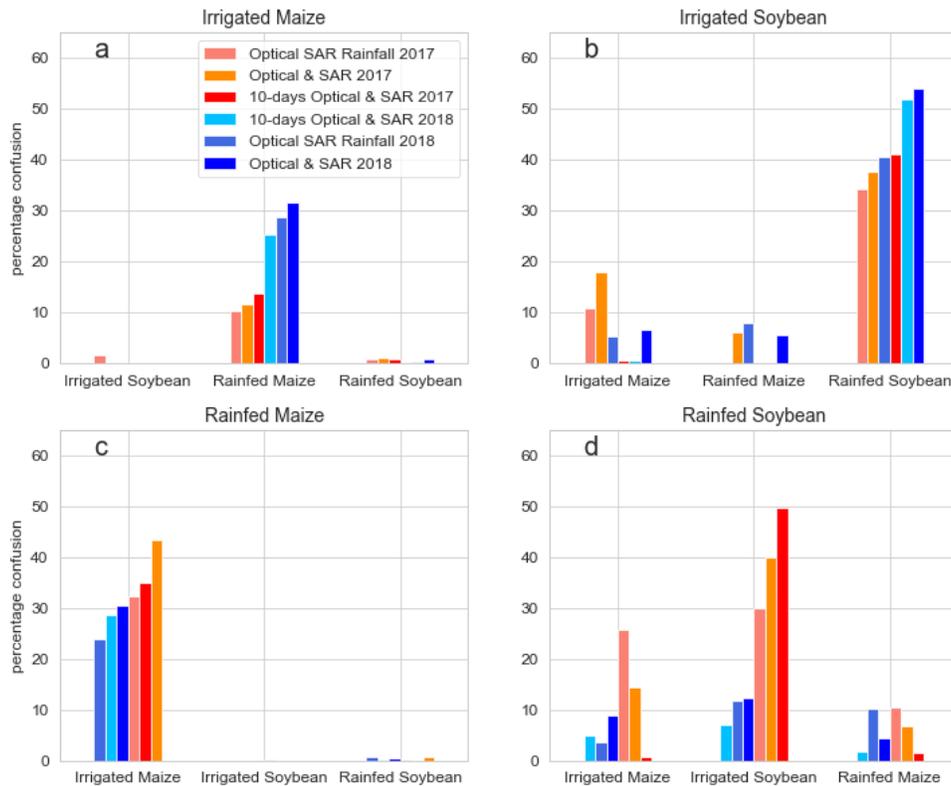
**Figure 6.** Fscore by class as a function of the 3 scenarios. The orange and blue bars correspond, respectively, to the years 2017 and 2018.

#### 4.3. Analysis of Confusion Between Classes for Irrigated Crops

The confusion between classes were analysed for the three scenarios. Figure 7 illustrates the percentage of confusion between classes for both years, i.e., the percentage of prediction error.

For both years and regardless of the scenario, confusion are observed between practices (irrigated and rainfed) for a given crop but little confusion occurs between crops. The strongest confusions ( $30\% < \text{Fscore} < 50\%$ ) are observed in 2017 between irrigated and rainfed soybean (Figure 7b,d) as observed on the Fscore values (Figure 6). Lowest confusions are observed between irrigated and rainfed maize, for both years, with Fscore values varying from 10 to 30%, in average (Figure 7a,c).

Moreover, the use of rainfall data allows for a reduction in confusions for all classes. Indeed, the percentages of confusions are almost systematically lower for scenario 4 compared to those obtained for scenario 3.



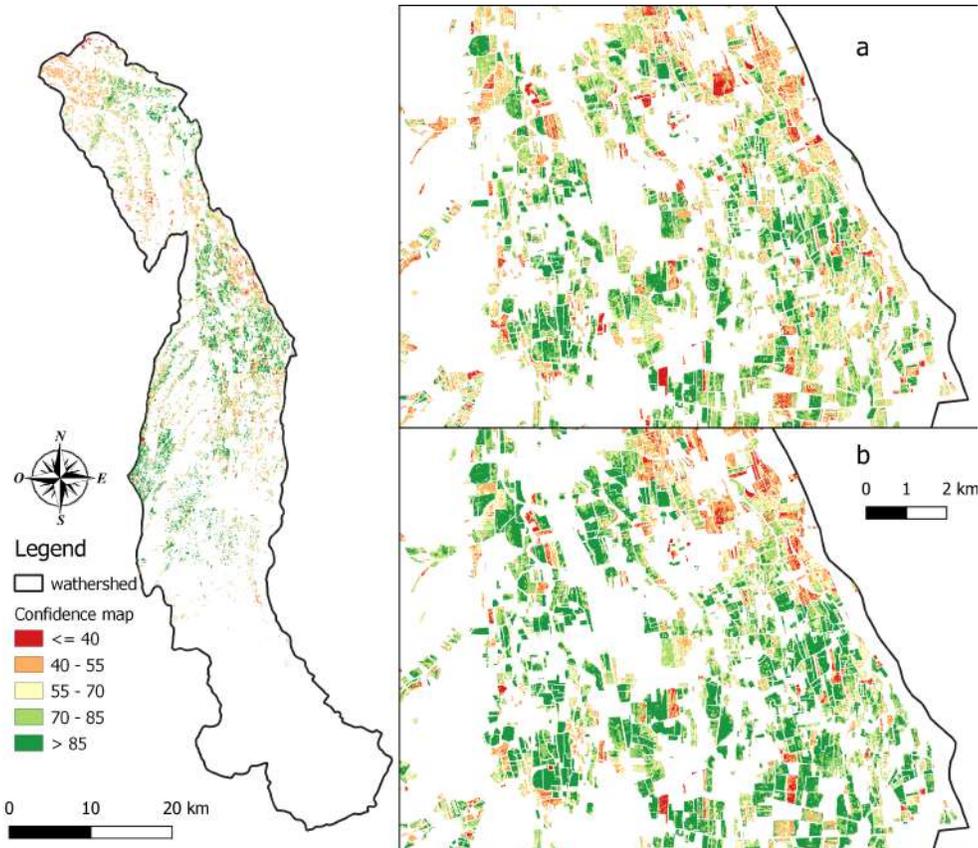
**Figure 7.** Confusion according to the scenarios. The title of each sub-graph corresponds to the real class and the labels in the horizontal axis refer to the predicted classes. The letter on each graph corresponds to a crop, with (a): irrigated maize, (b): irrigated soybean, (c): rainfed maize and (d): rainfed soybean.

#### 4.4. Confidence Map

Figure 8 shows the confidence index for each pixel on scenarios 3 (Figure 8a) and 4 (Figure 8b) in 2017. The best confidence for all classes combined is for scenario 4 for both years. Indeed, the average confidence is  $69.5\% \pm 8\%$  for scenario 4 compared to  $63\% \pm 10\%$  for scenario 3 in 2017 and  $63\% \pm 10\%$  and  $72.10\% \pm 7\%$  for scenarios 3 and 4, respectively, in 2018. We also see in Figure 8 that some areas, such as the Northeast, still have low confidence despite the addition of rainfall. These areas remain difficult to classify by the model. The Table 7 shows the average percentage of confidence for each class. Irrigated and rainfed maize and sunflower have the highest confidence for both years. Irrigated and rainfed soybeans have the lowest confidence and those for both years studied.

**Table 7.** Average confidence for the years 2017 and 2018, with associated standard deviations, expressed in %.

Class Label	2017		2018	
	Scenario 3	Scenario 4	Scenario 3	Scenario 4
Irrigated maize	$73 \pm 10$	$84 \pm 8$	$70 \pm 10$	$84 \pm 7$
Rainfed maize	$70 \pm 11$	$78 \pm 9$	$62 \pm 10$	$72 \pm 11$
Irrigated soybean	$55 \pm 11$	$61 \pm 11$	$64 \pm 12$	$65 \pm 12$
Rainfed soybean	$53 \pm 12$	$62 \pm 14$	$56 \pm 11$	$59 \pm 9$
Sunflower	$89 \pm 8$	$92 \pm 4$	$56 \pm 13$	$74 \pm 12$



**Figure 8.** Confidence map for 2017: (a) scenario 3 and (b) scenario 4.

#### 4.5. Regional Statistics

Table 8 shows the total areas by crop provided by scenario 4 and 5 and compared to RPG for the entire study area. The areas estimated were similar to the RPG, with average errors per class not exceeding  $\pm 8\%$  for Scenario 5. However, the errors were higher for Scenario 4. Maize is the crop with the best area estimated by both scenarios, with an average error of  $\pm 2\%$ . In contrast, soybeans have an average error of  $\pm 15\%$ , with the largest gap observed in 2017 in Scenario 4. Scenario 5 produced to better performances.

**Table 8.** Summary of areas by class for Scenarios 4 and 5 and the RPG for the years 2017 and 2018. They are expressed in hectares. The term diff. refers to the difference between the area from the scenario and the RPG. It is expressed as a percentage.

Class Label	2017					2018				
	RPG	Scenario 4	Diff.	Scenario 5	Diff.	RPG	Scenario 4	Diff.	Scenario 5	Diff.
Maize	20,987	21,479	+2%	20,601	−2%	20,242	20,695	+2%	20,149	−1%
Sunflower	2210	1973	−11%	2183	−1%	1242	1131	−9%	1339	+8%
Soybean	2301	1402	−39%	2445	+6%	2326	2001	+2%	2339	0%
Total	25,498	24,854	−3%	25,229	−1%	23,811	23,827	0%	23,827	0%

## 5. Discussion

### 5.1. Optical or/and Radar Features

Scenarios 1 and 2, based on single-source use of radiometric information, show the worst performance in terms of OA and Kappa coefficient (between 0.3 and 0.49). The low Fscore obtained with the radar data only is due to the large variations in the SAR signal and the lack of spectral

information that does not allow good discrimination between classes. Indeed, SAR polarisations are the result of multiple contributions, between rain, vegetation and tillage, leading to classification errors. The results obtained by this scenario are in agreement with those obtained by Ferrant et al., on the Telangana province in South India with a Kappa coefficient between 0.3 and 0.49 depending on the year [35]. The poor performance of scenario 2 is due to the low number of features, caused by cloud cover (37% in 2017 and 31% in 2018), and the absence of the 2B sensor in 2017 that can make crop growth detection difficult like frequently observed in [9,10,33,35,36].

Thus so-called “single-source” scenarios are highly dependent on the number and quality of the dataset. Figure 5 reveals that the synergy optical and radar data permits to limit the impact of cloud cover, with a gain in all metrics for both years. Similar results were found in the literature with a significant gain in performance on the detection of irrigated areas in India (more than 74% gain on the Fscore and 0.20 on the kappa coefficient, when the synergy of the two sensors is used) [35], in Northern Spain, with a 5% increase in overall accuracy compared to using Sentinel-1 data alone [37].

### 5.2. Impact of Cumulative Indices

Dealing with the huge number of images available requires optimised computing methods. To avoid this constraint, we evaluated the performance of classifications with a reduced number of indices. Results show that cumulative indices lead to similar performances for maize (irrigated/rainfed) than the overall 10-day features (Figure 5), meaning that these is redundant information when using all the full spectral bands and dates. The lowest Fscore observed for the minority classes (Soybean and rainfed maize) is due to a deficit of learning samples. Indeed, the low number of reference dataset for these classes does not allow to characterise the whole spatial and temporal variability of these classes, and consequently leads to a high degree of confusion, as shown in Figure 7. However, Scenario 5 is seems less sensitive to the size of reference dataset. The addition of the learning data for the soybean and rainfed maize in 2018, the results were improved with lower confusion (Figure 7) and higher Fscore. This link between performance of the classification methods and the number of reference data has been raise by Pelletier et al. [64]. For sunflowers, there is a decrease in Fscore and confidence between 2017 and 2018, which is explained by a smaller sample area in 2018, with only 40 ha, compared to 120 ha in 2017. Nevertheless, this small sample area does not have a significant impact on the results, as the phenology of this crop is very different from that of the other crops studied, as shown in Figure 3.

Much less computational resources was needed for the cumulative approach, as shown in Table 6. Classifications based on the use of cumulative indices (56 features) lead to similar performances to classifications using the 10-days features (385 features), while reducing the consumption of the computing resources by a factor of 4.

### 5.3. Contribution of Rainfall Features

The addition of rainfall data into the process slightly enhances the performance of the cumulative method, as illustrated by Fscore (Figure 6) and confidence (Section 4.4 and Table 7).

Indeed, adding these data improves the separability of the classes (Figure 7), and the possible noise of labelling present in the reference dataset. Nevertheless, they seem to lose importance during rainy years, as illustrated by the results on irrigated maize, which show a decrease in the Fscore between 2017 and 2018. This loss of efficiency can be explained by similar canopy growth dynamics between irrigated and rainfed crops, as rainfed crops are not subject to water stress limiting their phenological development during drought periods. These data also show that they can be used to discriminate rainfed and irrigated crops for near-real-time approaches [37]. Moreover, we note that scenario 4 is slightly faster compared to scenario 3 during the learning and application phase of the model (classification). This increase in speed is explained by the addition of rainfall data in the classification process which seems to simplify the choice of the classifier to assign a class to a given pixel.

The analysis of the confidence map illustrated in Section 4.4 confirms these results as the best confidence values are observed for scenario 4 (Figure 8) and those for both years. Nevertheless, the contribution of meteorological data does not significantly increase confidence for minority classes as shown in the Table 7. There are still areas where uncertainty remains high, as illustrated in the inserts of the Figure 8. As rainfall exhibits spatial heterogeneities all the ambiguities between irrigated and rainfed plots might not be removed. Indeed, the rainfall data used in our study have a low spatial resolution (8 km), which can increase confusions on the distinction between irrigated and rainfall.

## 6. Conclusions

The objective of this study was to establish a methodology for detecting irrigated and rainfed crops in temperate areas, using monthly cumulative of optical vegetation indices and SAR polarisations together. The use of these cumulative indices allows taking into account discrepancies on canopy development (speed and amplitude) between various crops and practices (irrigated and rainfed), while retaining all the spectral information. Classifications with radar only, or optical only, show poor performances (Kappa and OA < 0.5) caused by the lack of spectral information, not allowing a good discrimination of classes. The combined use of optical and radar features gives excellent results for irrigated maize (Fscore > 0.80), which represents 80% of the summer crops in the area. The results were worse for soybean (Fscore < 0.60), especially in 2017, which is explained by the lack of in situ reference data, partly due to the low representativeness of this crop on this territory (9%), making in situ collection difficult. In order to overcome this data constraint and to be able to extend the study area, the use of an eco-climatic spatial stratification could be envisaged as illustrated by Inglada et al. [47]. The use of spatial stratification would allow an improvement in performance as well as a better sampling of the minority classes.

In the course of this work, the contribution of rainfall data was also evaluated. The addition of these data allows a significant improvement of the Fscore for the irrigated and rainfed classes and a reduction of confusion between classes during dry years. However, the low spatial resolution of rainfall data used in our study (8 km), can lead to high uncertainties, especially in areas with strong rainfall heterogeneity. To limit these uncertainties, the use of data with a finer spatial resolution, like the AROME [66] or the COMEPHORE [67] data distributed by Météo-France, can be considered in a future work. Our study also reveals that the use of monthly cumulative indices leads to performances similar to those of the use of gap-filled images every 10 days while reducing the need of computer resources ( $\times 4$ ). A cumulative method would seem to be the best choice for operational application, maintaining the best classification performances, while reducing the need of computational resources. The approach developed is valuable for cereal crops in temperate climate but it might also be valuable for semi-arid areas where the contrasts between irrigated and rainfed crops are huge. However, that needs to be confirmed with further studies. The study could also be extended by an in-season study such as proposed in Demarez et al. [36] that revealed that the use of Landsat-8 and Sentinel-1 images allowed early detection of irrigated crops.

**Author Contributions:** Y.P. and V.D. conceived and designed the experiments; Y.P. conducted the experiments; Y.P., V.D., F.B. and J.I. analysed the results; Y.P. and V.D., wrote the article; J.I., N.B. and F.B. revised the paper. All authors have read and agreed to the published version of the manuscript.

**Acknowledgments:** This work is funded by the French space agency (CNES), Adour Garonne Water Agency and the Compagnie d'aménagement des coteaux de Gascogne, and it was carried out at the CESBIO laboratory. The authors would like to thank the Hautes Pyrénées Chamber of Agriculture for the data collection and T the development team of the  $iota^2$  chain and especially Arthur Vincent for his help in the computer development of the method.

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

## References

- Bruinsma, J. Food and Agriculture Organization of the United Nations. *World Agriculture: Towards 2015/2030: An FAO Perspective*; Earthscan Publications Ltd.: London, UK, 2003.
- Schaldach, R.; Koch, J.; der Beek, T.A.; Kynast, E.; Flörke, M. Current and future irrigation water requirements in pan-Europe: An integrated analysis of socio-economic and climate scenarios. *Glob. Planet. Chang.* **2012**, *94*, 33–45. [[CrossRef](#)]
- Dubois, O. *The State of the World's Land and Water Resources for Food and Agriculture: Managing Systems at Risk*; Earthscan Publications Ltd.: London, UK, 2011.
- Ozdogan, M.; Yang, Y.; Allez, G.; Cervantes, C. Remote Sensing of Irrigated Agriculture: Opportunities and Challenges. *Remote Sens.* **2010**, *2*, 2274–2304. [[CrossRef](#)]
- Bastiaanssen, W.G.; Molden, D.J.; Makin, I.W. Remote sensing for irrigated agriculture: Examples from research and possible applications. *Agric. Water Manag.* **2000**, *46*, 137–155. [[CrossRef](#)]
- Bazzi, H.; Baghdadi, N.; El Hajj, M.; Zribi, M. Potential of Sentinel-1 Surface Soil Moisture Product for Detecting Heavy Rainfall in the South of France. *Sensors* **2019**, *19*, 802. [[CrossRef](#)]
- Boken, V.K.; Hoogenboom, G.; Kogan, F.N.; Hook, J.E.; Thomas, D.L.; Harrison, K.A. Potential of using NOAA-AVHRR data for estimating irrigated area to help solve an inter-state water dispute. *Int. J. Remote Sens.* **2004**, *25*, 2277–2286. [[CrossRef](#)]
- Kamthonkiat, D.; Honda, K.; Turrall, H.; Tripathi, N.; Wuwongse, V. Discrimination of irrigated and rainfed rice in a tropical agricultural system using SPOT VEGETATION NDVI and rainfall data. *Int. J. Remote Sens.* **2005**, *26*, 2527–2547. [[CrossRef](#)]
- Thenkabail, P.S.; Schull, M.; Turrall, H. Ganges and Indus river basin land use/land cover (LULC) and irrigated area mapping using continuous streams of MODIS data. *Remote Sens. Environ.* **2005**, *95*, 317–341. [[CrossRef](#)]
- Ozdogan, M.; Gutman, G. A new methodology to map irrigated areas using multi-temporal MODIS and ancillary data: An application example in the continental US. *Remote Sens. Environ.* **2008**, *112*, 3520–3537. [[CrossRef](#)]
- Portmann, F.T.; Siebert, S.; Döll, P. MIRCA2000—Global monthly irrigated and rainfed crop areas around the year 2000: A new high-resolution data set for agricultural and hydrological modeling. *Glob. Biogeochem. Cycles* **2010**, *24*. [[CrossRef](#)]
- Pervez, M.S.; Brown, J.F. Mapping irrigated lands at 250-m scale by merging MODIS data and national agricultural statistics. *Remote Sens.* **2010**, *2*, 2388–2412. [[CrossRef](#)]
- Hajj, M.E.; Baghdadi, N.; Belaud, G.; Zribi, M.; Cheviron, B.; Courault, D.; Hagolle, O.; Charron, F. Irrigated Grassland Monitoring Using a Time Series of TerraSAR-X and COSMO-SkyMed X-Band SAR Data. *Remote Sens.* **2014**, *6*, 10002–10032. [[CrossRef](#)]
- Zohaib, M.; Kim, H.; Choi, M. Detecting global irrigated areas by using satellite and reanalysis products. *Sci. Total Environ.* **2019**, *677*, 679–691. [[CrossRef](#)] [[PubMed](#)]
- Thenkabail, P.; Dheeravath, V.; Biradar, C.; Gangalakunta, O.R.; Noojipady, P.; Gurappa, C.; Velpuri, M.; Gumma, M.; Li, Y.; Thenkabail, P.S.; et al. Irrigated Area Maps and Statistics of India Using Remote Sensing and National Statistics. *Remote Sens.* **2009**, *1*, 50–67. [[CrossRef](#)]
- Cheema, M.J.M.; Bastiaanssen, W.G.M. Land use and land cover classification in the irrigated Indus Basin using growth phenology information from satellite data to support water management analysis. *Agric. Water Manag.* **2010**, *97*, 1541–1552. [[CrossRef](#)]
- Dheeravath, V.; Thenkabail, P.S.; Chandrakantha, G.; Noojipady, P.; Reddy, G.P.O.; Biradar, C.M.; Gumma, M.K.; Velpuri, M. Irrigated areas of India derived using MODIS 500 m time series for the years 2001–2003. *ISPRS J. Photogramm. Remote Sens.* **2010**, *65*, 42–59. [[CrossRef](#)]
- Gumma, M.K.; Thenkabail, P.S.; Hideto, F.; Nelson, A.; Dheeravath, V.; Busia, D.; Rala, A. Mapping irrigated areas of Ghana using fusion of 30 m and 250 m resolution remote-sensing data. *Remote Sens.* **2011**, *3*, 816–835. [[CrossRef](#)]
- Ambika, A.K.; Wardlow, B.; Mishra, V. Remotely sensed high resolution irrigated area mapping in India for 2000 to 2015. *Sci. Data* **2016**, *3*, 160118. [[CrossRef](#)]

20. Bousbih, S.; Zribi, M.; El Hajj, M.; Baghdadi, N.; Lili-Chabaane, Z.; Gao, Q.; Fanise, P. Soil moisture and irrigation mapping in A semi-arid region, based on the synergetic use of Sentinel-1 and Sentinel-2 data. *Remote Sens.* **2018**, *10*, 1953. [[CrossRef](#)]
21. Gao, Q.; Zribi, M.; Escorihuela, M.J.; Baghdadi, N.; Segui, P.Q. Irrigation Mapping Using Sentinel-1 Time Series at Field Scale. *Remote Sens.* **2018**, *10*, 1495. [[CrossRef](#)]
22. Jalilvand, E.; Tajrishy, M.; Hashemi, S.A.G.Z.; Brocca, L. Quantification of irrigation water using remote sensing of soil moisture in a semi-arid region. *Remote Sens. Environ.* **2019**, *231*, 111226. [[CrossRef](#)]
23. Xie, Y.; Lark, T.J.; Brown, J.F.; Gibbs, H.K. Mapping irrigated cropland extent across the conterminous United States at 30 m resolution using a semi-automatic training approach on Google Earth Engine. *ISPRS J. Photogramm. Remote Sens.* **2019**, *155*, 136–149. [[CrossRef](#)]
24. Peña-Arancibia, J.L.; McVicar, T.R.; Paydar, Z.; Li, L.; Guerschman, J.P.; Donohue, R.J.; Dutta, D.; Podger, G.M.; van Dijk, A.I.J.M.; Chiew, F.H.S. Dynamic identification of summer cropping irrigated areas in a large basin experiencing extreme climatic variability. *Remote Sens. Environ.* **2014**, *154*, 139–152. [[CrossRef](#)]
25. Shahriar Pervez, M.; Budde, M.; Rowland, J. Mapping irrigated areas in Afghanistan over the past decade using MODIS NDVI. *Remote Sens. Environ.* **2014**, *149*, 155–165. [[CrossRef](#)]
26. Torres, R.; Snoeij, P.; Geudtner, D.; Bibby, D.; Davidson, M.; Attema, E.; Potin, P.; Rommen, B.; Floury, N.; Brown, M.; et al. GMES Sentinel-1 mission. *Remote Sens. Environ.* **2012**, *120*, 9–24. [[CrossRef](#)]
27. Drusch, M.; Del Bello, U.; Carlier, S.; Colin, O.; Fernandez, V.; Gascon, F.; Hoersch, B.; Isola, C.; Laberinti, P.; Martimort, P.; et al. Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services. *Remote Sens. Environ.* **2012**, *120*, 25–36. [[CrossRef](#)]
28. Inglada, J.; Arias, M.; Tardy, B.; Hagolle, O.; Valero, S.; Morin, D.; Dedieu, G.; Sepulcre, G.; Bontemps, S.; Defourny, P.; et al. Assessment of an Operational System for Crop Type Map Production Using High Temporal and Spatial Resolution Satellite Optical Imagery. *Remote Sens.* **2015**, *7*, 12356–12379. [[CrossRef](#)]
29. Valero, S.; Morin, D.; Inglada, J.; Sepulcre, G.; Arias, M.; Hagolle, O.; Dedieu, G.; Bontemps, S.; Defourny, P.; Koetz, B.; et al. Production of a Dynamic Cropland Mask by Processing Remote Sensing Image Series at High Temporal and Spatial Resolutions. *Remote Sens.* **2016**, *8*, 55. [[CrossRef](#)]
30. Immitzer, M.; Vuolo, F.; Atzberger, C.; Immitzer, M.; Vuolo, F.; Atzberger, C. First Experience with Sentinel-2 Data for Crop and Tree Species Classifications in Central Europe. *Remote Sens.* **2016**, *8*, 166. [[CrossRef](#)]
31. 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. [[CrossRef](#)]
32. Vuolo, F.; Neuwirth, M.; Immitzer, M.; Atzberger, C.; Ng, W.T. How much does multi-temporal Sentinel-2 data improve crop type classification? *Int. J. Appl. Earth Obs. Geoinf.* **2018**, *72*, 122–130. [[CrossRef](#)]
33. Vogels, M.F.; De Jong, S.M.; Sterk, G.; Douma, H.; Addink, E.A. Spatio-temporal patterns of smallholder irrigated agriculture in the horn of Africa using GEOBIA and Sentinel-2 imagery. *Remote Sens.* **2019**, *11*, 143. [[CrossRef](#)]
34. Fieuzal, R.; Duchemin, B.; Jarlan, L.; Zribi, M.; Baup, F.; Merlin, O.; Hagolle, O.; Garatuza-Payan, J. Combined use of optical and radar satellite data for the monitoring of irrigation and soil moisture of wheat crops. *Hydrol. Earth Syst. Sci.* **2011**, *15*, 1117–1129. [[CrossRef](#)]
35. Ferrant, S.; Selles, A.; Le Page, M.; Herrault, P.A.; Pelletier, C.; Al-Bitar, A.; Mermoz, S.; Gascoin, S.; Bouvet, A.; Saqalli, M.; et al. Detection of Irrigated Crops from Sentinel-1 and Sentinel-2 Data to Estimate Seasonal Groundwater Use in South India. *Remote Sens.* **2017**, *9*, 1119. [[CrossRef](#)]
36. Demarez, V.; Helen, F.; Marais-Sicre, C.; Baup, F. In-Season Mapping of Irrigated Crops Using Landsat 8 and Sentinel-1 Time Series. *Remote Sens.* **2019**, *11*, 118. [[CrossRef](#)]
37. Bazzi, H.; Baghdadi, N.; Ienco, D.; El Hajj, M.; Zribi, M.; Belhouchette, H.; Escorihuela, M.J.; Demarez, V. Mapping Irrigated Areas Using Sentinel-1 Time Series in Catalonia, Spain. *Remote Sens.* **2019**, *11*, 1836. [[CrossRef](#)]
38. Bazzi, H.; Baghdadi, N.; Fayad, I.; Zribi, M.; Belhouchette, H.; Demarez, V. Near Real-Time Irrigation Detection at Plot Scale Using Sentinel-1 Data. *Remote Sens.* **2020**, *12*, 1456. [[CrossRef](#)]
39. Le Page, M.; Jarlan, L.; El Hajj, M.M.; Zribi, M.; Baghdadi, N.; Boone, A. Potential for the Detection of Irrigation Events on Maize Plots Using Sentinel-1 Soil Moisture Products. *Remote Sens.* **2020**, *12*, 1621. [[CrossRef](#)]

40. Durand, Y.; Brun, E.; Merindol, L.; Guyomarc'h, G.; Lesaffre, B.; Martin, E. A meteorological estimation of relevant parameters for snow models. *Ann. Glaciol.* **1993**, *18*, 65–71. [[CrossRef](#)]
41. Cantelaube, P.; Carles, M. Le registre parcellaire graphique: Des données géographiques pour décrire la couverture du sol agricole. In *Le Cahier des Techniques de L'INRA*; INRA: Paris, France, 2014; pp. 58–64.
42. IRRIGADOUR, O.U. *Organisme Unique de Gestion Collective IRRIGADOUR, Rapport Annuel 2018*; Technical Report; Organisme Unique IRRIGADOUR : Paris, France, 2019.
43. Monod, B. *Carte Géologique Numérique à 1/250 000 de la Région Midi-Pyrénées*; Notice Technique -BRGM/RP-63650-FR; BRGM: Paris, France, 2014; p. 160.
44. Hagolle, O.; Huc, M.; Villa Pascual, D.; Dedieu, G. A multi-temporal and multi-spectral method to estimate aerosol optical thickness over land, for the atmospheric correction of FormoSat-2, LandSat, VEN $\mu$ S and Sentinel-2 images. *Remote Sens.* **2015**, *7*, 2668–2691. [[CrossRef](#)]
45. Baetens, L.; Desjardins, C.; Hagolle, O. Validation of Copernicus Sentinel-2 Cloud Masks Obtained from MAJA, Sen2Cor, and FMask Processors Using Reference Cloud Masks Generated with a Supervised Active Learning Procedure. *Remote Sens.* **2019**, *11*, 433. [[CrossRef](#)]
46. Grizonnet, M.; Michel, J.; Poughon, V.; Inglada, J.; Savinaud, M.; Cresson, R. Orfeo ToolBox: Open source processing of remote sensing images. *Open Geospat. Data Softw. Stand.* **2017**, *2*, 15. [[CrossRef](#)]
47. Inglada, J.; Vincent, A.; Arias, M.; Tardy, B.; Morin, D.; Rodes, I. Operational High Resolution Land Cover Map Production at the Country Scale Using Satellite Image Time Series. *Remote Sens.* **2017**, *9*, 95. [[CrossRef](#)]
48. Tucker, C.J. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sens. Environ.* **1979**, *8*, 127–150. [[CrossRef](#)]
49. Huete, A.; Didan, K.; Miura, T.; Rodriguez, E.P.; Gao, X.; Ferreira, L.G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sens. Environ.* **2002**, *83*, 195–213. [[CrossRef](#)]
50. Gitelson, A.; Merzlyak, M.N. Spectral reflectance changes associated with autumn senescence of *Aesculus hippocastanum* L. and *Acer platanoides* L. leaves. Spectral features and relation to chlorophyll estimation. *J. Plant Physiol.* **1994**, *143*, 286–292. [[CrossRef](#)]
51. Sims, D.A.; Gamon, J.A. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. *Remote Sens. Environ.* **2002**, *81*, 337–354. [[CrossRef](#)]
52. Gao, B.C. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sens. Environ.* **1996**, *58*, 257–266. [[CrossRef](#)]
53. Patel, P.; Srivastava, H.S.; Panigrahy, S.; Parihar, J.S. Comparative evaluation of the sensitivity of multi-polarized multi-frequency SAR backscatter to plant density. *Int. J. Remote Sens.* **2006**, *27*, 293–305. [[CrossRef](#)]
54. Jacome, A.; Bernier, M.; Chokmani, K.; Gauthier, Y.; Poulin, J.; De Sève, D. Monitoring volumetric surface soil moisture content at the La Grande basin boreal wetland by radar multi polarization data. *Remote Sens.* **2013**, *5*, 4919–4941. [[CrossRef](#)]
55. Amazirh, A.; Merlin, O.; Er-Raki, S.; Gao, Q.; Rivalland, V.; Malbeteau, Y.; Khabba, S.; Escorihuela, M.J. Retrieving surface soil moisture at high spatio-temporal resolution from a synergy between Sentinel-1 radar and Landsat thermal data: A study case over bare soil. *Remote Sens. Environ.* **2018**, *211*, 321–337. [[CrossRef](#)]
56. Chauhan, S.; Srivastava, H.S. Comparative evaluation of the sensitivity of multi-polarized SAR and optical data for various land cover classes. *Int. J. Adv. Remote Sens. GIS Geogr.* **2016**, *4*, 1–14.
57. Keeling, C.; Tucker, C.; Asrar, G.; Nemani, R. Increased plant growth in the northern high latitudes from 1981 to 1991. *Nature* **1997**, *386*, 698–702.
58. Dong, J.; Kaufmann, R.K.; Myneni, R.B.; Tucker, C.J.; Kauppi, P.E.; Liski, J.; Buermann, W.; Alexeyev, V.; Hughes, M.K. Remote sensing estimates of boreal and temperate forest woody biomass: Carbon pools, sources, and sinks. *Remote Sens. Environ.* **2003**, *84*, 393–410. [[CrossRef](#)]
59. Myneni, R.; Williams, D. On the relationship between FAPAR and NDVI. *Remote Sens. Environ.* **1994**, *49*, 200–211. [[CrossRef](#)]
60. Breiman, L. Random Forests. *Mach. Learn.* **2001**, *45*, 5–32. [[CrossRef](#)]

61. Miao, X.; Heaton, J.S.; Zheng, S.; Charlet, D.A.; Liu, H. Applying tree-based ensemble algorithms to the classification of ecological zones using multi-temporal multi-source remote-sensing data. *Int. J. Remote Sens.* **2012**, *33*, 1823–1849. [[CrossRef](#)]
62. Rodriguez-Galiano, V.F.; Ghimire, B.; Rogan, J.; Chica-Olmo, M.; Rigol-Sanchez, J.P. An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS J. Photogramm. Remote Sens.* **2012**, *67*, 93–104. [[CrossRef](#)]
63. Pelletier, C.; Valero, S.; Inglada, J.; Champion, N.; Dedieu, G. Assessing the robustness of Random Forests to map land cover with high resolution satellite image time series over large areas. *Remote Sens. Environ.* **2016**, *187*, 156–168. [[CrossRef](#)]
64. Pelletier, C.; Valero, S.; Inglada, J.; Champion, N.; Marais Sicre, C.; Dedieu, G. Effect of Training Class Label Noise on Classification Performances for Land Cover Mapping with Satellite Image Time Series. *Remote Sens.* **2017**, *9*, 173. [[CrossRef](#)]
65. Igel, C.; Heidrich-Meisner, V.; Glasmachers, T. Shark. *J. Mach. Learn. Res.* **2008**, *9*, 993–996.
66. Bouttier, F. Arome, avenir de la prévision régionale. In *La Météorologie*; Société Météorologique de France: Paris, France, 2007.
67. Tabary, P.; Desplats, J.; Do Khac, K.; Eideliman, F.; Gueguen, C.; Heinrich, J.C. The New French Operational Radar Rainfall Product. Part II: Validation. *Weather Forecast.* **2007**, *22*, 409–427. [[CrossRef](#)]



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





**AUTEUR :** PAGEOT Yann

**TITRE :** Apport des données satellitaires Sentinel-1 et Sentinel-2 pour la détection des surfaces irriguées et l'estimation des besoins et des consommations en eau des cultures d'été dans les zones tempérées.

**DIRECTRICE DE THÈSE :** DEMAREZ Valérie

**LIEU ET DATE DE SOUTENANCE :** CESBio , 13 décembre 2021

---

### Résumé

L'eau est une ressource naturelle, qui depuis des millions d'années participe au cycle de la vie. Mais depuis peu, le changement climatique et les activités humaines remettent en cause l'équilibre du cycle de l'eau. Pour préserver cette ressource, il est nécessaire d'améliorer la connaissance sur les surfaces irriguées ainsi que les besoins et consommations en eau des cultures sur de grandes surfaces, mais elle n'est pas simple à appréhender à cause de la forte variabilité spatiale des sols, du climat et des pratiques agricoles. La télédétection a un rôle fondamental à jouer et plus particulièrement les données Sentinel. Ces travaux de thèse ont vocation à fournir des outils de diagnostics pour assurer une gestion optimale de la ressource en eau à l'échelle des bassins versants. Pour cela, une approche de cartographie des surfaces irriguées en zones tempérées à partir d'images Sentinel-1 & 2 a été développée. Elle a permis de cartographier les cultures d'été irriguées et pluviales sur les bassins versants Adour amont et Tarn aval en fin de saison. Nous nous sommes intéressés à la modélisation des besoins et des consommations en eau du maïs irrigué à partir du modèle agro-météorologique SAMIR utilisant des images d'indice de végétation (NDVI et FCover). Il a été appliqué à différentes échelles spatiales et sur différents jeux de données de validation. Les résultats montrent que le modèle est capable de reproduire de façon satisfaisante les consommations en eau des parcelles des partenaires. Nous avons également évalué l'impact de différentes données pédologiques pour estimer la réserve utile (RU). Les résultats illustrent la nécessité d'une bonne estimation de la RU et cela à une échelle compatible avec une modélisation à la parcelle pour pouvoir estimer correctement les irrigations saisonnières, ainsi que les volumes.

---

**TITLE :** Contribution of Sentinel 1 and Sentinel 2 satellite data for the detection of irrigated areas and the estimation of water needs and consumption of summer crops in temperate zones

### Abstract

Water is a natural resource that has been part of the life cycle for millions of years. But recently, climate change and human activities have challenged the balance of the water cycle. To preserve this resource, it is necessary to improve knowledge of irrigated areas and the water needs and consumption of crops over large areas, but this is not easy to understand because of the high spatial variability of soils, climate and cultivation practices. Remote sensing has a fundamental role to play and more particularly Sentinel data. The aim of this thesis is to provide diagnostic tools to ensure optimal management of water resources at the catchment scale. To this end, an approach for mapping irrigated areas in temperate zones based on monthly Sentinel-1 & 2 images was developed. It was used to map irrigated and rain-fed summer crops in the Adour amont and Tarn aval catchments during and at the end of the season. In parallel with these results, the method was developed for operational purposes. We focused on modelling the water requirements and consumption of irrigated maize using the SAMIR agro-meteorological model using vegetation index images (NDVI and FCover). It was applied at different spatial scales and on different validation data sets. The results show that the model is able to reproduce satisfactorily the water consumption of the partners plots. We also evaluated the impact of different soil data to estimate the maximum useful reserve. The results illustrate the need for a good estimation of the AWC at a scale compatible with plot modelling in order to be able to correctly estimate seasonal irrigations and volumes.

**MOTS-CLÉS:** Irrigation, Sentinel-1 et Sentinel-2, Cartographie, Modélisation du bilan hydrique

**DISCIPLINE ADMINISTRATIVE :** Surfaces et interfaces continentales - Hydrologie

**INTITULE ET ADRESSE DU LABORATOIRE :** Centre d'études spatiales de la Biosphère, UMR 5126, 13 avenue colonel roche 31401 Toulouse.