



Les synergies de la télédétection optique par drone et satellite : changement d'échelle et application à la conservation des prairies humides

Emilien Alvarez-Vanhard

► To cite this version:

Emilien Alvarez-Vanhard. Les synergies de la télédétection optique par drone et satellite : changement d'échelle et application à la conservation des prairies humides. Géographie. Université Rennes 2, 2021. Français. NNT : . tel-03519981

HAL Id: tel-03519981

<https://theses.hal.science/tel-03519981>

Submitted on 10 Jan 2022

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 DE DOCTORAT DE

L'UNIVERSITÉ DE RENNES 2

ÉCOLE DOCTORALE N° 604
Sociétés, temps, territoires
Spécialité : *Géographie*

Par

Emilien ALVAREZ-VANHARD

Les synergies de la télédétection optique par drone et satellite

Changement d'échelle et application à la conservation des prairies humides

Thèse présentée et soutenue à Rennes, le 25/10/2021

Unité de recherche : LETG (Littoral - Environnement - Télédétection - Géomatique) UMR 6554

Rapporteurs avant soutenance :

Hervé PIÉGAY Directeur de Recherche CNRS - EVS UMR 5600
Xavier BRIOTTET Directeur de Recherche ONERA - DOTA

Composition du Jury :

Examinatrice :	Anne PUISSANT	Professeure - LIVE UMR 7362 / Université de Strasbourg
Examinatrice :	Charlotte PELLETIER	Maître de conférence - IRISA UMR 6074 / Université Bretagne Sud
Examinatrice :	Cendrine MONY	Maître de conférence - ECOBIO UMR 6553 / Université Rennes 1
Examineur :	Simon GASCOIN	Chargé de recherche CNRS - CESBIO UMR 5126
Dir. de thèse :	Thomas HOUET	Directeur de recherche CNRS - LETG UMR 6554 / Université Rennes 2
Co-dir. de thèse :	Thomas CORPETTI	Directeur de recherche CNRS - LETG UMR 6554 / Université Rennes 2

REMERCIEMENTS

Je remercie toutes celles et ceux qui ont rendu possible, de près ou de loin, l'aboutissement de ce travail de thèse en y contribuant directement et indirectement, en m'encourageant ou tout simplement en étant à mes côtés.

Je voudrais dans un premier temps remercier mes directeurs de thèse : les deux Thomas, Houet et Corpetti. Je les remercie d'avoir encadré mes travaux de recherche et d'avoir su me conseiller tout le long de ces 3 années.

Thomas Houet, un grand merci pour m'avoir fait confiance très tôt dans mon parcours, dès ma première année de master, en acceptant d'encadrer un premier projet qui démarra une série d'autres sur la thématique des drones. Je te remercie de m'avoir initié à ce passionnant sujet et d'avoir été mon mentor. J'ai toujours été très enthousiaste de participer aux diverses missions drone auxquelles tu me conviais.

Thomas Corpetti, un grand merci également pour avoir co-encadré cette thèse. Tes conseils et explications ont toujours été d'une grande utilité et ont contribué à alimenter ma réflexion. J'ai aussi grâce à toi pu découvrir certaines merveilles de la Chine et une équipe scientifique très accueillante au laboratoire AIR de Pékin. Ce fut une expérience enrichissante pour moi tant sur le plan professionnelle que personnelle.

Je tiens à remercier Xavier Briottet, Hervé Piégay, Anne Puissant, Charlotte Pelletier, Cendrine Mony et Simon Gascoin d'avoir accepté d'être dans mon jury thèse.

Je remercie aussi Romain Tavenard et Cendrine Mony pour avoir été dans mon comité de suivi et de m'avoir apporté leurs réflexions toujours très pertinentes.

Je suis très heureux et reconnaissant d'avoir appartenu à l'écosystème LETG-Rennes. D'abord, je suis honoré d'avoir eu pour collègues mes anciens enseignants - Samuel, Damien, Jean, Alban, Simon - et d'avoir découvert que leur sérieux n'a d'égale que leur joyeuseté. Je suis très heureux d'avoir vécu cette aventure en même temps que Gwen et Alex avec qui j'ai souvent pu partager mes galères et qui ont été d'une grande aide pour cela. Gwen, d'une motivation sans limite, toujours prête pour lancer un nouveau projet ou boire un coup. Je suis très heureux d'en avoir initié certains avec toi (Longue vie à Géolink!). Alex, d'une rigueur scientifique naturelle qui m'aura inspiré et continuera à m'inspirer je l'espère pour mes futures recherches. Ce fut un plaisir aussi d'avoir Damien

comme compagnon de galère toujours dispo pour une session skate ou discuter de nos techniques photo respectives. Merci à Florent d’avoir été mon colocataire pendant 3 mois, je garde un très bon souvenir de nos aventures en Chine. Un merci particulier à Gu, pour avoir été comme un troisième superviseur pendant cette fin de thèse, tes commentaires furent d’une grande aide. Merci au trio Clémence, Elodie et Jeanne qui amenaient une énergie particulière à la vie de labo. J’ai eu également la chance d’exercer le métier d’enseignant pendant quelques semestres avec Adeline, Anne-Julia et Valérie et les remercie d’avoir partagé leurs expériences avec moi. Mais aussi un grand merci à tous les doctorants - Julien, Audrey, Fanny, Charlotte, Pedro, Paul, Roberta, Florian, François - post-docs, ingénieurs et stagiaires avec qui j’ai partagé de très bon moments autour d’un café ou d’une galette saucisse !

Cette thèse s’est construite surtout grâce à des collaborations. D’abord, je tiens à remercier Cendrine, Lucie, Aude et Guillaume du laboratoire ECOBIO pour votre expertise et votre bonne humeur sur le terrain. Cendrine, troisième remerciement mais en même temps tu as été présente sur beaucoup d’aspects et je t’en remercie, grâce à toi j’en connais un peu plus sur les prairies humides et l’écologie en générale. Ensuite, je souhaiterai remercier professeure Tang et toute son équipe pour leur accueil chaleureux au sein du laboratoire AIR. J’ai profondément appris sur l’apprentissage profond pendant ce séjour... Un merci particulier à Jiwen qui fut notre guide à travers les rues, bars et restaurants pékinois.

Une thèse est faite de nombreuses rencontres mais bien que je ne puisse les citer toutes ici je suis très reconnaissant pour chacune d’entre elles car elles m’ont toutes apporté quelque chose dans la maturation de cette thèse ou personnellement.

Je tiens également à remercier tous les copains qui m’ont soutenu, même à distance. Un grand merci à Trackos qui sans le savoir m’a sûrement transmis sa passion pour la Géographie. Max et toute l’équipe de Banc Public qui m’ont permis de préserver ma passion pour le skate. Amina, Simon et tous les copains pendant les années de master. Mais aussi Jo, Macogno et Krikri, et tout les copains de Rennes, de Nantes et d’ailleurs.

Enfin un immense merci à ma famille. À mes parents et mes frères qui ont toujours été présents pour moi et m’ont soutenu depuis le début. Merci aux Elodies, Margot, Mathieu, Laura, Antoine, Anne et Thierry qui ont toujours porté un intérêt pour mon travail. Un merci aux poilues, Shawan et Ainhoa. Et surtout je voudrais remercier celle qui m’accompagne au quotidien et sans qui cela ne serait pas possible, Fanny. Tu m’as offert le plus beau des cadeaux et je t’en serais éternellement reconnaissant.

Je dédie cette thèse à mon petit Lévi, qui m'a encouragé à sa manière.

Sommaire

Introduction générale	1
La télédétection pour l'observation de la terre et l'apport du drone	2
L'observation de la Terre, un domaine interdisciplinaire	10
Problématiques	15
Organisation du document	16
Contributions	17
 Chapitre 1 État-de-l'art : Identification des synergies entre drone et satellite	 19
1.1 Introduction	22
1.2 Méthodes	25
1.2.1 Literature review process	25
1.2.2 Categorization in strategy types	25
1.3 Résultats	28
1.3.1 Emerging trends	28
1.3.2 Strategy types	31
1.3.3 Key contributions of UAV data	37
1.4 Discussion	39
1.4.1 A still under-exploited synergy	39
1.4.2 Towards a stronger exploitation of synergies	42
1.5 Conclusion	45
 Chapitre 2 Le potentiel des synergies drone/satellite pour le suivi des prairies humides	 47
2.1 Introduction	48
2.2 Les problématiques et enjeux du suivi des prairies humides	48
2.2.1 Structure et fonctionnement d'une prairie humide	49

2.2.2	La gestion des prairies humides : entre patrimoine naturel et activités agro-pastorales	52
2.2.3	Les indicateurs de suivi écologique	52
2.3	Méthodologies appliquées aux synergies drone/satellite	53
2.3.1	Les méthodes de changement d'échelle	53
2.3.2	Les réseaux de neurones convolutifs	56
2.3.3	La logique floue	58
2.4	Site d'étude et données	59
2.4.1	Site d'étude : Les marais du Couesnon	59
2.4.2	Collection de données multi-sources	63
2.5	Conclusion	71

Chapitre 3 | Calibration de modèle : Cartographie des communautés végétales de prairie humide **73**

3.1	Introduction	76
3.2	Matériels	78
3.2.1	Study site	78
3.2.2	Field data	80
3.2.3	Remotely sensed data	80
3.3	Méthodes	82
3.3.1	Step 1 : Unsupervised classification of floristic data	82
3.3.2	Step 2 : Reference map : supervised classification of UAV data . . .	83
3.3.3	Step 3 : Estimation of abundances of plant communities	84
3.3.4	Step 4 : Accuracy assessment and optimization	85
3.3.5	Experiments	86
3.4	Résultats	88
3.4.1	Floristic typology	88
3.4.2	Sub-pixel reference map	89
3.4.3	Abundance estimation	90
3.5	Discussion	93
3.5.1	Endmember effectiveness in spectral, spatial and temporal dimensions	95
3.5.2	Synergies among <i>in situ</i> , UAV and satellite data	96
3.5.3	Remote sensing : A proxy of the state of biodiversity	97
3.6	Conclusion	98

Chapitre 4 Fusion de données : Cartographie des dynamiques d'inon-	
dation de prairie humide	99
4.1 Introduction	101
4.2 Matériels	104
4.2.1 Sites d'étude	104
4.2.2 Données	104
4.3 Méthodes	108
4.3.1 Préparation des données	108
4.3.2 Modèle de super-résolution adapté à la fusion de données	110
4.3.3 Évaluation du modèle	113
4.4 Résultats	114
4.4.1 Sélection du modèle	114
4.4.2 Performances de Fusion-UNet	116
4.4.3 Sensibilité spatio-temporelle	117
4.4.4 Transférabilité du modèle	120
4.5 Discussion	121
4.5.1 Les données d'observation	122
4.5.2 Modélisation des dynamiques d'inondation	123
4.5.3 Les dynamiques d'inondation comme indicateurs écologiques	125
4.6 Conclusion	126
Conclusion générale	127
Synthèse des travaux	128
Perspectives de recherche	131
Annexes	135
Bibliographie	161

Table des figures

1	Les différences d'échelles d'observations entre satellite, drone et <i>in-situ</i> . . .	5
2	Illustration des complémentarités d'échelle d'observation entre données <i>in-situ</i> , drone et satellite.	9
3	Localisation du sujet de thèse dans les domaines scientifiques concernés. . .	10
4	Les signatures spectrales caractéristiques de la surface terrestre.	11
5	Cadre conceptuel des <i>Essential Biodiversity Variables</i>	14
1.1	Resolution requirements in the main application fields of remote sensing and data source supply.	23
1.2	Hierarchical decision tree for categorizing UAV/Satellite strategies.	26
1.3	Diagram of UAV/Satellite strategies.	27
1.4	Distribution of studies that address UAV/Satellite synergies.	29
1.5	Distribution of the strategy categories in the period 2008–2019.	30
1.6	Types of UAV optical data used among strategies.	31
1.7	Types of satellites and UAVs used for UAV/Satellite synergies.	32
1.8	Diagram of the “data calibration” strategy.	35
1.9	Distribution of Earth Observation systems by spatial scales.	38
2.1	Structure végétale et flux hydriques d'entrée et de sortie en milieu humide.	50
2.2	Descriptions des motifs de la répartition des espèces végétales le long d'un gradient environnementale.	51
2.3	Fréquence des méthodes exploitées par les différentes stratégies de couplage.	54
2.4	Architectures des <i>Convolutional Neural Network</i> et des <i>Fully Convolutional Network</i>	57
2.5	Architecture du modèle <i>UNet</i> du type <i>Fully Convolutional Network</i>	59
2.6	Localisation du site d'étude.	60
2.7	Illustrations du paysage du marais de Sougéal.	62
2.8	Caractéristiques de la collection de données multi-source.	64

2.9	Compositions colorées fausses couleurs de la série de données multispectrales drone sur une année hydrologique.	67
2.10	Matériel drone utilisé pour les acquisitions multispectrales.	68
2.11	épones spectrales relatives des quatres bandes du Sequoia, ainsi que les bandes correspondantes les plus proches du MSI de Sentinel-2A.	69
2.12	Luminance incidente et réfléchi d'une mesure de quantité décrite en tant que facteur de réflectance hémisphérique-conique.	69
2.13	Répartition schématique des points de contrôle au sol sur un site de 150 ha.	70
2.14	Plan de vol schématique pour assurer un recouvrement latéral entre les prises de vues de chaque ligne de vol.	71
3.1	Location of the Sougéal marsh study site on the Mont-Saint-Michel Bay Natura 2000 site and locations of floristic surveys.	79
3.2	Spectral and spatial features of Sentinel-2, Pleiades and Sequoia (UAV) sensors.	81
3.3	The general workflow for evaluating unmixing approach.	83
3.4	Influence of spatial resolution on the spectral response of survey areas.	87
3.5	Topography and plant communities of the Sougéal marsh.	90
3.6	Color composites of wet grassland plant communities in the Sougéal marsh derived from spectral unmixing.	92
3.7	Fuzzy producer's accuracy and user's accuracy by class and unmixing process.	93
3.8	Scatterplots of UAV vs. satellite reflectance with and without domain adaptation for the near infrared spectral band	94
4.1	Différenciation de la réponse hydrologique en fonction du contexte topographique et pédologique du site.	102
4.2	Localisation et caractéristiques hydrogéomorphologiques des marais de Sougéal et d'Aucey.	105
4.3	Dynamiques hydrologiques mesurées par les sondes piézométriques et acquisitions Sentinel-2 de 2017 à 2021	107
4.4	Schéma général de l'approche de cartographie subpixelique des hauteurs d'eau basé sur Fusion-UNet.	108
4.5	Séquence de transformation pour l'augmentation des données.	109
4.6	Architecture du modèle Fusion-UNet.	111

4.7	Comparaison visuelle des prédictions des modèles <i>UNet-S2</i> , <i>UNet-MNT-S2</i> et <i>Fusion-UNet</i>	115
4.8	Courbe d'apprentissage du modèle <i>Fusion-UNet</i>	116
4.9	Évolution de la métrique d'EAM et du nombre de pixels en fonction des gammes de hauteurs d'eau.	117
4.10	Mise en relation, sous forme d'un nuage de points, entre les prédictions du modèle <i>Fusion-UNet</i> et les références	118
4.11	Prédiction des niveaux d'eau moyens pour chaque compartiment contenant une sonde piézométrique sur la période de validation.	119
4.12	Comparaison d'une image drone vraies couleurs avec la prédiction du modèle <i>Fusion-UNet</i>	120
4.13	Comparaison l'imagerie Sentinel-2 avec la prédiction du modèle <i>Fusion-UNet</i> lorsque le site est sous une couverture nuageuse	120
4.14	Évolution de la métrique d'EAM et du nombre de pixels en fonction des gammes de hauteurs d'eau pour les prédictions sur le marais d'Aucey.. . . .	121
4.15	Mise en relation, sous forme d'un nuage de points, entre les prédictions du modèle <i>Fusion-UNet</i> et les références sur le site du marais d'Aucey.	121
4.16	Résultats d'interpolation des images drones entre 2017 et 2019.	132
4.17	Exemples de paramètres et d'indicateurs mesurés selon les zones et renseignant les fonctions hydrologiques, biogéochimiques et d'accomplissement du cycle biologique des espèces (source : GAYET et al., 2016).	133
18	Chaîne de traitement MAJA	139
19	Les différents chemins du rayonnement solaire qui contribuent à la réflectance TOA, graphique de (RICHTER et al., 2006)	142

Liste des tableaux

1	Classification des systèmes drone basée sur leurs propriétés physiques.	6
2	Scénarios nationaux de vol drone.	6
3	Caractéristiques des différents systèmes satellitaires optiques d'observation de la Terre.	8

4	Comparaison des caractéristiques des systèmes drone et satellite pour la télédétection.	9
1.1	General features of UAV and satellite vectors.	24
2.1	Caractéristiques spectrales et spatiales des bandes de l'instrument multispectrale (MSI) de Sentinel-2.	66
2.2	Domaines spectraux mesurés par le capteur Sequoia	68
3.1	Acquisition details for UAV, Sentinel-2 and Pleiades data.	82
3.2	Codes given to the unmixing processes tested.	86
3.3	Mean confusion matrix between the random forest classification of three plant communities derived from UAV imagery and sampling plots.	89
3.4	Unmixing results by endmember sources for each Sentinel-2 and Pleiades acquisition.	91
3.5	Improvements in spectral calibration of UAV data and unmixing results with UAV endmembers between applying and not applying the domain adaptation method.	95
4.1	Comparaison des performances (EAM_{aj} en m) entre les modèles <i>UNet-S2</i> , <i>UNet-MNT-S2</i> et <i>Fusion-UNet</i>	115
4.2	Comparaison des résultats par validation-croisée du modèle <i>Fusion-UNet</i> entraîné avec jeu d'apprentissage sur 1, 2 et 3 années hydrologiques.	118

ACRONYMES

- CMOS** *Complementary Metal Oxide Semi-conductor*. 65, 67, 145
- CNES** Centre Nationale d'Études Spatiales. 63, 81, 106
- CNN** *Convolutional Neural Network*, Réseau de neurones convolutif. 12, 13, 56, 57, 103
- CSHE** Cartographie Sub-pixelique des Hauteurs d'Eau. 102, 103
- EAM** Erreur Absolue Moyenne. xi, 113–118, 120
- EBV** *Essential Biodiversity Variables*, Variables Essentiels pour le suivi de la Biodiversité. 14, 129
- EO** *Earth Observation*. 21–24, 41, 43–45
- ESA** *European Space Agency*. 64, 81, 106
- FCN** *Fully Convolutional Network*, Réseau de neurones entièrement convolutif. 58, 100, 125, 131
- GNSS** Géolocalisation et Navigation par un Système de Satellite. 66, 69, 106, 123, 137
- H** *Hygrophilic*. 88, 89
- HE** Hauteurs d'Eau. 102, 103, 106, 108–110, 112, 114, 122
- HGMU** *Hydrogeomorphological Unit*, Unités Hydrogéomorphologiques. 101, 104, 105, 109, 113, 118, 122, 123
- HR** *High Resolution*, Haute Résolution. 55, 56, 72, 103
- IGN** Institut National de l'Information Géographique et Forestière. 106, 137
- IMU** *Inertial Measurement Unit*, Unité de Mesure Inertielle. 66, 137
- KIA** *Kappa Index of Agreement*. 84, 85, 89
- LiDAR** *Light Detection And Ranging*. 11, 106, 123, 133
- LR** *Low Resolution*, Basse Résolution. 55, 56, 72, 103

- LTSER** *Long Term Socio-Ecological Research*. 104
- M** *Mesophilic*. 88, 89
- MESMA** *Multiple Endmember Spectral Mixing Analysis*. 84, 87, 94
- MH** *Meso-Hygrophilic*. 88, 89
- MNT** *Modèle Numérique de Terrain*. 7, 65, 69, 72, 100, 102, 103, 109, 110, 113, 137
- MSI** *MultiSpectral Instrument*. xi, 65, 66, 106
- NDVI** *Normalized Difference Vegetation Index*. 12
- OA** *Overall Accuracy*. 84, 85, 89
- PA** *Producer's Accuracy*. 89
- PCS** *Point de Contrôle au Sol*. 137, 143, 144
- PIR** *Proche-InfraRouge*. 67
- RE** *Rayonnement Électromagnétique*. 10, 11
- RF** *Random Forest*. 83, 84, 89, 97
- RMSE** *Root Mean Square Error*. 81, 95
- RS** *Remote Sensing*. 22–24, 37, 76, 77, 88
- SR** *Super-résolution*. 55, 56
- THRS** *Très Haute Résolution Spatiale*. 7–9, 55, 71, 72, 74, 131
- TOC** *Top Of Canopy*. 81, 93
- UA** *User's Accuracy*. 89
- UAV** *Unmanned Aerial Vehicle*. 5, 21, 22, 30, 33, 39, 42, 43, 45, 74, 75, 77, 78, 86
- VHSR** *Very High Spatial Resolution*. 44
- ZAAr** *Zone Atelier Armorique*. 60, 63

INTRODUCTION GÉNÉRALE

La télédétection pour l'observation de la terre et l'apport du drone

L'observation de la Terre par télédétection contribue au développement des sciences de l'environnement et à l'aménagement du territoire via des applications et services de plus en plus nombreux. Elle fournit une information spatialisée fiable et de longue durée qui permet une meilleure compréhension de notre environnement et de son évolution. Elle est un outil essentiel de la Géographie actuelle telle que l'a défini J. Bruhnes :

"La Géographie éclaire [...] le problème des conditions de l'implantation progressive de l'homme et la part des transformations de la planète qui lui revient" ¹

Dans ce contexte, un apport de la télédétection consiste à évaluer l'impact des activités anthropiques sur l'environnement et en cela aide nos sociétés à s'adapter aux grands défis associés : changement climatique, perte globale de la biodiversité, pollutions, risques sanitaires, risques naturels et gestion des ressources. Dans cette thèse, nous souhaitons mettre à contribution les avancées dans le domaine de la télédétection pour la conservation des espaces naturels. Plus particulièrement, nous cherchons la manière dont on peut exploiter la synergie entre drone et satellite comme outil pour la conservation des milieux de prairies humides.

Les nouveaux paradigmes de la télédétection

Le domaine de la télédétection évolue avec les avancées technologiques et tend, aujourd'hui, vers de nouveaux paradigmes : 1) le déplacement des compétences d'acquisition de données de télédétection vers les utilisateurs-finaux grâce aux drones (aéronefs sans pilote à bord) et 2) l'intégration de données multi-sources.

➤ *Les drones : 3^{ème} génération des systèmes d'observation de la Terre par télédétection*

La télédétection a connu une évolution qui peut être perçue à travers trois générations de système d'observation : l'aviation habitée, le satellite et le drone. Les premières images aériennes ont été acquises à l'aide de ballons captifs², de cerf-volants³ ou encore de pigeons-voyageurs⁴ à la fin du 19^{ème} siècle. C'est réellement l'aviation habitée qui

1. Annales de Géographie (1913)

2. Les Nadar, une légende photographique

3. La photographie aérienne par cerf-volant, Arthur Batut (1890)

4. Les nouveautés photographiques (1910)

constitue la première génération car elle permet de couvrir de larges territoires de manière systématique. L'imagerie aérienne a connu un réel essort lors de la Seconde Guerre mondiale. En France, l'Institut Géographique National (IGN) est créé en 1940 pour succéder au Service Géographique des Armées, et amènera l'imagerie aéroportée à être utilisée à des fins civiles. Par la suite, des satellites d'observation de la Terre sont mis en orbite et constituent la seconde génération. Ces systèmes permettent alors de couvrir l'ensemble du globe avec des résolutions spatiales et temporelles en constante progression. Le programme américain *Landsat* est le premier programme d'observation de la Terre par l'espace à des fins civiles. Il débute en 1972 avec la lancée de ERTS-1 (*Earth Ressources Technology Satellite*) et continue aujourd'hui grâce à la mission *Landsat Data Continuity* (ensuite renommée *Landsat-8*) créant ainsi une série de données sur 50 ans et rendant possible l'étude du moyen et long terme par télédétection. Du côté européen, l'ESA (*European Space Agency*) a lancé son premier satellite d'observation de la Terre, ERS-1 (*European Remote Sensing*), en 1991⁵ et continue avec la mission *Copernicus Sentinel*, fort de 6 systèmes satellitaires aux caractéristiques complémentaires. Enfin, depuis le début des années 2000's, le développement technologique des drones a réellement élargi le champ des possibilités en matière de télédétection, amenant à les considérer comme la troisième génération des systèmes d'observation (MILAS et al., 2018). Cette technologie, très accessible en raison de son faible coût et de sa facilité d'utilisation, a déplacé la compétence d'acquisition de l'imagerie spatialisée plus proche de l'utilisateur final. Il est devenu relativement facile pour les scientifiques mais aussi le grand public d'acquérir de la donnée en déterminant où et quand voler. Finalement, les générations de systèmes se succèdent mais ne remplacent jamais leur prédécesseurs (CRACKNELL, 2018). Elles apportent, au contraire, des échelles d'observations (i.e. caractéristiques spatiales, temporelles et spectrales) complémentaires à l'existant (ANDERSON, 2016).

➤ *La télédétection multi-source*

Cette multiplication des sources de données de télédétection est une opportunité pour les scientifiques mais aussi un défi car cela constitue un véritable déluge d'informations plus connu sous le nom de *Big Data* de l'observation de la Terre⁶. L'accessibilité accrue aux diverses sources et la réduction des délais d'obtention des données ont amené les nouvelles études de télédétection à ne plus mobiliser une unique source mais à en croiser

5. ERS 30 years of outstanding achievements, European Space Agency

6. Big Data in Earth Observation, Commission Européenne (2017)

et/ou fusionner plusieurs. Aujourd'hui, chaque système résulte d'un compromis entre les caractéristiques de résolutions, de fauchée ou encore de la qualité du signal (KEREKES & LANDGREBE, 1991). Pour dépasser les limites respectives des systèmes, des données aux caractéristiques complémentaires sont utilisées, par exemple en terme de résolutions spatiales, temporelles et/ou spectrales. Le domaine de la télédétection tend donc vers l'intégration de données multi-sources ce qui facilite le changement d'échelle pour une meilleure caractérisation des surfaces terrestres. Cependant, la multiplicité et l'hétérogénéité des sources de données constituent un défi en terme de traitement de l'information (J. ZHANG, 2010). Aujourd'hui, les avancées dans le domaine de l'informatique, et notamment en intelligence artificielle, ont ouvert de nombreuses voies dans le traitement des données multi-sources de télédétection (GHAMISI et al., 2019) rendant possible l'usage de données très diverses (séries temporelles, drone, radar, hyperspectrale,...).

Dans cette thèse, nous nous intéressons aux synergies entre drone et satellite dans le domaine de la télédétection optique. Ces deux sources de données sont de plus en plus accessibles et présentent des caractéristiques complémentaires. Le drone offre une échelle d'observation unique qui facilite la mise en correspondance des observations de terrain (*in-situ*) et l'imagerie satellitaire (voir Figure 1).

Les complémentarités entre drone et satellite

La synergie entre les systèmes drone et satellite a encore peu été étudiée dans le champ de la télédétection. Pourtant les caractéristiques respectives de ces systèmes montrent un potentiel intéressant.

› Les drones

Il existe une large gamme de types de drones qui peuvent être différenciés selon les propriétés physiques suivantes : portée, altitude, endurance et masse. Le Tableau 1 nous montre l'étendue des caractéristiques possibles, allant des nano-drones jusqu'aux drones stratosphériques. Cette classification ne prend pas en compte la capacité des drones à voler légalement et beaucoup de ces catégories sont à usage militaire. En effet, les réglementations nationale et européenne⁷ définissent les types de drones et les espaces de vols autorisés⁸ en fonction des risques liés aux personnes au sol et au trafic aérien. En France, les scénarios de vols nationaux sont encore en vigueur jusqu'en 2025. La pratique

7. Usages professionnels des aéronefs sans équipage à bord, DGAC (2021)

8. Carte interactive des restrictions pour les drones en catégorie Ouverte.




FIGURE 1 – Les différences d'échelles d'observations entre satellite, drone et *in-situ*.

professionnelle des scénarios S1, S2 et S3 du Tableau 2 est possible sous condition d'avoir une formation théorique et pratique de télépilote, tandis que le S4 nécessite une licence de pilote d'avion. Dans cette thèse, nous nous intéressons donc aux drones légers à très faible portée et de basse altitude, c'est à dire les nano-, micro- et mini-drones. Ces catégories ont connu une forte démocratisation et facilitent l'acquisition de données de télédétection car les drones associés sont les plus accessibles compte-tenu de leur coût et de la législation. Dans la suite du document, le terme "drone" (ou UAV pour *Unmanned Aerial Vehicle*)

réfère donc à ces catégories.

Catégorie	Portée (km)	Altitude (m)	Endurance (h)	Masse au dé- collage (kg)
Nano	<1	100	<1	<0.025
Micro	<10	250	1	<5
Mini	<10	150-300	<2	<30
Faible Portée	10-30	3000	2-4	150
Courte Portée	30-70	3000	3-6	200
Moyenne Portée	70-200	5000	6-10	1250
Moyenne Portée et Endurance	>500	8000	10-18	1250
Basse Altitude à Forte Pénétration	>250	50-9000	0.5-1	350
Basse Altitude Longue Endurance	>500	3000	>24	<30
Moyenne Altitude Longue Endurance	>500	14000	24-48	1500
Haute Altitude Longue Endurance	>2000	20000	24-48	>4500
Stratosphérique	>2000	>20000	>48	30- ?

TABLE 1 – Classification des systèmes drone basée sur leurs propriétés physiques (EVERAERTS, 2009). En vert, les systèmes considérés dans cette thèse.

Scénario	Masse au dé- collage (kg)	Altitude (m)	Distance au télé- pilote (m)	Zone
S1	<25	120	200 (à vue)	Hors-agglomération
S2	<2	120	1000 (hors vue)	Hors-agglomération
	2-25	50	1000 (hors vue)	Hors-agglomération
S3	<8	120	100 (à vue)	Zone peuplée
S4	<2	120	Illimité (hors vue)	Hors-agglomération

TABLE 2 – Scénarios nationaux de vol drone.

La télédétection par drone a émergé dans le début des années 2000's grâce au développement de la robotique, de la miniaturisation des capteurs et de la vision par ordinateur (COLOMINA & MOLINA, 2014). Aujourd'hui, la technologie s'est démocratisée et tend vers une professionnalisation⁹ grâce aux caractéristiques uniques qu'elle propose.

9. Perspectives de développement de la filière des drones civils à l'export (2017)

La télédétection par drone fournit des produits cartographiques, Modèle Numérique de Terrain (MNT) et ortho-images, à très haute résolution spatiale (THRS, <1m) et permet une haute flexibilité dans les conditions d'acquisition. La capacité du drone à acquérir des images à très basse altitude permet d'obtenir ces résolutions sub-métriques et aussi - en volant en-dessous de la couverture nuageuse et lorsque le rayonnement descendant est mesuré - le rend quasi-indépendant des effets de l'atmosphère, c'est-à-dire peu de transformation du rayonnement ascendant. La flexibilité du drone permet de spécifier de nombreux paramètres d'acquisitions - date, heure, fréquence, type de capteur, angle de vue et résolution spatiale - permettant de rendre compte de phénomènes invisibles autrement. Il permet également de survoler des zones dangereuses ou peu accessibles. Cependant, la télédétection par drone a l'inconvénient de couvrir de petites portions de territoires. En effet, la fauchée du drone est restreinte car elle dépend des caractéristiques du capteur, du type de drone et de la législation en cours qui impactent l'étendue de la zone de vol. La faible fauchée impact également les effets directionnels. Finalement, toutes ces caractéristiques font du drone une source de données unique avec une échelle d'observation intermédiaire entre les mesures *in-situ* et l'imagerie spatiale ou aéroportée.

› *Les satellites d'observation de la Terre*

Depuis les premiers satellites d'observation de la Terre mis en orbite dans les années 1970's, les caractéristiques des nouvelles constellations ont évolué pour atteindre des résolutions spatiales, temporelles et spectrales de plus en plus fines. Le compromis de résolution lié aux limites technologiques a entraîné une diversification et a fait ressortir quatre types de satellites : "suivi global", "suivi environnemental", les "nano-satellites" et les satellites "civiles" (voir Tableau 3). Bien que les satellites de "suivi global" apparaissent comme très avantageux, leur faible résolution spatiale est très contraignante pour établir un lien avec les observations *in-situ*. Les satellites "nano" et "civiles" semblent plus adaptés en terme de résolution spatiale mais certains sont peu accessibles à cause de leur coût. Les satellites de "suivi environnemental" sont des systèmes équilibrés dans leurs résolutions et sont libres d'accès. Des plateformes web et API (*Application Programming Interface*) facilitent leur appropriation par les scientifiques mais aussi par le grand public¹⁰. Un exemple probant est la mission *Copernicus Sentinel-2* qui profite énormément à la communauté de télédétection environnementale (PERSSON et al., 2018 ; PHIRI et al., 2020 ; RAPINEL,

10. Sentinel Playground

MONY et al., 2019).

	"Suivi global"	"Suivi environnemental"	"Nano"	"Civil"
Rés. spatiale (m)	> 100	10-100	1-10	< 1
Rés. temporelle (jours)	< 5	5-10	< 5	Sur demande
Rés. spectrale (bandes)	> 20	10-20	< 10	< 10
Couverture spatiale	Globale	Globale	Globale	Régionale
Accès	Libre	Libre	Payant	Payant
Exemple	MODIS	Sentinel-2	PlanetScope	Pléiades

TABLE 3 – Caractéristiques des différents systèmes satellitaires optiques d’observation de la Terre. Les caractéristiques les plus avantageuses sont en vert.

De manière générale, **les satellites optiques sont des systèmes avec des caractéristiques fixes** : ils sont contraints dans une configuration définie (capteur, angle de vue, temps de revisite) et sont très dépendants de la couverture nuageuse. Si certains systèmes comme la constellation *Pléiades* sont plus flexibles, ils restent peu accessibles en raison de leur coût.

› Les complémentarités

Les systèmes drone et satellite ont des caractéristiques qui apparaissent complémentaires (Tableau 4). Cette complémentarité apparaît encore plus forte avec les satellites de "suivi environnemental" dont les données sont très accessibles et qui montrent une échelle d’observation complémentaire à celle du drone. **D’un côté le satellite couvre de larges territoires avec des observations périodiques, tandis que, de l’autre côté, le drone apporte une solution à faible coût pour spécifier les observations satellitaires** (Figure 2) grâce à ses capteurs THRS et sa flexibilité d’acquisition. Les complémentarités d’échelles ont déjà été étudiées entre systèmes satellitaire et/ou aéroporté (MERCIER et al., 2005 ; J. ZHANG, 2010) mais peu d’études s’intéressent à celles entre drone et satellite qui montre pourtant un potentiel de synergies intéressant.




FIGURE 2 – Illustration des complémentarités d'échelles d'observations entre données *in-situ* (violet), drone (vert) et satellite (rouge). a) Les points représentent l'échantillonnage dans l'espace et le temps. Le satellite permet un échantillonnage régulier et systématique, tandis que le drone va permettre un sur-échantillonnage à une période et un lieu précis comme les observations *in-situ* mais avec une plus large couverture spatiale. b) Le drone permet de faire le pont entre les échelles spatiales des observations *in-situ* et satellitaires.

Caractéristiques/Systèmes	Drone	Satellite
Flexibilité	Fort	Faible
Dépendance des nuages	Quasi-indépendant	Oui
Coût THRS	Faible	Modéré
Charge utile	Interchangeable	Permanent
Fauchée	Faible	Large
Contraintes météo. directes	Vent et précipitation	Non
Pré-traitements	Fort	Prêt-à-l'analyse
Opérateur requis	Oui	Non
Gestion des données	Fort	Faible
Législation	Restrictive	Faible

TABLE 4 – Comparaison des caractéristiques des systèmes drone et satellite pour la télé-détection. Les caractéristiques les plus avantageuses sont en vert. THRS : Très Haute Résolution Spatiale

L'observation de la Terre, un domaine interdisciplinaire

L'exploitation des complémentarités entre drone et satellite peut couvrir de nombreux domaines liés à l'observation de la Terre. Cette thèse s'intéresse à la télédétection optique et aux méthodes de changements d'échelles par intelligence artificielle appliquées au suivi des prairies humides. Le sujet de cette thèse est donc à l'interface de trois domaines scientifiques (Figure 3) : la télédétection optique, l'intelligence artificielle et l'écologie de la conservation. Bien que situé au croisement de ces domaines, il reste très orienté sur les sources de données de télédétection et sur leurs apports respectifs. L'intelligence artificielle est choisie pour croiser les multiples sources de données et permettre le changement d'échelle car se sont des méthodes flexibles qui nécessitent peu de paramétrisation des modèles. Les modèles physiques, bien que pertinents, ne sont pas abordés dans le cadre de cette thèse. Enfin, la thématique abordée en écologie de la conservation concerne les prairies humides car ces milieux représentent un enjeu majeur pour le maintien des zones humides dans un contexte agricole.




FIGURE 3 – Localisation du sujet de thèse dans les domaines scientifiques concernés.

Télédétection optique

La télédétection est l'ensemble des techniques qui exploitent le Rayonnement Électromagnétique (RE) pour mesurer les propriétés d'un objet à distance. Le principe de la télédétection peut être conceptualisé comme une modélisation en quatre compartiments : la scène, l'atmosphère, le capteur et l'image. Le modèle de scène définit l'objet d'intérêt

(ex : l'occupation du sol). Le modèle de l'atmosphère correspond à la transformation du RE entre la surface et le capteur. Le modèle de capteur représente le processus de mesure du signal électromagnétique. Enfin, le modèle d'image désigne la méthode d'échantillonnage sur une grille régulière. Les acquisitions de télédétection s'effectuent généralement proche du nadir, c'est-à-dire une orientation du capteur à la verticale du sol, pour éviter des biais radiométriques et géométriques.

La télédétection optique étudie les propriétés optiques d'une scène, c'est-à-dire le RE réfléchi (ou réflectance) dans les longueurs d'ondes de la partie visible, du proche-infrarouge et moyen-infrarouge, soit 440 à 2200 nm. Le capteur optique passif mesure le RE réfléchi sur une scène et provenant d'une source d'énergie radiative naturelle, le soleil. A l'inverse, les capteurs actifs, par exemple le LiDAR (*Light Detection And Ranging*), envoient une onde électromagnétique artificielle et mesurent le retour de celle-ci.




FIGURE 4 – Les signatures spectrales caractéristiques de la surface terrestre (source : *GéoBretagne*)

Dans un monde idéal pour la télédétection, la nature de la surface terrestre pourrait être entièrement caractérisée par les signatures spectrales (Figure 4). En réalité, la complexité des surfaces naturelles, les effets de l'atmosphère et l'ambiguïté des signatures spectrales limitent l'utilisation de la télédétection comme unique source d'information (STEVEN, 1987). En effet, l'interprétation des images est souvent dépendante d'observations au sol, des "vérités terrain" qui apportent des variables de contexte allant au-delà de la mesure radiométrique. Cependant, **établir une relation entre les observations *in-***

situ et satellitaires peut-être difficile à cause de problèmes de correspondance spatiale ou temporelle ou encore de choix sémantique. Le problème du "mixel" - lorsque la résolution spatiale est trop grossière pour interpréter un pixel avec une unique classe - est caractéristique de ces difficultés et montre la nécessité d'une échelle d'observation intermédiaire.

Intelligence artificielle

L'intelligence artificielle est un ensemble de concepts et technologies tentant d'imiter les fonctions cognitives de l'être humain. C'est un domaine basé sur l'informatique, l'algorithmique et les statistiques. Deux sous-domaines de l'intelligence artificielle ont largement contribué à l'automatisation des tâches de photo-interprétation : la vision par ordinateur et l'apprentissage statistique.

La vision par ordinateur est l'ensemble des techniques qui permettent le traitement et la compréhension des images numériques afin d'automatiser des tâches de perception visuelle. Elles permettent l'extraction d'une représentation (ou vecteurs de caractéristiques) utile à la compréhension de l'image. La télédétection a longtemps privilégié les descripteurs radiométriques, tel que le *Normalized Difference Vegetation Index* (NDVI), en tant que vecteurs de caractéristiques expertes. La vision par ordinateur apporte au domaine des descripteurs spatiaux qui caractérisent à la fois la texture et les relations spatiales entre les objets, par exemple les descripteurs d'Haralick (HARALICK et al., 1973) ou *attribute profiles* (PEDERGNANA et al., 2012).

L'apprentissage statistique (ou automatique) donne la capacité aux ordinateurs d'extraire de la connaissance et d'apprendre des modèles à partir de données. On parle de tâche de classification si on recherche une variable discrète (ex : une classe associée à chaque pixel) et de régression pour une variable continue. En général, il y a deux phases. La première est celle d'"apprentissage" qui consiste à estimer un modèle à partir des données. La seconde est la phase d'"inférence" où le modèle appris est utilisé pour prédire avec des données inédites permettant de démontrer la capacité de généralisation du modèle. Trois types de modèles dominent la littérature scientifique en télédétection : les machines à vecteurs de support (SVM) (GEHLER & SCHÖLKOPF, 2009), les forêts aléatoires (RF) (BELGIU & DRĂGUȚ, 2016) et les réseaux de neurones (MA et al., 2019). Les deux premiers sont souvent utilisés avec des descripteurs "experts" générés manuellement, alors que les réseaux de neurones génèrent automatiquement ces descripteurs.

Au début des années 2010's, les réseaux de neurones convolutifs ou CNN (LECUN et

al., 2015), à l'interface entre l'apprentissage statistique et la vision par ordinateur, se sont imposés comme le nouvel état-de-l'art pour une grande partie des tâches de perception visuelle. Un réseau de neurones est l'association, en une architecture plus ou moins complexe, de "neurones élémentaires", ces derniers établissant une combinaison linéaire des données d'entrées sur laquelle on applique une fonction d'activation, de préférence différentiable pour faciliter l'optimisation (ex : sigmoïde, tangente hyperbolique, etc). En ajustant les paramètres de ces neurones (poids des combinaisons linéaires, paramètres des fonctions d'activations) lors de l'apprentissage, le réseau peut approximer une fonction complexe. Dans le cas des CNN, l'opération élémentaire effectuée par les neurones est remplacée par des filtres de convolution qui vont permettre de décrire le contenu spatial des images. A la fin des couches de convolution, on rajoute en général un réseau de neurone classique permettant d'effectuer l'opération souhaitée (classification/régression). Ainsi, l'apprentissage consiste à estimer les paramètres des filtres de convolutions et les paramètres des neurones de la dernière couche permettant de calculer la sortie. L'avantage principal est que, grâce aux filtres de convolutions, cela revient à estimer les descripteurs (spatiaux, spectraux) adaptés au problème posé, conduisant à une solution de bout-en-bout grâce à des modèles qui intègrent dans leur apprentissage l'ingénierie des descripteurs (tâche délicate à réaliser qui nécessite usuellement des experts). En télédétection, comme dans beaucoup d'autres domaines, les CNNs ont un grand succès grâce aux représentations spatiales-spectrales automatiquement apprises qui se montrent bien souvent plus performantes que l'exploitation des descripteurs experts. Dans le chapitre 4, nous présenterons différentes architectures basées sur les CNNs et en proposerons une pour combiner des données drones/satellites.

Écologie de la conservation

La conservation des espaces (semi-)naturels consiste en la protection de la biodiversité animale et végétale, ainsi que la conservation de l'intégrité écologique de leurs habitats, c'est-à-dire préserver les fonctionnalités et continuités des écosystèmes. L'écologie de la conservation est un champ de recherche qui y est dédié. C'est un domaine multidisciplinaire utilisant les principes de l'écologie, la biogéographie ou encore de l'écologie du paysage. Son objectif est de fournir des principes et outils pour la protection, la gestion et/ou la restauration de la diversité biologique. Ce domaine est situé entre la science et la gestion de l'environnement et exige d'agir sans connaissance de tous les faits scientifiques (SOULÉ, 1985). Aujourd'hui, des initiatives internationales telles que la CBD (*Convention*

on Biological Diversity) et l'IPBES (*Intergovernmental Science Policy Platform on Biodiversity and Ecosystem Services*) ont permis la mise en place de stratégies d'adaptation ou de réduction de l'impact anthropique. La CBD a, par exemple, établi les Objectifs d'Aichi, en 2010, qui servent de cadre général sur la biodiversité, mais aussi de plan d'action, pour les Nations Unies.

Traditionnellement, cette science dépend de relevés de terrain qui sont difficiles à appliquer à large échelle à cause de leur coût trop important en ressource et en temps. La télédétection environnementale est une méthode non-invasive qui permet de collecter des données sur des échelles spatiales et temporelles plus larges que ne permettent les méthodes de terrain. Les synergies possibles entre la recherche axée sur la conservation et la télédétection ont été reconnues par les deux disciplines (PETTORELLI et al., 2014). Des initiatives comme GEOBON (*Group on Earth Observations Biodiversity Observation Networks*) permettent de faire le pont entre les communautés, par exemple avec l'introduction des *Essential Biodiversity Variables* (EBVs) destinée à fournir un cadre conceptuel commun aux scientifiques, gestionnaires et politiques. Les EBVs correspondent à un niveau d'abstraction entre les observations brutes de bas-niveau, tel que l'imagerie spatiale, et les indicateurs de biodiversité de haut-niveau utiles à la gestion des territoires (Figure 5).




FIGURE 5 – Cadre conceptuel des *Essential Biodiversity Variables* (PEREIRA et al., 2013)

Cette thèse s'intéresse à la conservation des prairies humides. Une prairie humide est un biotope (i.e. un milieu aux conditions écologiques homogènes) de prairie caractérisé par la présence de plantes herbacées, des joncs, des carex, dont les sols des horizons supérieurs sont influencés par les eaux souterraines ou sont temporairement inondés. Ces milieux d'interface entre écosystème aquatique et terrestre sont souvent des petits objets à l'échelle du paysage (quelques dizaines à centaines d'ha) mais sont le support de nombreuses fonctions hydrologiques, physiques, biogéochimiques et écologiques. Le suivi de la structure de ces milieux et de l'hétérogénéité de celle-ci dans l'espace et le temps est essentiel pour leur conservation car l'homogénéisation peut-être un indicateur précoce de la perte des différentes fonctions, de la richesse spécifique ou encore de la résilience de l'écosystème (SCHMELLER et al., 2018). Un focus sera réalisé sur **deux éléments structurants des habitats de prairies humides : les dynamiques d'inondation et la distribution spatiale des communautés végétales.**

Problématiques

Face à des objets de petites tailles à l'échelle du paysage comme les prairies humides, le drone apporte une information à échelle fine qui peut compléter les observations satellitaires. Ces complémentarités entre les sources de données de télédétection peuvent ainsi aider à répondre à un enjeu fort du suivi des milieux (semi-)naturels. Pour cela, l'exploitation de méthodes de traitement avancées faisant appel à l'intelligence artificielle est requise pour croiser les sources de données et permettent le changement d'échelle. Ainsi, **cette thèse a pour objectif principal d'évaluer l'apport des complémentarités entre drone et satellite pour le suivi par télédétection des prairies humides.** L'hypothèse sous-jacente est que l'utilisation du drone permet une caractérisation et une représentation à échelle fine de la structure de ces milieux. Cet objectif peut être décliné en plusieurs sous-objectifs : 1) Identifier les synergies (ou stratégies de couplage) et les méthodes de changement d'échelle utiles pour exploiter les complémentarités drone/satellite ; 2) Évaluer les synergies et méthodes identifiées ; et 3) Exploiter les complémentarités drone/satellite pour améliorer le suivi des prairies humides. Répondre au premier sous-objectif consistera à dresser un état-de-l'art à travers une revue de la littérature scientifique tandis que, pour répondre aux deux autres sous-objectifs, des expérimentations seront menées sur les sites des marais du Couesnon qui présentent de forts enjeux de suivi pour la conservation du patrimoine naturel.

Organisation du document

Ainsi, pour répondre à ces questions, cette thèse est structurée deux parties composées chacune de deux chapitres. La première partie développe la problématique de l'utilisation des synergies drone et satellite pour le suivi des prairies humides :

- Le premier chapitre dresse un **état-de-l'art des synergies entre drone et satellite en observation de la Terre** à travers une revue de la littérature scientifique et a pour vocation de répondre au premier sous-objectif. Cette étude permet d'identifier les principales stratégies utilisées pour coupler ces deux sources de données et met en évidence des tendances dans l'utilisation de celles-ci et certaines difficultés dans leur application.
- Le second chapitre se focalise sur **les enjeux liés à l'exploitation des complémentarités drone/satellite pour le suivi des prairies humides**. La problématique de la conservation des prairies humides est développée à travers la présentation de leurs rôles (écologique et économique) et de leurs enjeux. Ensuite, une description du site d'étude et du jeu de données multi-sources est réalisée. Enfin, des méthodes de changement d'échelle, identifiées comme pertinentes à notre problématique, sont présentées.

La seconde partie se concentre sur l'application de deux synergies identifiées dans le second chapitre pour leur efficacité et encore inexploitées pour le suivi des prairies humides : la "calibration de modèle" (la donnée drone aide à calibrer un modèle sur les images satellites) et la "fusion de données" (les deux données sont exploitées simultanément). Elles sont appliquées à la cartographie de la végétation et des surfaces inondées, indicateurs fondamentaux pour le suivi de l'état de conservation de ces milieux.

- Le troisième chapitre porte ainsi sur la **cartographie des communautés végétales où les données drones permettent de calibrer un modèle de classification floue**. A travers cette étude, l'objectif est d'évaluer l'apport de l'imagerie drone en tant que donnée intermédiaire entre des relevés phytosociologiques sur le terrain et l'imagerie satellitaire pour cartographier la distribution spatiale de communautés végétales. La donnée drone est évaluée à la fois pour sa capacité à fournir une "vérité terrain" mais aussi à restituer des signatures spectrales considérées comme "pures" utiles au démélangeage des pixels satellitaires.

- Le dernier chapitre porte sur **la fusion des données drone et satellite pour la cartographie des dynamiques d'inondation**. L'imagerie drone est également pensée, ici, comme une donnée intermédiaire qui permet de faire le lien entre des relevés terrain ponctuels (niveau d'eau par piézomètre) et des séries temporelles d'images satellitaires. Le drone apporte une modélisation de la micro-topographie du site, une information essentielle pour modéliser finement la distribution spatiale des surfaces en eau.

Contributions

Comme nous le verrons au cours des différents chapitres, cette thèse a contribué à répondre aux trois objectifs identifiés dans la problématique :

- Démontrer l'apport des complémentarités entre les systèmes drone et satellite dans le champ de la télédétection.
- Formaliser les principales stratégies de couplage - synergies - de données drone et satellite.
- Élaborer des approches de télédétection multi-sources appliquées à l'écologie de la conservation.

Par ailleurs, un jeu de données multi-échelles unique a été produit pour la cartographie des prairies humides et est mis à disposition sur la plateforme *Indigeo* (HOUEY & ALVAREZ-VANHARD, 2021).

Les travaux de cette thèse s'inscrivent dans : le développement de la plateforme CNRS *D2T (Drone, Terrain, Télédétection)* dédiée à l'acquisition d'imagerie drone ; le projet *ALICE (Projet Interreg Atlantic Area)* dont l'un des objectifs est de développer des méthodes de surveillance des habitats du réseau Natura 2000 ; et enfin l'ANR *MATS* qui pour objectif de fournir des approches innovatrices dans la modélisation spatio-temporelle. À travers le dispositif de la Zone Atelier Armorique, ces travaux ont également été l'objet de partenariats et d'échanges d'expertises avec le laboratoire d'écologie ECOBIO (CNRS-UMR 6553) et la communauté de communes du Pays de Dol et de la Baie du Mont-Saint-Michel, gestionnaire de la réserve naturelle du marais de Sougéol.

Ce travail de doctorat a fait l'objet de plusieurs publications dans des journaux internationaux à comité de lecture :





- Alvarez-Vanhard, E. & Houet, T. & Mony, C. & Lecoq, L. & Corpetti, T. (2020). "Can UAVs fill the gap between in situ surveys and satellites for habitat mapping?". In : *Remote Sensing of Environment*, Volume 243, June 2020, 111780. DOI : 10.1016/j.rse.2020.111780
- Jin, X. & Tang, P. & Houet, T. & Corpetti, T. & Alvarez-Vanhard, E. & Zhang, Z. (2021). "Sequence Image Interpolation via Separable Convolution Network". In : *Remote Sensing*, Volume 13, Jan 2021, 296. DOI : 10.3390/rs13020296
- Alvarez-Vanhard, E. & Corpetti, T. & Houet, T. (2021). "UAV & satellite synergies for optical remote sensing applications : A literature review". In : *Science of Remote Sensing*, Volume 3, June 2021, 100019. DOI : 10.1016/j.srs.2021.100019

Et de communications dans des conférences internationales et nationales :

- Alvarez-Vanhard, E. & Houet, T. & Mony, C. & Lecoq, L. & Corpetti, T. (2019). "Satellite multispectral unmixing by drone data for wet grassland habitats classification". In : *4th Open Science Meeting of the Global Land Programme*, Apr 2019, Berne, Switzerland. DOI : halshs-02191100
- Alvarez-Vanhard, E. & Corpetti, T. & Houet, T. (2020). "UAV & satellite synergies for Ecology : a review". In : *GEOBON OSC 2020*, Jul 2020, leipzig, Germany. DOI : hal-02941762
- Alvarez-Vanhard, E. & Houet, T. (2021). "La fusion de donnée drone et satellite pour la cartographie des dynamiques d'inondation en prairie humides". In : *1^{ère} édition des journées Drones & Capteurs embarqués*, Sept 2021, Île d'Oléron, France.

Cette thèse a été financée par l'Université Rennes 2 (école doctorale Société Temps Territoires) et la Région Bretagne. Elle a bénéficié du soutien et a été intégrée aux projets Interreg ALICE et l'ANR MATS. Elle a également été soutenue par l'Université Rennes 2 (action spécifique, soutien à la mobilité doctorale) et la Zone Atelier Armorique. Enfin, elle a été conduite sous la supervision d'un comité de suivi composé de Cendrine Mony, Maître de conférences (Université Rennes 1 / ECOBIO UMR 6553) et Romain Tavenard, Maître de conférences (Université Rennes 2 / LETG UMR 6554).

ÉTAT-DE-L'ART : IDENTIFICATION DES SYNERGIES ENTRE DRONE ET SATELLITE



L'utilisation des complémentarités entre drone et satellite est une approche nouvelle dans le champ de la télédétection. Bien qu'elles soient de plus en plus exploitées, aucune formalisation n'a encore été effectuée pour établir des stratégies de couplage des données (i.e. synergies) drone et satellite. L'objectif de ce premier chapitre est donc d'identifier et formaliser les principales synergies. Nous avons effectué une revue de la littérature scientifique qui a permis de recenser 137 articles publiés dans des journaux à comité de lecture et traitant de ces complémentarités. Ce corpus documentaire a permis l'identification et la formalisation de quatre synergies : la "comparaison de donnée", l'"analyse multi-échelle", la "calibration de modèle" et la "fusion de données". L'état-de-l'art montre les tendances et limites dans leur utilisation. Le rôle joué par la donnée drone est aussi discuté pour mettre en évidence l'apport de celle-ci face aux observations satellitaires.

Cette étude a été publiée sous forme d'article de revue dans le journal *Science of Remote Sensing* sous l'intitulé "*UAV & satellite synergies for optical remote sensing applications : A literature review*".

UAV & satellite synergies for optical remote sensing applications : A literature review

› **D.O.I** : <https://doi.org/10.1016/j.srs.2021.100019>

› **Résumé** : Unmanned aerial vehicles (UAVs) and satellite constellations are both essential Earth Observation (EO) systems for monitoring land surface dynamics. The former is frequently used for its acquisition flexibility and its ability to supply imagery with very high spatial resolution (VHSR); the latter is interesting for supplying time-series data over large areas. However, each of these data sources is generally used separately even though they are complementary and have strong and promising potential synergies. Data fusion is a well-known technique to exploit this multi-source synergy, but in practice, UAV and satellite synergies are more specific, less well known and need to be formalized. In this article, we review remote sensing studies that addressed both data sources. Current approaches were categorized to distinguish four strategies : “data comparison”, “multiscale explanation”, “model calibration” and “data fusion”. Analysis of the literature revealed emerging trends, the supply of these distinct strategies for several applications and allowed to identify key contributions of UAV data. Finally, the high potential of this synergy seems currently under-exploited; therefore a discussion is proposed about the related implications for data interoperability, machine learning and data sharing to reinforce synergies between UAVs and satellites.

1.1 Introduction

The synergy between UAV and satellite data (UAV/Satellite synergy) is essential for understanding the dynamics of the Earth's surfaces (KUENZER et al., 2015). On the one hand, these two data sources produce significant volumes of data contributing to the Big EO Data (P. LIU et al., 2018). Indeed, this exponential production of EO data since the beginning of the 2000s can be partly explained by the increase in the number of satellites in orbit (GHAMISI et al., 2019) and the democratization of UAVs due to the decreasing cost of exploitation (SUN & SCANLON, 2019). On the other hand, each EO system has specific acquisition features that result from a trade-off between resolutions (spatial, spectral and temporal), swath (Figure 1.1) and signal-to-noise ratio (ALAVIPANAH et al., 2010). Pending a new technology with all required features, it is necessary to combine data from different sources to enhance observations. Satellite constellations and UAV for EO provide complementary data interesting for a synergy approach.

Current satellite constellations are numerous and offer different trade-offs that can be grouped into four categories : global monitoring (GM-), environmental monitoring (EM-), nano- and civilian-satellites. GM-satellites in high orbit (e.g. MODIS Terra or NOAA AVHRR) or geostationary satellites have high temporal frequency, which makes it possible to provide daily to infra-hourly data at coarse spatial resolution (>100 m). EM-satellites (e.g. Landsat or Sentinel-2) are balanced in their resolutions, providing high temporal data (few days) with high spatial (10–100 m) and spectral (ca. ten bands) resolutions. These first two categories of satellites provide long-term data time-series, for example, up to 50 years for the Landsat legacy. Next, nano-satellites (e.g. Planet), due to the large number of them placed in low orbit, provide daily global coverage at high spatial resolution (1–10 m) but with a lower data quality that does not satisfy all applications. Finally, civilian-satellites (e.g. Pleiades or Ikonos) are low-orbit spaceborne satellites with sensors that provide data at very high spatial resolution (VHSR; <1 m) but with low spectral resolution (5 bands), and whose cost limits the achievement of global coverage and dense time series. Globally, optical remote sensing (RS) satellites have little flexibility in their acquisition features, for example they are constrained by cloud cover, view angle or acquisition time.

Remote sensing by UAV (RS UAV) has emerged due to the development of robotics, computer vision and sensor miniaturization (COLOMINA & MOLINA, 2014). The openness of data-acquisition skills (MILAS et al., 2018), due to the development of micro-UAVs




FIGURE 1.1 – Resolution requirements (temporal, spatial, spectral and swath) in the main application fields of remote sensing and data source supply. Information based on BRIOTTET et al., 2011, RIIHIMÄKI et al., 2019, TRANSON et al., 2018, and X. ZHU et al., 2018. EO : Earth Observation ; EM : Environmental Monitoring ; GM : Global Monitoring ; sat. : satellite ; LC : Land Cover ; LU : Land Use.

(i.e. weight less than a few kg), changes the paradigm of RS by giving end-users the ability to control acquisition features. Ultraspatial resolution (centimetric to millimetric) and acquisition flexibility are the strengths of RS UAV. The ability of UAVs to acquire data close to the surface allows such spatial resolution but also the ability to be quasi-independent or less-affected by clouds. UAV flexibility allows acquisition conditions to be chosen : the type of sensor, angles of view, spatial resolution, time and frequency of acquisition. The choice of acquisition dates and times is an essential characteristic for certain applications, such as monitoring biological, hydrological or geomorphological dynamics (ABDULLAH et al., 2018 ; FYTSILIS et al., 2016 ; MÜLLEROVÁ et al., 2017). However, RS UAV has the disadvantage of having a smaller swath (a few km²), often because of its low energy reserves and the legislation needed to protect air traffic and

people safety and privacy (CRACKNELL, 2017).

Finally, UAVs offer a different and complementary profile to satellites. There are complementarities in resolution between UAV and satellite acquisitions, particularly in spatial and temporal resolution and swath (Figure 1.1), as well as advantages and disadvantages of using each vector (Table 1.1). For example, although RS UAV has high acquisition flexibility, it requires a ground operator, management of large volumes of data and pre-processing, while satellite data are easily available on web-based platforms and are generally ready to analyze. Furthermore, UAV provides data at a resolution unreachable by satellite but cannot rival the latter’s observed extent and remains constrained in particular territories by national and/or international legislation. Between these two sources of RS data, advantages of the former appear to compensate for disadvantages of the latter, and vice versa, revealing a strong potential for synergies. Moreover, it is considered necessary to use this synergy (VIHERVAARA et al., 2017 ; X. ZHU et al., 2018) to bridge the gap between the abilities of EO systems and the data needs of different application fields (Figure 1.1).

Features/EO sytem	UAV	Satellite
Flexibility	High	Low
Cloud dependence	No	Yes
Direct meteorological constraint	Wind and precipitation	No
Pre-processing	High	Analysis ready data
Operator required	Yes	No
Data management	High	Low
VHSR cost	Low	High
Payload	Interchangeable	Permanent
Legislation	Restrictive	None

TABLE 1.1 – General features of UAV and satellite vectors. Advantageous features are in bold.

To our knowledge, there is no review of the literature that analyzes UAV and satellite synergies. The synergy between multi-resolution RS data has already focused on the complementarity of satellite and airborne data (P. LIU et al., 2018 ; J. ZHANG, 2010), however the complementarities between UAV and satellite are more specific (KAKOOEI & BALEGHI, 2017). We therefore attempt to fill this gap in the scientific literature by

reviewing these synergies. This review categorizes four types of strategy, identify emerging trends and key contributions of UAV data. Then a discussion is proposed to overpass current limits and to fully exploit the potential of this synergy.

1.2 Méthodes

1.2.1 Literature review process

This review aimed to collect, in the most exhaustive way, peer-reviewed articles that dealt simultaneously with UAV and satellite data. To this end, the Google Scholar, Science Direct and Web of Science databases were queried for the period 2000–2019. Articles were first selected using the following query :

$$"UAV_{syn}" AND "Satellite_{syn}"$$

with UAV_{syn} and $Satellite_{syn}$ corresponding to a list of synonymous terms or well-known sensor names (Appendix A). A total of 495 articles were found in this search. By analyzing the entire corpus, articles that mentioned the two data sources but did not deal with them were eliminated. The remaining articles were then filtered to retain only those that dealt with optical data acquired by a passive sensor (panchromatic, RGB, multispectral and hyperspectral) and related to the study of the Earth's surface (excluding studies of the atmosphere and oceans, which have other specific characteristics). Ultimately, the corpus of our study was based on 137 articles published in peer-reviewed journals (Appendix A).

1.2.2 Categorization in strategy types

To guide future studies in the exploitation of UAV/Satellite synergies, we categorized articles of our corpus. Our categorization approach distinguished different strategies according to a three-criteria hierarchical decision tree (Figure 1.2).

The first criterion distinguishes weak and strong synergies (Figure 1.2) based on the degree of data integration. The synergy will be strong if combining the data provides more information than using each data source separately (" $1 + 1 = 3$ ") (Pohl and Genderen, 1998). Conversely, weak synergy, called "data comparison", compares only advantages and disadvantages to determine which data source is the most suitable ("UAV or Satellite")




FIGURE 1.2 – Hierarchical decision tree for categorizing UAV/Satellite strategies.

for the application under study (Figure 1.3A). Data combination in this category is for visual or quantitative comparison but does not help in the final interpretation.

Among the strong synergies (Figure 1.2), the second criterion distinguishes studies whose observation object is the same for both UAV and satellite acquisitions from those whose object is not the same. The latter refers to the “multiscale explanation” strategy, in which the objects observed by UAVs and satellites are at different spatio-temporal scales, generally with a different spatial extent. Information extracted at a finer resolution for a small site is used to explain the information for a larger extent that contains the former. Generally, these studies observe an object precisely by UAV and use satellite data to obtain the more global context in which this object is located. The data are therefore processed separately, and the extracted information is then used together to improve the scientific interpretation (Figure 1.3B).

The last criterion distinguishes studies that develop models (e.g. classification, regression or detection) based on only one data source (“UAV for Satellite”) from those based




FIGURE 1.3 – Diagram of UAV/Satellite strategies.

on both sources (“UAV and Satellite”). The former defines “model calibration” strategy, i.e. one data source is used to calibrate/infer by inference a model based on the other source (Figure 1.3C). Two sub-categories are distinguished : qualitative (e.g. hard classification) and quantitative (e.g. regression or soft classification). The first generally refers to labeling satellite pixels by interpreting UAV data. While the second refers mainly to the use of raw (e.g. reflectance) or derived (e.g. biophysical variables) numerical values from UAV data to calibrate a satellite-based model. In a few rare cases, the roles of UAV and satellite data are reversed.

The last type of strategy, “data fusion”, concerns studies in which new data are produced from a model based on both UAV and satellite data (Figure 1.3D). These methods make it possible to improve the resolution of each data source. There are several ways to fuse data by coupling or complementing spatial, spectral and temporal resolutions. In general, fusion techniques in RS can be classified into three categories according to the degree of fusion (Zhang, 2010) : pixel-level, feature-level and decision-level.

The bibliographical analysis on which this review is based was performed with the help of a reading grid (Appendix A). Using this grid, a variety of information was extracted (e.g. application field, strategy type, data type, methods).

1.3 Résultats

1.3.1 Emerging trends

The recent emergence and growing interest in UAV/Satellite synergies was evident from the bibliographical analysis (Figure 1.4A). The first articles addressing this synergy emerged in 2008, which logically coincided with the democratization of UAVs. Interest in this practice remained modest for several years, accumulating barely 19 articles by 2013. From 2014-2019, the number of studies increased considerably, reaching 37 articles published in 2019.

Reviewed studies were unevenly distributed among the strategy categories (Figure 1.4B). Of the 137 articles, 29% compared only UAV and satellite data and thus exhibited weak synergy. However, when the synergy was strong, “model calibration” strategy was most common, at 48% of the articles (qualitative and quantitative pooled). “Multiscale explanation” and “data fusion” strategies were under-represented (9% and 10% of the studies reviewed, respectively). The undefined category represented only 0,7%, one me-




FIGURE 1.4 – Distribution of studies that address UAV/Satellite synergies. A) Number of articles published from 2008-2019 ; B) Distribution of studies among the strategies identified ; C) Distribution of articles among the main application areas of Earth Observation.

thodological article about multiscale data fusion. Figure 1.5 shows that the UAV/Satellite synergy emerged with the “calibration model” strategy and evolved with it. The “data comparison” appeared later, in 2012, and seemed to evolve slightly. The “multiscale explanation” appeared relatively early but remained punctual. And lately, the “data fusion” appeared in 2014, and although present every year until 2019 it seemed to evolve poorly.

Application fields were also unevenly distributed among the strategy categories (Figure 1.4C). Ecology and precision agriculture were the main fields of application of these




FIGURE 1.5 – Distribution of the strategy categories in the period 2008–2019.

synergies, representing respectively 48% and 26% of the reviewed articles. While ecology was based mainly on “model calibration” strategy, precision agriculture used all strategies, with a slight preference for “data fusion”. Although ecology was the field with the most UAV/Satellite synergies, it had no “multiscale explanation” strategy study for the period studied. Less common fields of applications like geosciences and disaster were frequent over time, unlike applications in archaeology, urban and water resources that were rare and punctual. It can be seen that these less common fields of application were mainly strategies through “data comparison” or “multiscale explanation”.

Optical data used for these synergies came mainly from EM- and civilian-satellites, while nano- and GM-satellites were rarely used (Figure 1.7A). This may be due to the recent release of nano-satellites and to the coarser spatial resolution of GM-satellites than that of UAVs (i.e. the scale factor is too high). Overall, 58% of the studies reviewed used open-source satellite data such as Sentinel-2, Landsat, Gaofen or MODIS, thus demonstrating the contribution of open-source data to this synergy. On the UAV side, multi-rotor UAVs seemed to be used more than fixed-wing UAVs, although a large percentage (30,7%) of the articles did not mention the characteristics of the UAV used (Figure 1.7B). Although, 10% of articles did not mention the types of UAV optical data collected (RGB, multispectral or hyperspectral) it seems that RGB data was more used for strong synergies, and multispectral data for “data comparison” (Figure 1.6). On average, UAVs provided a resolution of 26 cm in a range of 0.2–500 cm depending on the application,

with a median of 8 cm. The scale factor between UAV and satellite data therefore varied from 2-20,000, with a median of 100.




FIGURE 1.6 – Types of UAV optical data used among strategies.

1.3.2 Strategy types

1.3.2.1 “Data comparison” strategy

“Data comparison” is a weak synergy in which data are not combined to improve interpretation. In comparative studies the specific features of UAVs and satellites are identified, and thus their complementary nature is highlighted (Figure 1.1).

Satellites provide data with a larger extent that UAVs cannot achieve (JACOBSEN, 2012; RAU et al., 2014). They cover areas that are difficult for UAVs to access, such as urban areas (MÜLLEROVÁ et al., 2016) or conflict zones (MATOUŠKOVÁ et al., 2016). Moreover, standardization of the pre-processing of satellite data (analysis-ready data) facilitates and accelerates the processing of these data (MÜLLEROVÁ et al., 2016). In addition, UAVs provide low-cost VHSR data that reveal fine patterns such as inter-row and intra-plot variability in vineyards (ALEEM et al., 2019; MATESE et al., 2015), the fine morphology of glaciers (FUGAZZA et al., 2015), and even small water bodies (CÂNDIDO et al., 2016). This VHSR also makes it possible to isolate the study object from areas that could interfere, such as adjacent bare soils (ALEEM et al., 2019) and shadows (RUPASINGHE




FIGURE 1.7 – Types of satellites (A) and UAVs (B) used for UAV/Satellite synergies.

et al., 2019), which can bias the spectral signatures of vegetation. The low cost of the technology makes this vector particularly attractive; however, according to RUWAIMANA et al., 2018 UAVs are cost-effective for acquisitions only for long-term monitoring. Finally, the flexibility of UAVs is a major asset when acquisitions must be made at a specific date or time, as may be the case for precision agriculture to determine the addition of inputs (BRINKHOFF et al., 2018; JUREČKA et al., 2018), or to perform rapid assessment during climate events and natural disasters, such as landslides (CASAGLI et al., 2017).

To conclude the comparison of UAVs and satellites, the choice of data source depends mainly on the scale (extent, resolution) of analysis and the objective of the study. The features required for the study (e.g. ground resolution, temporal frequency, types of acquisition, extent) will guide the choice of data source the most, but it may also depend on the study's organizational and financial conditions (JACOBSEN, 2012). Among these comparative studies, 19% of them considered strong UAV/Satellite synergies the most in their perspectives.

1.3.2.2 “Multiscale explanation” strategy

The “multiscale explanation” strategy combines the observation scales of each data source to interpret the data better. This complementarity was used mainly for natural risk management (33%), geosciences (25%) and archaeology (25%). In natural risk management, this approach enables, for example, relations between the presence of gullies and agro-industrial development to be established (AÏT HSSAÏNE et al., 2011). The satellite is thus used to obtain information about the dynamics of changes in land occupation and use, while the UAV provides fine-scale analysis of the gullies via photo-interpretation and analysis of digital surface models (DSM) generated by photogrammetry (AÏT HSSAÏNE et al., 2011 ; R. WANG et al., 2016). In geosciences, a study of yardangs in a desert environment showed that UAVs can be used to extract morphological features, while satellites provided information about their spatial distribution (Y. ZHAO et al., 2018). In archaeology, satellite imagery is used either for prospection studies (HUANYU DING et al., 2016) or to contextualize an archeological site in its environment (GRUEN et al., 2012 ; LIN et al., 2011), while UAVs reveal details of archeological sites that are invisible even from the ground (LIN et al., 2011) and provide spatial description in three dimensions (GRUEN et al., 2012 ; HUANYU DING et al., 2016). And, an original use of this approach made it possible to study coastal dynamics both physically and socially (PAPAKONSTANTINOY et al., 2019). Satellite data provided information on the evolution of the coastline and geomorphological changes of available beaches, while UAVs counted and characterized tourist infrastructure on these beaches. Finally, through this strategy, satellites make it possible to analyze spatial or temporal patterns, contextualize or locate at a regional scale, while UAVs provide additional information, often in the DSMs produced by photogrammetry, or refine the characterization of the study objects.

1.3.2.3 “Model calibration” strategy

“Model calibration” uses one data source to calibrate a model (qualitative or quantitative) based on the other data source. Among the articles classified as strong synergies, it was the most frequent strategy, with 70% of the articles (“data comparison” excluded) and was widely used by applications in ecology and precision agriculture (Figure 1.4B).

Typically, the qualitative approach allowed satellite-based classification (or post-classification (NHAMO et al., 2018)) to be made using labelled samples from UAV data. Labels can be determined by : 1) photo-interpretation by an expert, 2) thresholding of metrics (e.g.

spectral indices or biophysical parameters) or 3) automated classification (pixel or object oriented) that can be supervised or not. These labels are then used to calibrate supervised classification models. Those produce land-cover or land-use maps and thus provide information about landscape structure like the spatial distribution of habitats, and can help for change detection like deforestation in wooded systems (MARX et al., 2017). For example, SZANTOI et al., 2017 used this strategy to map land cover and land use and quantify loss of primary forest to assess their impacts on orangutan habitat in Indonesia.

The quantitative approach uses numerical values directly from UAV data to calibrate a satellite-based model. Usually, the numerical values extracted are (bio)physical parameters of the surface (e.g. chlorophyll content or aboveground biomass) derived from spectral measurement (S. ZHANG et al., 2019) or from photogrammetrically estimated height models (e.g. tree height (ST-ONGE & GRANDIN, 2019)). But UAV data may also have other natures, such as land-cover rates for sub-pixel validation of soft classification models to estimate the fraction of vegetation cover (MELVILLE et al., 2019; RIIHIMÄKI et al., 2019), for example to improve estimation of flooded areas (XIA et al., 2017) or detection of invasive species (KATTENBORN et al., 2019). Lastly, raw radiometric data can be used directly to calibrate spectral unmixing models. For example, ALVAREZ-VANHARD et al., 2020 used pixels considered to be “pure” (not mixed) extracted from UAV data to calibrate an unmixing model of wet grassland habitats based on Sentinel-2 data.

A specific case of the “model calibration” strategy is the data intercalibration where the spectral signature is modeled (Figure 1.8). The intercalibration needs a reference dataset to calibrate the rest of the dataset. This reference can be the satellite data to calibrate a finer resolution (HOUBORG & MCCABE, 2018) or the UAV data, itself calibrated by in-situ spectroradiometer measurements, to calibrate the satellite data (PADRÓ et al., 2018).

In most cases, UAV data were used in addition to in-situ data. Generally, these validation data were integrated in a nested model. For example, XIA et al., 2017 used in-situ surveys to validate an object-oriented UAV classification that then facilitated selection of “pure” pixels for a satellite-based spectral unmixing model, as well as to obtain independent training and validation data. However, 32% of the studies used UAVs to replace in-situ surveys, and thus depended only on interpretation of VHSR images. Some studies compared the influence of the use of in-situ data to that of UAV data. For example, FORSTER et al., 2018 demonstrated that UAVs can be used with confidence to provide ground truth for producing thematic maps. SPENCE et MENGISTU, 2016 showed that




FIGURE 1.8 – Diagram of the “data calibration” strategy.

an intermittent-stream detection model calibrated with in-situ data was more accurate than a UAV-calibrated model, but the latter was more robust. Finally, MELVILLE et al., 2019 and LIANG et al., 2017 were specific cases who calibrated a UAV-based model with satellite data.

1.3.2.4 “Data fusion” strategy

“Data fusion” can be considered as the strongest synergy because it tries to use the features of each data source fully to create new data. This strategy, although little used, was nonetheless explored by the precision agriculture field (Figure 1.4), which aims to extract the land cover and biophysical features of vegetation cover at a fine resolution.

Two-thirds of “data fusion” strategy articles were pixel-level studies with the objective of creating an enhanced-feature dataset by combining one or more resolutions of each source. The most basic method is the densification or completion of time series. For

example, using a multi-source time series NIKOLAKOPOULOS et al., 2019 mapped evolution of the coastline, and FIRLA et al., 2019 estimated intra-seasonal variations in the penguin population in Antarctica. More elaborate approaches combine two dimensions :

- Spatial-spectral (also known as super-resolution (YUE et al., 2016)) : JENEROWICZ et al., 2017 used the Gram-Schmidt pansharpening method with Landsat imagery to improve the spectral resolution of low-cost UAV sensor imagery and thus significantly improve the accuracy of land-cover classification. HASSAN-ESFAHANI et al., 2017 improved the spatial resolution of Landsat imagery by a factor of four through supervised learning using UAV image patches. Thus, high-frequency details in each band and their derivatives can be recovered from Landsat imagery.
- Spatial-temporal (X. ZHU et al., 2018) : Pioneering studies demonstrated the contribution of spatial-temporal fusion, especially the Spatial Temporal Adaptive Reflectance Fusion Model algorithm (GAO et al., 2006). GEVAERT et al., 2014 combined UAV hyperspectral data with a Formosat-2 time series to derive biophysical parameters (leaf area index and chlorophyll content) of potato crops and make consistent predictions with fine spatial patterns. In the same vein, H. LIU et al., 2019 fused a sparse UAV time series with a denser time series from the Planet nano-satellite to estimate grassland forage production finely.
- Spectral-temporal : GEVAERT et al., 2015 used Bayesian theory to fill in missing spectral information in multispectral satellite data with hyperspectral data from a UAV. The Spectral-Temporal Response Surface model designed in their study provided continuous spectral reflectance at high temporal frequency. The results generated correlated well with spectral measurements in the field ($r = 0.953$) and allowed for derivation of biophysical variables (leaf area index and chlorophyll content) that were consistent with the observations.

The remaining one-third of the studies used a feature-level fusion approach with a less classic approach. For example, KAKOOEI et BALEGHI, 2017 used different UAV and satellite view angles to assess post-disaster damage on buildings. Using oblique images obtained by the UAV, they extracted features on building facades, while satellite imagery provided features on roofs. These features were fused to estimate damage levels. Another application in change detection used a method for near real-time detection (FYTSILIS et al., 2016) that compared features of UAV data to those of historical satellite data in order

to detect potential changes in a territory. The method developed was presented as being robust to differences in spatial and spectral resolution and misregistration issues. Finally, decision-level fusion, although having interesting potential (ATKINSON, 2013), was not used at all with UAV and satellite data.

1.3.3 Key contributions of UAV data

In this synergy, UAVs played a “bridging role” by complementing and magnifying the potentials of in-situ and satellite data (Figure 1.9). UAVs provided new data that can be acquired only by this vector and thus provided a single intermediate observation scale. This characteristic allowed UAVs to play three types of roles according to the strategies : (1) explanation, (2) validation and (3) completion of satellite data.

Explanation was a major use of RS UAV within the UAV/Satellite synergy. It consisted of providing complementary data (e.g. VHRS or DSM) to reveal inaccessible details or unseen from space or on the ground. In-situ observations made by experts or a network of sensors are generally precise but punctual (GAMON, 2015), while satellite observations cover large areas but have a resolution that remains too low to be interpreted properly without in-situ information. Although these two observation scales complement each other, pairing them remains however uncommon because of the difference in surface of the areas they observe (ALVAREZ-VANHARD et al., 2020). Between the two scales, UAVs provide spatially explicit local data that reveal spatial patterns of prime importance to study processes using satellite measurements (FAWCETT et al., 2020 ; GAMON, 2015). This role of UAVs was particularly highlighted in the “multiscale explanation” strategy, but it also forms the basis of all strong UAV/Satellite synergies.

The validation role consisted of using UAV data as “ground truth” (or “drone truth”) and relied on UAVs’ ability to explain satellite data. This was the main purpose of UAV data in this synergy in particular via the “model calibration” strategy. UAV data can be used in synergy with in-situ data in a nested model or can replace them. As mentioned, UAV data can replace in-situ observations for applications in which the object to be detected was clearly identifiable, such as water bodies (GÓRAJ et al., 2019 ; TSCHUDI et al., 2008), the fraction of plant cover (BIAN et al., 2016) or certain invasive species (ELKIND et al., 2019 ; MARTÍNEZ-SÁNCHEZ et al., 2019). Indeed, UAVs provided spatially explicit data fine enough for experts to identify elements of the landscape directly. Moreover, UAVs had the advantage of covering modest to large areas quickly and can easily reach the least accessible environments. In the current era of data-driven models




FIGURE 1.9 – Distribution of Earth Observation systems by spatial scale (resolution and spatial extent), based on Riihimäki et al. (2019) (Riihimäki et al., 2019). Ultrahigh : <1 m, High : 1–10 m, Medium : 10–100 m, Coarse : >100 m.

developed by non-parametric supervised learning methods (e.g. random forest, support vector machine or neural networks), UAVs can play a key role in providing “ground truth”. Indeed, validation data are critical in these methods, but the heavy logistical involvement required for large-scale acquisitions reduces the potential of such approaches. UAVs provide an affordable solution for acquiring ground-truth data to analyze or calibrate satellite data. CARBONNEAU et al., 2020 showed that this approach is valid, robust and allows for hydrogeomorphological analysis to be extended to the regional scale by applying locally trained models to new satellite data. The transferability of the models needs to be assessed more widely in terms of seasonal and interannual variability and also between different

geographical areas. Nonetheless, this approach should be tested on other applications.

Lastly, the completion role of UAVs lied in their ability to fill gaps in satellite data. Spontaneous UAV acquisitions made it possible to fill temporal gaps in sparse satellite time series (MENGMENG et al., 2017) and to produce change-detection maps in near-real time (FYTSILIS et al., 2016). It can also fill spatial gaps, e.g. in which optical satellite data were degraded by cloud cover. UAVs can provide data under clouds, which is particularly useful in tropical areas where cloud cover is frequent for long periods of the year. Through fusion methods, UAVs can improve spatial, temporal or spectral resolutions of satellite data by providing a complementary dimension. These methods were still rarely used at the scales of observation provided by UAVs, but the first applications (GEVAERT et al., 2015; GEVAERT et al., 2014; H. LIU et al., 2019) show high potential that can open the field toward new applications that require very high resolutions, such as monitoring hydrological regimes, phenological traits of plants or degradation states of environments.

1.4 Discussion

1.4.1 A still under-exploited synergy

The analyses made in this paper have highlighted interesting synergies between UAV and satellite data. However, to our opinion, current synergies are not fully exploited and one can go a step forward to go beyond the validation purpose of UAV data and exploit together UAV and satellite data. Today this mutual exploitation is limited to some studies mainly for the two following reasons : interoperability is not obvious and UAV/Satellite synergies often answer to a specific use case without the aim of fully exploring its potential. These two points are discussed below.

1.4.1.1 Data interoperability remains challenging

The quality and interoperability of satellite data are guaranteed by the Committee on Earth Observation Satellites (CEOS), whose original function was to standardize data formats and ensure the validation, inter-calibration and inter-comparison of satellite products. For UAV data, however, there is no guarantee of data quality since the data-acquisition skills are transferred to users. Acquisition and pre-processing protocols can vary among users and sensors, which does not guarantee consistent data, thus making multi-source interoperability difficult. Ensuring this interoperability is an important chal-

challenge because models based on the synergy between UAV and satellite data are sensitive to the quality of the input data (BELGIU & STEIN, 2019; CARBONNEAU et al., 2020; MENGMEG et al., 2017). Intercalibrating data (geometric and radiometric) and estimating uncertainty in multisource models are therefore essential steps to ensure the quality of the results from this synergy.

Misregistration between data from one or more sources causes errors in analysis at different spatial and temporal scales. To ensure the quality of analyses, sub-pixel geometric intercalibration is necessary (FYTSILIS et al., 2016; POHL & GENDEREN, 1998). Although pre-processing UAV and satellite data provides sub-pixel inter-band and inter-date co-registration, their different resolutions imply calibrations of different orders (centimetric and metric, respectively). Methods for automatically georeferencing multisource data can ensure this consistency. For example, the multi-scale SIFT (Scale-Invariant Feature Transform)-RANSACT (RANDOM Sample Consensus) methods (OH et al., 2011) automatically generate tie points to locate the data correctly using an affine transformation, or optical flow methods (BRIGOT et al., 2016) which do not use tie points and are effective for multimodal datasets.

Using the full optical spectrum (multispectral or hyperspectral) through different sensors requires ensuring consistency between these radiometric measurements, which remains a challenge in itself. Indeed, reflectance values may vary depending on the type of sensor (wavelength, vignetting), acquisition protocol (angle of view, ground resolution), environmental conditions (atmosphere, topography) and corrections made to the data (SCHAEPMAN-STRUB et al., 2006). For example, the bi-directional reflectance distribution function of the surface can be ignored and considered as Lambertian for observations at low spatial resolution (satellite), which is not the case for UAV observations, whose high variability in reflectance values is due to the heterogeneity in the optical properties and 3D structure of the surfaces, which leads to heterogeneous observation geometries (STARK et al., 2016; STOW et al., 2019). Moreover, low-cost UAV sensors may have limitations or defaults that are not yet well known and that make it difficult to combine them with satellite data (FAWCETT et al., 2020). These differences in reflectance measurements between UAV and satellite observations must therefore be considered because they influence multi-scale models. In the absence of absolute reflectance measurements, radiometric intercalibration is an effective solution for multi-sensor interoperability as seen in the section “Model calibration” strategy.

Despite data correction and intercalibration, measurement uncertainty can persist and

must be considered as it propagates into the scales of fusion or nested inference models. For example, SOLAZZO et al., 2018 used Monte-Carlo simulations to estimate uncertainty in a dune-volume prediction model based on UAV data and express it in a satellite-based model.

Up to now, these questions of interoperability and intercalibration have strongly limited the nature of exploitation of the synergies between UAV and satellite images.

1.4.1.2 An unexplored potential

From our review, it seems that the potential of the UAV/Satellite synergy is currently not fully exploited : (1) several scientific fields do not take enough advantage of this synergy, (2) the capacities of the different EO systems are under-exploited, and (3) stronger synergies are less used.

Ecology and agriculture scientific fields have been mainly involved in the exploitation of UAV/Satellite complementarities, unlike other earth observation fields (geosciences, disaster, archaeology, water resource or city monitoring) that generally require less important resolutions (Figure 1.1). However, a breakthrough can be anticipated in these less common fields. For example, ANTOINE et al., 2020 highlight the challenge of combining different observation scales for geosciences and disaster purposes, and identify combined workflow between space-based and UAV data as a proper solution.

EO systems used in this synergy are under-exploited, in particular for UAV capacities. First, EM-satellites are most used, certainly because these data are open (e.g. Sentinel-2, Landsat and Gaofen) and their observation scales provide good complementarities with UAV data. Yet, nano- and civilian-satellites are interesting in particular for the “data fusion” strategy in view of similarities and the low scale factor with UAV data, but their cost remains a barrier. Then, the use of UAV data is too limited to RGB, leaving the high potential of optical RS still unexploited. Specific characteristics of the observation geometry remain little used but have an interesting potential to improve characterization of surface reflectance properties, such as anisotropy (MARTONCHIK, 1994 ; ROOSJEN et al., 2017 ; SU et al., 2007). Similarly, optical properties of the surface observable by multispectral sensors vary and are related to acquisition conditions (e.g. wavelengths, viewing angle, ground resolution) ; thus, the flexibility of UAVs does not yet appear to be fully exploited and new applications that use both UAVs and satellites that may lead to new types of synergies remain to be discovered and developed. Lastly, technological advances related to the installation of LiDAR and hyperspectral sensors on satellites or UAVs will

also increase the potential of this synergy.

Currently, this synergy remains in the “UAV or Satellite” and the “UAV for Satellite” paradigms. The former corresponds to the “data comparison” use case, whose purpose is well summarized by the question of ABDULLAH et al., 2018 : “Can UAVs replace Satellites?”. This purpose can finally be seen as opposed to a synergy. The latter paradigm refers to the “model calibration” strategy using UAV data for a validation purpose. Although this strategy is efficient to answer scientific questions, we think this way is not optimal and doesn’t keep information from the multiscale observations. Actually, UAV data is often reduced to a label or up-sampled to satellite spatial resolution losing fine spatial patterns. The strongest synergies “multiscale explanation” and “data fusion” are strategies preserving information from each source, and should be more explored to move towards a new paradigm : “UAV and Satellite”.

1.4.2 Towards a stronger exploitation of synergies

From the previous section one observes that UAVs have completed satellite images for validation, completion or explanation purposes but these two sources of data have not that much been used together for fusion issues. This is to our opinion due to the fact that :

- The questions of interoperability are tricky ;
- Usually UAV are acquired for a specific application and no more exploited then ;
- Fusion requires advanced methodologies not easily accessible.

From this latter point, it is important to outline that since several years, spectacular advances in machine learning and especially with deep neural networks have enabled a breakthrough in the processing of massive and heterogeneous spatial data.

1.4.2.1 Machine learning for UAV/Satellite fusion

The idea behind deep learning is to construct a neural network composed of a large number of layers, enabling to model very complex relations between inputs (multi-source data) and outputs (estimation of parameters, labels, etc). Though the idea is old, the progresses in the recent years come from the fact that we have now enough data and associated computational resources to train such complex networks (and then to condition

the optimization processes associated with the large number of calibration parameters to estimate). In addition, some theoretical progresses on the definition and optimization of such networks have opened a wide range of applications. The reader can find in (YAN et al., 2015) a general introduction to deep learning.

As for the processing of spatial data, the state of the art network for assigning a label to an image is the well-known CNN (Convolutional Neural Network). Since then, many architectures, either adapted to assign a label to each pixel (Fully Convolutional Networks and variants (LONG et al., 2015)), to deal with unstructured data (QI et al., 2017) or to time series (**fazle_lstm_2017**) for example have been proposed. More recently, the community is also focusing on the fusion of complex data, as for example ZHENFENG et al., 2018 in the context of satellite images. The great quantitative improvements have encouraged researchers to explore the fusion of heterogeneous sources and some studies using UAV have already been proposed (BARRERO & PERDOMO, 2018; W. LIU et al., 2019). Obviously we encourage the community to explore this point and to fully exploit the synergies between UAV and satellites.

Associated with these new methodological insights, the open access to data is also a trend the community has to follow.

1.4.2.2 Facilities for multisource workflow

The UAV/Satellite synergy has the potential to overcome current limitations of EO systems. However, the complementarities of the data sources are not sufficient for this potential to be fully exploited. The combined workflow between UAV and satellite data must be facilitated and adapted to the Big EO Data. To achieve this, facilities are needed to ensure the Findability, Accessibility, Interoperability, and Reusability (FAIR principles) (WILKINSON et al., 2016) of data and methods. In this section, we discuss current initiatives that contribute to this vision of an open and reproducible EO science.

There is a trend to the openness of satellite data which are now easier to find due to the multiplication of downloading platforms based on the model of ESA's Copernicus program. Conversely, sharing of UAV data is not following this trend to the same degree. The difficulty in sharing UAV data is understandable given the large number of suppliers who acquire data with specific objectives. The lifespan of UAV data is therefore currently limited to a single use, although it could be used more widely for global applications if they would become open-access. Nonetheless, initiatives such as Open Aerial Map or the GEOSS platform allow UAV data to be shared freely. At European level, the

INSPIRE directive requires public authorities to make their environmental spatial data open and accessible on the internet. This directive also concerns public bodies producing ortho-imagery by UAV. For example in the West of France, the spatial data infrastructure Indigeo contributes to this effort by sharing UAV data among other geodata. However, the free sharing of data raises the issue of personal data and privacy that are accessible through VHSR UAV imagery, i.e. information allowing the direct identification of natural persons (e.g. identifiable faces), or indirect (e.g. number plates) and private property. For example, in the European Union, the diffusion of data must be done in conformity to the General Data Protection Regulation (GDPR) which prohibits the diffusion and processing of personal data without the consent of the person, owner or manager of a property. Lastly, data sharing must be accompanied by explicit description of the acquisition conditions based on the model of the Spatio Temporal Asset Catalog initiative (STAC), which facilitates queries of spatial data. Indeed, as mentioned, interoperability must also be achieved for the radiometric measures, which depend on the acquisition conditions. These metadata and their meanings are widely transmitted for satellite products but, again, it is not yet standard for UAV products.

Finally, infrastructure such as EO Data Cubes (EODCs) facilitate and formalize the integration, processing and analysis of Big EO Data, thus contributing to the reproducibility of EO science (GIULIANI et al., 2019). EODCs provide an architecture that brings together different spatial databases to facilitate data storage and manipulation. Many initiatives have emerged this decade, such as Open Data Cube (LEWIS et al., 2017), Google Earth Engine (GORELICK et al., 2017), JEODPP (SOILLE et al., 2018) or Rasdaman (BAUMANN et al., 2019). However, each initiative has its own architecture, which is not compatible with the others. OpenEO addresses this problem by providing an API (Application Programming Interface) that generalizes connections between users and EODCs. Recently, in addition to these initiatives, code sharing on platforms such as GitHub has contributed greatly to strengthening this synergy by contributing to the development of new algorithms and making it possible to test them on new datasets. Although this practice remains rare, some applicable contributions to this synergy exist (CARBONNEAU et al., 2020 ; TAN et al., 2019).


1.5 Conclusion

The scientific literature was reviewed to guide future studies that wish to use the strong complementarities between UAVs and satellites. Overall, 137 articles published in peer-reviewed journals were collected. This corpus of literature made it possible to identify four main strategies : “data comparison”, “multiscale explanation”, “model calibration” and “data fusion”. These four types of synergy helped in filling the gap between sensor capacities and the data needs in EO applications. However, this categorization was specific to the corpus of this review and will aim to evolve with future applications. In just a few years, this synergy emerged with various strategies and applications. Through this bibliographical study highlighted the following trends :

1. Ecology was the main application area that used this synergy and used mostly the “model calibration” strategy.
2. A significant part (29%) of UAV/Satellite synergies were weaks (“data comparison”).
3. “Multiscale explanation” and “data fusion” strong synergies were under-exploited.
4. RS UAV can replace in-situ surveys for basic applications.
5. UAV capacities offered greater potential than what was currently used.

We concluded that the UAV/Satellite synergy evolved quickly and provided proper solutions to answer scientific questions in need of multiscale observations. However, this potential was under-exploited using mainly UAV data for validation purposes. We suggest to the scientific community to explore “multiscale explanation” and “data fusion” strategies to fully exploit these multiscale data. Advances in multisource interoperability, data sharing and machine learning will help move towards these stronger synergies.

LE POTENTIEL DES SYNERGIES DRONE/SATELLITE POUR LE SUIVI DES PRAIRIES HUMIDES



2.1 Introduction

Pour être réussie, une application de télédétection doit avoir des objectifs compatibles avec le potentiel technique. Ici, nous analysons le potentiel des synergies drone/satellite, vu précédemment, pour le domaine de l'écologie de la conservation, appliqué à la gestion des prairies humides. Ce chapitre aborde donc en détail les aspects thématiques et méthodologiques pour identifier des points de correspondance. Dans un premier temps, sont mis en évidence les problématiques et enjeux liés aux suivis des milieux de prairies humides. Plus particulièrement, les paramètres étant à la fois des indicateurs de l'état de conservation du milieu et mesurables par télédétection sont identifiés. Ensuite, le site d'étude et ses enjeux sont présentés. Dans un deuxième temps, les méthodes de changement d'échelle identifiées comme adaptées à nos problématiques sont explicitées. La collection de données multi-sources nécessaires aux expérimentations est présentée dans une dernière partie.

2.2 Les problématiques et enjeux du suivi des prairies humides

Les prairies humides sont des milieux "ouverts", constituées d'une végétation herbacée et caractérisées par l'engorgement temporaire en eau du sol où elles sont installées. En France, elles sont considérées principalement comme des milieux humides¹ ou zones humides au sens de la définition de la convention de Ramsar :

[...] des étendues de marais, de fagnes, de tourbières ou d'eaux naturelles ou artificielles, permanentes ou temporaires, où l'eau est stagnante ou courante, douce, saumâtre ou salée, y compris des étendues d'eau marine dont la profondeur à marée basse n'excède pas six mètres.

Ces milieux sont reconnus pour leurs fonctions de régulation hydraulique (ex : régulation des crues, recharge des nappes), de maintien de la qualité du milieu (ex : régulation des nutriments, stockage des micro-polluants), de régulation climatique (ex : stockage du carbone) ou encore pour leurs fonctions biologiques (ex : biodiversité, corridors écologiques). Ils apportent également une valeur économique (pâturage et fauche), scientifique, récréative (ex : loisirs naturalistes, chasse) et paysagère. De nombreuses études ont permis d'évaluer la valeur des services écosystémiques des habitats humides et de concrétiser ainsi la perte monétaire importante engendrée par la dégradation ou la disparition des services

1. *Milieux humides ou zones humides ?* (2020)

et fonctions qui y sont associés (COSTANZA et al., 1997 ; SCHUYT & BRANDER, 2004). En France métropolitaine, les prairies humides couvrent environ 1 million d’hectares, soit près des deux tiers des milieux humides majeurs². On les retrouve en général à proximité des cours d’eau (prairie en zone alluviale), parfois dans une dépression (dépressions limoneuses, dépressions en montagne, prairies humides dunaires). Par l’importance de leur superficie, elles représentent un enjeu majeur pour le maintien des zones humides dans un contexte agricole plus respectueux de l’environnement.

2.2.1 Structure et fonctionnement d’une prairie humide

La structure et le fonctionnement de l’écosystème de prairie humide sont principalement régis par divers paramètres de l’hydropériode (Figure 2.1). L’hydropériode est liée aux variations de flux hydriques et correspond à l’évolution dans le temps du niveau d’eau libre à proximité immédiate de la surface du sol, en dessous ou au-dessus de celle-ci. Les paramètres en question sont la durée et la période d’inondation, la date(s) ou périodes d’exondation, la hauteur d’eau et également la durée de la période de saturation du sol en eau et donc d’anoxie (BONIS, 2014).

Les conditions hydriques et les variations du sol amènent à une alternance des périodes d’inondation et d’assec qui sont caractéristiques des zones humides. Cette alternance permet aux végétations aquatiques et terrestres de coexister le long du gradient d’hygrophyllie (Figure 2.1). On aura tendance à retrouver une végétation mésophile dans les zones les plus hautes, une végétation méso-hygrophile dans les zones partiellement inondées et une végétation hygrophile dans les zones inondées en permanence. Cependant, on peut retrouver sur les mêmes emplacements différents types de végétation. Dans ce cas, les espèces utilisent l’habitat différemment. Ce sont les différents paramètres de l’hydropériode qui vont agir comme filtre en fonction du cycle des plantes et donc sélectionner les espèces de façon particulière (BOUZILLÉ et al., 2001 ; CASANOVA & BROCK, 2000 ; VIOLLE et al., 2005). Ce gradient environnemental est propice à une stratification de la végétation sous forme de ceintures de communautés végétales avec des transitions graduelles, décrites comme des écotones, où une communauté est progressivement remplacée par une autre. Ainsi, les motifs spatiaux de la répartition des espèces végétales (comme des surfaces inondées) sont flous, rendant leur délimitation dans l’espace difficile (Figure 2.2).

Un habitat de zone humide est soumis à des processus d’évolution naturelle qui le

2. Centre de ressource des milieux humides (2015)




FIGURE 2.1 – Structure végétale et flux hydriques d'entrée et de sortie en milieu humide.

conduisent sur le long terme à disparaître au profit d'un habitat moins humide. Ce phénomène de succession écologique est principalement mené par des processus d'atterrissement et de comblement liés à l'accumulation progressive de la matière organique au sol. Cette accumulation de biomasse non dégradée augmente le niveau du sol, diminuant ainsi les niveaux d'eau. Des espèces moins hygrophiles peuvent alors se développer et on observe également une colonisation par des ligneux hygrophiles tels que le saule ou l'aulne. Le développement de cette végétation accélère encore le phénomène de comblement en produisant davantage de biomasse jusqu'à la fermeture du paysage. Pour empêcher ce processus, des activités agricoles de fauches et de pâturages sont maintenues.

Finalement, la structure et le fonctionnement des prairies humides sont principalement liés à leur fonctionnement hydrologique mais sont maintenus grâce aux pratiques agricoles (KOŁOS & BANASZUK, 2018). Caractériser les différents paramètres de l'hydropériode est susceptible de fournir des éléments d'interprétation décisifs pour apprécier, comprendre et anticiper l'effet du régime hydrique sur la diversité végétale et sa dynamique (BONIS, 2014) mais aussi la diversité animale, comme la présence d'oiseaux migra-




FIGURE 2.2 – Descriptions des motifs de la répartition des espèces végétales le long d'un gradient environnemental (FEILHAUER et al., 2020). (a) et (b) Distributions des espèces le long d'un gradient environnemental. Les probabilités d'occurrence des espèces changent en fonction des exigences écologiques des espèces et des processus de la communauté. (c) Description de la composition des espèces sous forme de communautés végétales distinctes (classes).

teurs (SCHAFER-SMITH et al., 2018 ; SKAGEN & KNOPF, 1994 ; ŻMIHORSKI et al., 2016). L'étude de ces paramètres est également essentielle pour mieux comprendre les fonctions hydrologiques des prairies humides, telles que la rétention des inondations, la recharge des nappes souterraines (HAYASHI et al., 2016) et les cycles des éléments biogéochimiques (BATES et al., 2014). Enfin, du point de vue des activités agro-pastorales, les conditions hydrologiques influencent la capacité de production de biomasse de la prairie en limitant la croissance végétale ou par des changements de composition floristique (BONIS, 2014). Elles déterminent également le calendrier de l'activité de pâturage et de fauche réalisées en condition sèche.

2.2.2 La gestion des prairies humides : entre patrimoine naturel et activités agro-pastorales

Les enjeux de gestion d'une zone humide dont le fonctionnement naturel est modifié par des facteurs anthropiques sont complexes. Il s'agit principalement de réduire les impacts liés aux activités anthropiques en mettant en place des mesures de gestion qui maintiennent le mieux possible l'habitat de zone humide fonctionnelle sur le long terme. Ce maintien artificiel permet de bloquer les processus naturels et donc les phénomènes de successions écologiques. Bien que discutable sur le plan éthique, on peut considérer qu'il est de notre responsabilité de conserver les milieux humides, dans un contexte de régression forte de leurs superficies à l'échelle globale. Le risque est la perte à la fois d'une biodiversité inféodée au milieu, d'habitats, de corridors écologiques et de nombreux services écosystémiques, aux conséquences difficilement réversibles.

Dans le cadre de la restauration ou de la conservation d'une zone humide, la mesure de gestion la plus importante à mettre en place est la surveillance et la gestion des niveaux d'eau. En effet, c'est le degré d'alimentation en eau et son maintien qui conditionne le bon fonctionnement du milieu. A côté de cela, les phénomènes de comblement et d'atterrissement liés à un développement rapide de la végétation peuvent être régulés par le rétablissement ou le maintien de pratiques agro-pastorales extensives, comme la fauche annuelle ou le pâturage. Ces méthodes de gestion ont démontré leur efficacité en terme de régulation de la biomasse produite ainsi que la limitation du développement des ligneux en zone humide, à condition de respecter un chargement adapté (KOŁOS & BANASZUK, 2013, 2018). Cependant, ces pratiques peuvent créer une pression de sélection sur le pool d'espèces végétales, par exemple par une fauche précoce ou par la sélection des espèces végétales pâturées par les animaux.

2.2.3 Les indicateurs de suivi écologique

Suivre l'état de conservation de ces milieux à travers des indicateurs est essentiel pour une bonne gestion. Il existe de nombreux indicateurs de suivi, nécessitant souvent des relevés de terrain. La télédétection peut être un proxy pour certains indicateurs. Dans cette thèse nous nous intéressons à deux d'entre eux :

- **Le suivi des communautés végétales.** Cet indicateur est important car la végétation est essentielle pour plusieurs raisons : 1) les communautés végétales structurent les habitats dont dépendent les biocénoses associées, 2) elles constituent un excellent

descripteur biologique du fonctionnement des hydrosystèmes, et 3) elles comptent un certain nombre d'espèces d'intérêt patrimonial et certains groupements végétaux constituent des habitats d'intérêt communautaire. La méthode privilégiée pour cet indicateur est le relevé phytosociologique.

- **Le suivi des dynamiques d'inondations.** La caractérisation des hydropériodes est indispensable car elles sont un préalable au développement des autres caractéristiques propres à la zone humide. Les hydropériodes sont caractérisées par des variations des niveaux d'eau à la surface et sous le sol. Seules les variations à la surface sont visibles par télédétection. Généralement, les niveaux d'eau sont mesurés ponctuellement à l'aide de piézomètre ou de mire graduée.

Les états-de-l'art des approches de télédétection en tant que proxy du suivi des communautés végétales et de la dynamique d'inondation sont dressées dans les parties 3.1 et 4.1, respectivement. Ces indicateurs sont souvent représentés sous forme de catégories qui ne restituent pas la nature graduelle de la structure d'une zone humide (GUO et al., 2017). À travers nos travaux, nous exploiterons les synergies drone/satellite afin de produire des proxys de la structure de cet écosystème plus représentatifs de la nature graduelle de celui-ci. Ces proxys peuvent ensuite être utilisés comme des indicateurs de biodiversité de plus haut niveau (voir Figure 5 de l'introduction générale), tel que l'indice d'habitat des espèces qui quantifie les changements qui surviennent dans les habitats d'une espèce et fournit une estimation des pertes potentielles de populations et/ou des augmentations du risque d'extinction.

2.3 Méthodologies appliquées aux synergies drone/satellite

2.3.1 Les méthodes de changement d'échelle

Afin de répondre à la problématique du suivi des prairies humides, nous exploitons les complémentarités entre drone et satellite. Cependant, exploiter plusieurs sources de données de télédétection sous-tend l'utilisation de méthodes de traitement plus ou moins avancées. En effet, en fonction du niveau d'intégration que l'on souhaite entre les données, on peut aller de la simple comparaison de caractéristiques pour une synergie faible jusqu'aux méthodes de fusion de données les plus avancées pour les synergies les plus fortes. À travers la revue de la littérature scientifique, nous avons constaté que l'approche la plus exploitée est l'utilisation de modèle de classification calibré par une "vérité drone".

Cette approche bien qu'elle soit efficace pour de nombreuses applications, ne suppose pas une intégration forte des deux sources de données. En revanche, les synergies les plus fortes qui permettent le changement d'échelle sont sous-exploitées (voir Figure 2.3). En télédétection, on entend par changement d'échelle, l'amélioration des résolutions spatiale, spectrale et temporelle ou encore de l'étendue spatiale. Dans cette thèse, nous nous intéressons au changement d'échelle rendu possible par les complémentarités entre drone et satellite. En considérant les caractéristiques respectives des systèmes drone et satellite, une synergie forte semble résider dans l'amélioration de la résolution spatio-temporelle³. Les stratégies de couplage par "calibration de modèle" et "fusion de données" s'y prêtent et une large gamme de méthodes sont exploitables. Plusieurs familles de méthodes de changement d'échelle existent (ATKINSON, 2013 ; DU, 2018 ; GHAMISI et al., 2019). Nous considérons ici les approches par démélangeage spectral et super-résolution.




FIGURE 2.3 – Fréquence des méthodes exploitées par les différentes stratégies de couplage. Les méthodes rapportant au changement d'échelle sont identifiées par le cercle rouge. STF : *Spatio-Temporal Fusion* ; STRS : *Spectral Temporal Response Surface*

3. Mais certaines études ont montré, également, le potentiel de synergie pour l'amélioration spectral-temporelle (GEVAERT et al., 2015) et spatial-spectral (JENEROWICZ & WOROSZKIEWICZ, 2016)

2.3.1.1 Démélangeage spectral

La faible résolution spatiale d'images de télédétection implique que le signal mesuré d'un pixel est souvent un mélange des signatures spectrales de différents matériaux présents au sein de l'aire couverte par la résolution au sol, on parle alors de "mixel". Le démélangeage spectral est alors le processus qui permet de décomposer un signal mesuré en une collection de spectres assimilés comme "purs", les *endmembers*, et d'estimer leurs abondances respectives dans un "mixel" (DU, 2018). Ainsi, en mesurant ou approximant des *endmembers* qui compose une scène, il est possible grâce à ces méthodes de retrouver l'information de composition à l'échelle sub-pixelique. Ces méthodes sont fréquemment utilisées pour traiter l'imagerie hyperspectrale (F. ZHU, 2017) mais elles sont également exploitables pour l'imagerie multispectrale (MELVILLE et al., 2019; PACHECO & MCNAIRN, 2010). Le lecteur trouvera dans la thèse de Simon Rebeyrol (REBEYROL, 2021) un point de vue complet sur l'état des recherches en démélangeage spectral.

Les *endmembers* peuvent être estimés ou bien apportés par des mesures auxiliaires ou des banques de spectres connus. Dans le cadre de la complémentarité drone/satellite, nous supposons que le drone grâce à la THRS permet de délimiter précisément des zones sans mélange et mesurer des spectres "purs". Les *endmembers* apportés par le drone peuvent alors permettre le démélangeage des pixels satellitaires à plus large échelle.

2.3.1.2 La super-résolution

La Super-résolution (SR) traite également du problème de la faible résolution spatiale. Elle a pour but de trouver une transformation, souvent une fonction de déconvolution, qui permet de passer de la basse (LR) vers la haute résolution (HR) d'une image. C'est un problème ancien qui n'a pas encore été résolu, car c'est un problème "mal posé" qui a des solutions multiples. Il existe différents types d'approches (J. YANG & HUANG, 2011) : modéliser directement la fonction de déconvolution, l'apprendre à partir de multiples images LR d'une même scène pour en reconstruire une donnée plus résolue, exploiter de nombreux couples d'images LR/HR visualisant la même zone et avec les mêmes bandes spectrales, ou encore exploiter un couple LR/HR d'une même zone mais sans les mêmes bandes spectrales pour reconstruire une donnée HR sur de nombreuses bandes spectrales. Nous nous intéressons ici à ces dernières approches basées sur la fusion de données qui utilisent une information HR pour aider la reconstruction (GARZELLI, 2016; GHAMISI et al., 2019). Par exemple, la fusion spatio-spectrale tel que le *pan-sharpening* utilise une

image panchromatique HR pour améliorer la résolution spatiale d’une image multispectrale LR, ou la fusion spatio-temporelle exploite le lien entre des images LR et HR à une date t_0 pour reconstruire une image HR à partir d’une image LR à une date t_1 .

Aujourd’hui, les réseaux de neurones, méthodes basées sur l’apprentissage, constituent l’état-de-l’art de la SR (W. YANG et al., 2019), comme pour beaucoup d’autres tâches de la vision par ordinateur, et ils forment un cadre adapté à la fusion de données de télédétection (AUDEBERT et al., 2018 ; Y. LIU et al., 2018). Le lecteur trouvera dans la thèse de Nicolas Audebert (AUDEBERT, 2018), un état-de-l’art complet sur l’application des réseaux de neurones en télédétection. En SR, contrairement aux approches classiques, les réseaux de neurones ne requièrent pas de définir des règles de fusion ou de changements d’échelles, laissant le soin au modèle de les apprendre à partir des données. Dans la perspective de la synergie drone/satellite, on a d’un côté le satellite qui apporte des images multispectrales LR de manière systématique et le drone qui peut apporter une information HR localement. Les réseaux de neurones seront alors utiles pour bien combiner cette information, comme cela sera abordé dans le chapitre 4.

2.3.2 Les réseaux de neurones convolutifs

Les architectures adaptées aux images s’appuient sur les réseaux de neurones convolutifs (CNN pour *Convolutional Neural Network* en anglais). Au lieu de construire des réseaux de neurones qui connectent tous les pixels entre eux, l’idée consiste à estimer les paramètres d’un ensemble de filtres de convolutions permettant de mieux décrire le contenu de l’image par rapport au problème posé. Dans son architecture initiale (LE CUN et al., 1989), chaque couche effectue une série de convolutions de tailles fixes sur la couche précédente puis une réduction de la taille des images. La convolution est une opération élémentaire consistant à modifier la valeur d’un pixel en fonction de celle de ses voisins. L’étape de réduction de la taille des images vise quant à elle à ne garder que l’information la plus importante et à introduire un aspect multi-échelle. En effet, en ne changeant pas la taille du filtre mais en réduisant celle des images, les convolutions s’appliquent sur une emprise spatiale de plus en plus grande. Les coefficients des opérations de convolution sont appris sur une base de donnée labélisée. Bien que de nombreux filtres de convolution pré-définis existent en traitement d’images (moyennes, gradients, texture, etc) et peuvent être utilisés pour mieux représenter les données, le principe ici est d’estimer les paramètres de chaque filtre en fonction du problème posé. Ainsi, les meilleurs filtres (ou descripteurs) sont estimés pour la tâche à effectuer. On parle alors d’apprentissage de

descripteurs ("*feature learning*") et c'est cette capacité des réseaux à ajuster les descripteurs pour un problème posé qui font une partie de leurs succès. Il est ainsi possible de s'affranchir de la difficile tâche de définition "manuelle" des descripteurs mais ceux-ci sont appris. L'architecture du réseau initial type CNN est visible sur la Figure 2.4.a : chaque couche effectue une série de convolutions et de réductions des images d'entrées. Ainsi, à la dernière couche, le vecteur de descripteur obtenu est très adapté au problème posé. il s'agit alors d'*encodage de l'information*. Le problème de classification/régression, appliqué à ces données encodées, devient alors plus simple et est résolu à l'aide d'un réseau de neurone à une seule couche (dernière partie de la Figure 2.4.a).




FIGURE 2.4 – Architectures des *Convolutional Neural Network* (a) et des *Fully Convolutional Network* (b).

Cette version initiale, communément nommée CNN vise à identifier une valeur (une classe, une quantité) pour une image entière. Si une information en chaque pixel est souhaitée, il faut alors ajouter un réseau de déconvolution qui va, à partir des données encodées, les déconvoluer en adaptant les filtres de déconvolution au problème à traiter. De

tels réseaux, nommés *encodeurs/décodeurs* sont visibles sur la Figure 2.4.b et on obtient, en sortie, une donnée par pixel de l'image. On parle alors de réseaux convolutionnels pleinement connectés, ou FCN en anglais (pour *Fully Convolutional Networks*). Il existe en pratique de nombreuses architectures basées sur les convolutions/déconvolutions (resnet, alexnet, googlenet, etc) qui diffèrent en fonction du nombre de bandes spectrales, de convolutions, de couches, des données sur lesquelles les paramètres sont calibrés. Parmi les architectures populaires, le réseau *UNet* est un des plus connus (cf. Figure 2.5). Il s'agit d'un réseau type encodeur/décodeur mais ici, à chaque couche de la déconvolution, l'information issue de la résolution correspondante au niveau de l'encodage est concaténée (cela est illustré par les flèches sur la Figure 2.5). Cela permet, tout au long de la phase de déconvolution, de mieux prendre en compte le contexte spatial. En effet, si par exemple on cherche à obtenir une segmentation en chaque pixel, s'appuyer uniquement sur des déconvolutions ne permettrait pas de prendre en compte de manière précise les contours. À l'inverse, ajouter l'image d'entrée à la dernière couche (et les images encodées aux couches précédentes) permet de capter également ces détails. Par ailleurs, les expérimentations ont démontré qu'un plus petit nombre de données était nécessaire pour l'apprentissage, par rapport à un réseau FCN classique.

2.3.3 La logique floue

La télédétection, dans ses approches classiques, tend souvent à discrétiser les éléments de la surface terrestre. Les cartes ainsi produites représentent donc une classe unique pour chaque pixel de l'image et tracent des limites nettes entre les entités. Ces approches s'avèrent parfois limitées en raison d'une part d'une sémantique pouvant être ambiguë (amenant de l'incertitude sur la nature des classes) et d'autre part en raison de la nature directement floue ou graduelle des objets d'étude. La logique floue et sa notion de sous-ensemble flou a pour but de permettre des gradations dans l'appartenance d'un élément à une classe, c'est-à-dire d'autoriser un élément à appartenir plus ou moins fortement à cette classe. Cette notion permet l'utilisation de catégories aux limites mal définies ou le passage progressif d'une propriété à une autre.

Comme nous l'avons vu précédemment, la structure des milieux humides est de nature extrêmement graduelle. Afin d'obtenir dans une restitution cartographique plus proche de la réalité, des approches méthodologiques permettant une représentation floue doivent être privilégiées. Concernant, la cartographie des communautés végétales, l'utilisation du démélangeage spectral doit permettre de représenter chaque catégories en terme d'abon-




FIGURE 2.5 – Architecture du modèle *UNet* (RONNEBERGER et al., 2015) du type *Fully Convolutional Network*.

dance et donc mettre en évidence les espaces de transition graduelle (écotones). Enfin, pour la cartographie des surfaces inondées, le paramètre de hauteur d'eau (paramètre continu) sera préféré à celui d'extension spatiale (classification binaire) car il permet de mieux appréhender le gradient d'hygrophyllie.

2.4 Site d'étude et données

2.4.1 Site d'étude : Les marais du Couesnon

2.4.1.1 Les marais de la basse vallée du Couesnon

Les marais du Couesnon sont situés à une vingtaine de kilomètres de l'exutoire du bassin versant du Couesnon (Figure 2.7). Ils occupent une plaine alluviale dans laquelle transite la majeure partie des eaux provenant du bassin. Ils font partie des marais périphé-

riques de la Baie du Mont-Saint-Michel, site du réseau européen Natura 2000. A l'échelle de la baie, ce vaste ensemble humide est l'un des plus préservés et fait figure de site à enjeux en terme de conservation de la biodiversité. Les marais du Couesnon sont essentiellement composés de prairies (78% de l'espace) au caractère plus ou moins hygrophile. Ils peuvent se découper en quatre sous-ensembles distincts, aux caractéristiques paysagères et aux modes de gestion spécifiques : le marais du Mesnil (190 ha), le marais de Sougéal (285 ha), le marais d'Aucey-Boucey (290 ha) et le marais de la Folie (172 ha). Ce site est particulièrement intéressant car il fait l'objet d'un suivi scientifique depuis 2006 en tant que "entité marais" de la Zone Atelier Armorique (ZAAr).




FIGURE 2.6 – Localisation du site d'étude. Fond de carte à gauche : Altitude (IGN). Fond de carte à droite : Image Pléiades à la date du 11-06-2017 (Kalidéos, CNES).

2.4.1.2 La réserve naturelle régionale du marais de Sougéal

Nous nous intéressons plus particulièrement à la réserve naturelle régionale du marais de Sougéal, inscrite sur la rive gauche du Couesnon. Ce site, de 175 ha pour sa partie communale et de 130 ha pour sa partie privée, constitue la partie centrale de la zone humide de la basse vallée du Couesnon. Cette prairie humide réhabilitée est maintenue artificiellement ennoyée plusieurs mois dans l'année afin de permettre à une faune et une flore spécifique de s'y développer. Le détail sur la structure de cet habitat, c'est-à-dire la distribution et la composition floristique ainsi que les dynamiques hydrologiques du site sont détaillés dans les sections 3.2.1 et 4.2.1, respectivement. Nous présentons, ici, le patrimoine naturel, les fonctionnalités écologiques ainsi que les modes de gestion de la réserve naturelle.

› *Le patrimoine naturel et les fonctionnalités écologiques du marais*

Le marais de Sougéal joue un rôle écologique primordiale à l'échelle de la baie du Mont-Saint-Michel et de la basse vallée du Couesnon.

Il est, d'abord, une source remarquable de biodiversité floristique et faunistique. Il abrite 360 espèces floristiques différentes au sein des prairies et des milieux aquatiques, dont la présence de quelques espèces d'intérêt patrimonial majeur comme le flûteau nageant (*Luronium natans*) qui bénéficie d'une protection nationale. Cette diversité provient, à la fois, de sa proximité avec le littoral et de la double influence des coteaux et du Couesnon qui apportent respectivement des eaux pauvres et riches en nutriments. Du côté faunistique, le marais abrite également plusieurs espèces d'amphibiens et près de 60% des espèces d'odonates de Bretagne.

De plus, le marais joue des rôles primordiaux pour le maintien de nombreuses espèces. Il constitue une frayère pour plusieurs espèces piscicoles dont le Brochet (*Esox lucius*). Le site de Sougéal est également un site favorable à l'accueil des oiseaux d'eau. A l'échelle de la baie, il constitue le principal site de stationnement migratoire pour plusieurs espèces, comme la Sarcelle d'été (*Anas querquedula*). En plus de son patrimoine naturel, le site préserve un patrimoine culturel à travers des modes de gestion traditionnels.

› *Gestion de la réserve naturelle*

Afin de préserver les intérêts patrimoniaux du marais de Sougéal, le site a été labellisé « Réserve naturelle régionale – Espace remarquable de Bretagne » par le Conseil régional



FIGURE 2.7 – Illustrations du paysage du marais de Sougéal (photos de Thomas houet et Emilien Alvarez-Vanhard) : a) Paysage en période d’assec, b) Paysage en période humide, c) Ceintures de végétation, et d) Nid de Foulque macroule (*Fulica atra*).

de Bretagne⁴. Ainsi, la réserve est gérée par la communauté de commune du Pays de Dol et de la Baie du Mont-Saint-Michel qui a pour rôle le maintien des habitats, des espèces et de la fonctionnalité du site.

La fonctionnalité du marais est préservée, notamment, via la gestion des niveaux des eaux qui est effectuée à l’aide de porte à flots et d’un réseau de canaux. La gestion

4. Réserve naturelle régionale du Marais de Sougéal, Région Bretagne (2019)

hydraulique est actuellement calée sur le cycle de reproduction du Brochet et les périodes de pâturage. Le site est maintenu inondé en hiver et une vidange progressive est effectuée à partir de la mi-avril, ce qui correspond également aux périodes d'hivernage et de migration pré-nuptiale des oiseaux d'eau mais reste trop précoce pour leur nidification.

Les habitats du marais sont préservés par différentes mesures. D'abord, les prairies herbacées sont maintenues grâce à un mode de gestion traditionnel : le pâturage collectif. Cette pratique est réglementée via une mesure agroenvironnementale et climatique qui permet de maintenir le milieu ouvert sans créer de déséquilibre lié au surpâturage. Ensuite l'habitat aquatique est entretenu, notamment, via le curage des canaux où se développe le flûteau nageant ce qui évite le comblement de ceux-ci et la colonisation par d'autres espèces végétales. Enfin, la mise en défend de pâturage de certains secteurs permet une diversification des habitats. Cette pratique favorise le développement d'autres groupements de végétaux qui sont de potentiels sites de ponte pour certains oiseaux et invertébrés.

2.4.2 Collection de données multi-sources

À travers cette thèse, des observations satellitaire, drone et *in-situ* du site des marais du Couesnon ont été rassemblées (voir Figure 2.8). Ce jeu de données multi-source et multi-échelle doit permettre d'appliquer et d'évaluer les synergies drone/satellite dans le cadre du suivi de prairies humides.

Les observations satellitaires Sentinel-2 et Pléiades proviennent, respectivement, du pôle de données et de services surfaces continentales *Théia* et du dispositif *Kalidéos Bretagne* du Centre Nationale d'Études Spatiales (CNES). Les observations drones ont été acquises via la plateforme CNRS D2T (Drone, Terrain, Télédétection) hébergée au sein de l'UMR LETG-Rennes. Enfin, les observations *in-situ* ont été réalisées grâce à un partenariat avec l'UMR ECOBIO : Cendrine Mony, Aude Ernoult et Lucie Lecoq ont réalisés les relevés floristiques, et Guillaume Bouger a assuré les relevés des sondes piézométriques, installées dans le cadre de la ZAAr.

Cette section présente les principales données exploitées : les produits Sentinel-2 et drone. Les données auxiliaires (ex : Pléiades) et *in-situ* qui ont été utilisées pour des études spécifiques seront décrites dans les chapitres où elles sont exploitées.




FIGURE 2.8 – Caractéristiques de la collection de données multi-source.

2.4.2.1 Collecte de données satellites : produits Sentinel-2

La constellation Sentinel-2 (DECHOZ et al., 2015) fait partie du programme *Copernicus* financé par l'ESA. Elle a été conçue pour fournir des informations de suivi opérationnel pour des applications en environnement et sécurité. La mission a pour objectif : (1) de fournir des acquisitions multispectrales globales et systématiques à haute résolution spatiale et temporelle ; (2) fournir une continuité à la série de satellite multispectral SPOT (Satellite Pour l'Observation de la Terre) ; et (3) fournir des observations pour la nouvelle génération de produits opérationnels tel que l'occupation du sol, des cartes de détection du changement d'occupation, et des variables géophysiques et biophysiques.

La constellation est composée du satellite Sentinel-2A lancé en 2015 et Sentinel-2B lancé en 2017. Les satellites sont équipés d'un instrument multi-spectral (MSI) avec 13 bandes spectrales du visible et proche infrarouge jusqu'au moyen infrarouge (Tableau 2.1). Le MSI est un imageur *push-broom*⁵ avec une ouverture de F/4, une distance focale de 0.6 m et des capteurs CMOS (*Complementary Metal Oxide Semi-conductor*). En fonction des bandes la résolution spatiale varie de 10 m à 60 m avec un champ de vue (ou fauchée) de 290 km. Ces satellites possèdent une durée de vie minimale de 7,25 années. Ce sont des satellites à orbite polaire et synchronisés avec le soleil à une altitude de 786 km. Les deux satellites sont déphasés de 180° permettant des acquisitions tous les 5 jours au niveau de l'équateur. L'angle d'observation est constant entre les acquisitions pour assurer des séries temporelles de données de qualité et consistante.

La qualité des produits Sentinel-2 du pôle de données *Théia* est au niveau L2-A, c'est-à-dire que la géométrie et la radiométrie des données sont corrigées (voir Annexe B). Ainsi, cette donnée fournit des images avec une information sur la réflectance du "haut de la canopée" et avec une erreur géométrique estimée à 12.5 m. La collecte de ces données est effectuée par téléchargement automatique à l'aide d'un script fournit par le CESBIO⁶.

2.4.2.2 Collecte de données drone : matériels et protocole d'acquisition

Dans le cadre de cette thèse et du développement de la plateforme D2T, j'ai acquis les compétences de télépilote de drone qui m'ont permises d'assurer l'acquisition d'une partie des données drone, l'autre partie ayant été acquise par Thomas Houet. Dans le cadre d'un financement *Action Spécifique* de l'Université Rennes 2, une série mensuelle de données drone (multispectrale, RGB, MNT) a pu être acquise sur une année hydrologique entre 2018 et 2019 (Figure 2.9). Les données sont accessibles sur l'infrastructure de données géographiques du LETG : *Indigeo* (HOUEY & ALVAREZ-VANHARD, 2021).

Cette partie détaille le matériel utilisé et les protocoles pour la production d'ortho-images multispectrales et de Modèle Numérique de Terrain (MNT) par drone.

> Drone : aile-volante *eBee*

Les drones utilisés pour les acquisitions sont des aile-volantes (*eBee+* et *eBeeX*, voir Figure 2.10.a) d'une envergure de 110 cm et d'un poids de 1,1kg. L'avantage de la voilure

5. Un imageur *push-broom* consiste en une ligne de capteurs disposés perpendiculairement à la direction de vol de l'engin spatial. Cette technologie a l'avantage de capter plus de lumière grâce à un temps de pose plus long (cf. earthobservatory.nasa.gov)

6. https://github.com/olivierhagolle/theia_download

Bandes Sentinel-2	Longueur d'onde centrale (nm)	Bande passante (nm)	Résolution spatiale (m)
B1 - Aérosol côtier	442.7	21	60
B2 – Bleu	492.4	66	10
B3 – Vert	559.8	36	10
B4 – Rouge	664.6	31	10
B5 – Végétation "red edge"	704.1	15	20
B6 – Végétation "red edge"	740.5	15	20
B7 – Végétation "red edge"	782.8	20	20
B8 – PIR	832.8	106	10
B8A – PIR "étroit"	864.7	21	20
B9 – Vapeur d'eau	945.1	20	60
B10 – SWIR – Cirrus	1373.5	31	60
B11 – SWIR	1613.7	91	20
B12 – SWIR	2202.4	175	20

TABLE 2.1 – Caractéristiques spectrales et spatiales des bandes de l'instrument multispectrale (MSI) de Sentinel-2.

fixe est la forte endurance qui permet au drone de couvrir de grandes portions du territoire (jusqu'à quelques centaines hectares).

Comme tous les drones, ces ailes volantes fonctionnent grâce à trois compartiments :

- La plate-forme aérienne composée de plusieurs éléments afin d'assurer le vol et le transport des capteurs pour acquérir des données. Il y a la structure de l'aéronef qui est conçue pour être légère et résister aux forces du vent pour éviter les déformations de l'appareil et les vibrations. Le système de navigation, qui regroupe les systèmes de servomoteurs, de GNSS et d'IMU, permet au drone de voler de manière autonome ou semi-autonome. Ensuite, la ou les batterie(s) qui fournissent l'énergie au système. Ce sont généralement des batteries LiPo (*Lithium Polymer*). Et enfin, la charge utile, c'est-à-dire le ou les capteurs dédiés à l'acquisition de données.
- La station de contrôle au sol qui assure un contrôle à distance interactif et permanent au télépilote. Il s'agit généralement d'une tablette ou d'un PC portable avec un logiciel de planification de vol (ex : *eMotion*). Ce logiciel doit permettre de planifier et paramétrer les zones d'atterrissage, les lignes de vols, l'altitude, les paramètres des capteurs mais aussi il informe le télépilote sur le déroulement du vol (vitesse, altitude, niveau des batteries, etc).




FIGURE 2.9 – Compositions colorées fausses couleurs (R : PIR - V : Rouge - B : Vert) de la série de données multispectrales drone sur une année hydrologique (sept. 2018 à août 2019).

- Enfin, le système de communication qui assure la connexion entre le compartiment aérien et celui au sol. Il s'agit d'une connexion radio dans des fréquences spécifiques qui est obligatoire pour pouvoir assurer des opérations d'urgences (ex : approche d'un autre aéronef).

› Imageur multispectral : *Sequoia*

Le *Sequoia* de Parrot est un capteur multispectral (Multiple Camera Array) compact. Il possède quatre capteurs CMOS monochromes de 1.2 mégapixels équipés de filtre à bande passante qui permettent la collecte de données dans plusieurs domaines du spectre électromagnétique : du visible au proche infrarouge (voir Table 2.2 et Figure 2.11). Avec



FIGURE 2.10 – Matériel drone utilisé pour les acquisitions multispectrales : a) aile-volante eBee ; b) capteurs Sequoia et Sunshine.

une distance focale de 2,2 mm, chaque capteur du *Sequoia* a un champ de vision horizontal (HFOV) de 64°, un champ de vision vertical (VFOV) de 50° et un angle de champ (DFOV) de 74°. Avec une hauteur de vol approchant les 120 m, on obtient une résolution au sol de 10-15 cm. Les prises de vues sont effectuées à l'aide d'un obturateur global évitant des problèmes de distorsion des images acquises. En complément, un capteur de l'illumination ambiante (le "*Sunshine*"), orienté vers le ciel, se déclenche en simultané de chaque acquisition faite par le *Sequoia*. Ce second capteur d'illumination acquiert dans les quatre mêmes bandes que le *Sequoia*. Les conditions d'illumination serviront à la calibration radiométrique des données.

Domaine spectral	Longueur d'onde centrale (nm)	Bande passante (nm)
Vert	550	40
Rouge	660	40
"Red edge"	735	10
Proche infrarouge	790	40

TABLE 2.2 – Domaines spectraux mesurés par le capteur Sequoia

Les valeurs brutes mesurées par le capteur *Sequoia* doivent être calibrées pour pouvoir les interpréter en terme de quantité de réflectance. Selon les définitions de SCHAEPMAN-STRUB et al., 2006 et NICODEMUS et al., 1977, les propriétés de réflectance de la surface mesurée par le *Sequoia* peuvent être décrites en tant que facteur de réflectance hémisphérique-conique (Figure 2.12). Étant donné la proximité de la prise de vue par drone (distance < 120m), l'atmosphère entre la surface et le capteur représente une faible couche (peu d'aérosols pouvant perturber les rayons réfléchis) et est potentiellement négligeable. L'ensemble des calibrations géométriques et radiométriques sont effectuées sous




FIGURE 2.11 – Réponses spectrales relatives des quatre bandes du Sequoia, ainsi que les bandes correspondantes les plus proches du MSI de Sentinel-2A (B3, B4, B6 et B7).

Pix4D (voir Annexe C pour la chaîne de traitement détaillée) qui semi-automatise la production d'ortho-images multispectrales et de MNT par photogrammétrie.




FIGURE 2.12 – Luminance incidente (à gauche) et réfléchie (à droite) d'une mesure de quantité décrite en tant que facteur de réflectance hémisphérique-conique. La luminance incidente est décrite par l'illumination ambiante diffuse ainsi que le rayonnement direct de la source de lumière. La luminance réfléchie est décrite par le champ de vue du capteur.

› Protocole d'acquisition

Pour chaque vol, des mires de calibration sont utilisées. D'abord, au moins neuf mires de calibration géométrique servent de points de contrôle au sol (PCS) pour l'orthorectification des images. Elles sont placées à travers le site selon la répartition spatiale visible sur la figure 2.13. La position de chaque PCS est enregistrée par un GNSS différentiel d'une précision centimétrique après correction. Ensuite, une mire de calibration radiométrique

(dont la réflectance est connue dans les bandes spectrales du *Sequoia*) est photographiée par le capteur. La réflectance de la mire ne doit pas être trop forte (blanche), car le temps d'intégration nécessaire pour un bon ratio signal-sur-bruit sur le reste de la scène mène à une saturation des surfaces brillantes (FAWCETT et al., 2020). Finalement, une mire bon marché avec une réflectance de 20% sur chaque bande est suffisante et donne des résultats proche à l'utilisation d'un spectralon considéré comme lambertien avec des réflectances de 40% (FAWCETT & ANDERSON, 2019).




FIGURE 2.13 – Répartition schématique des points de contrôle au sol sur un site de 150 ha. PCS : Points de Contrôle au Sol.

Les données sont acquises selon un plan de vol permettant une superposition latérale d'au moins 65% (voir Figure 2.14) et orienté perpendiculairement à l'angle d'azimut solaire pour éviter des effets de spécularité et de "hotspot". Le temps entre deux acquisitions est réglé automatiquement en fonction de la vitesse de vol pour fournir une superposition d'au moins 90% entre deux images successives d'une même ligne de vol. La superposition des images est importante car elle influence le pourcentage de pixel avec un angle de vue proche du nadir, c'est-à-dire une direction de prise de vue perpendiculaire à la surface d'intérêt. Tandis que les pixels au centre de l'image sont bien au nadir quand l'angle de vue est à 90°, les pixels sur le côté de l'image peuvent avoir un écart d'angle de vue jusqu'à 32°. La valeur de réflectance pour ces pixels peut alors être sur- ou sous-estimée. Le plan de vol est ajusté en fonction des paramètres de superposition mais aussi de la résolution au sol et surtout de l'extension spatiale souhaitée. Ces paramètres sont contraints par les caractéristiques du matériel utilisé (capteur et drone). Ce plan est également contraint par les caractéristiques du terrain, des conditions météorologiques (vent surtout pour la direction des lignes de vol), et également la législation locale. La réalisation de ce plan de vol est assistée par un logiciel (*eMotion 3*).



FIGURE 2.14 – Plan de vol schématique pour assurer un recouvrement latéral entre les prises de vues de chaque ligne de vol.

2.5 Conclusion


Dans ce chapitre, les gradients environnementaux qui caractérisent les prairies humides ont été mis en évidence et les paramètres utiles pour connaître l'état de conservation du milieu et approximables par télédétection identifiés. Les méthodes de changement d'échelle pertinentes et adaptées à la complémentarité drone/satellite ont été listées. La mise en correspondance de l'aspect thématique et méthodologique permet d'envisager un suivi des prairies humides qui rend compte des gradients spatiaux et des dynamiques temporelles existants au sein de ces milieux. Deux applications exploitant les complémentarités drone/satellite à travers des méthodes de changement d'échelle ont été pensées pour cette thèse :

- **La cartographie des communautés végétales par télédétection.** Les méthodes de classification discrète traditionnelles ne permettent pas de rendre compte du changement graduel de composition entre communautés végétales. Employer le démélangeage spectral pour cartographier ces entités aux limites floues semble pertinent. De plus, cette méthode de changement d'échelle permet de dépasser la limite de résolution spatiale des données satellitaires. Le drone grâce à la THRS permet de cibler des zones d'échantillonnage sans mélange et d'extraire une plus large gamme de *endmembers* pour caractériser chaque communautés. Il est supposé que la variabilité spectrale apportée par le drone aide au démélangeage des zones les plus hétérogènes, donc à priori les communautés méso-hygrophiles qui présentent la plus forte diversité spécifique (Annexe D.1).
- **La cartographie des dynamiques d'inondation.** Les acquisitions systématiques des satellites comme Sentinel-2 permettent de suivre la dynamique temporelle des

surfaces à un pas régulier de 5 jours (sans nuages) mais à une résolution spatiale qui ne permet pas de discerner des motifs spatiaux fins. Le drone a la capacité de produire des MNT précis à THRS. En s’inspirant des modèles de fusion spatio-temporelle, il est supposé que la fusion de l’imagerie multispectrale LR avec une information HR sur la topographie doit permettre de restituer la variabilité spatio-temporelle des niveaux d’eau sur les sites des marais du Couesnon.

Une base de données multi-sources a été collectée alliant observations *in-situ*, drone et satellitaires sur le site des marais du Couesnon. Elle doit permettre de répondre aux hypothèses précédentes. Seule une partie de ces données, notamment celle au coeur de cette thèse (les données drone) ont été présentées ici. En effet, afin d’éviter des redites, les données spécifiques à chacune des deux applications mentionnées ci-dessus sont présentées au sein des chapitres concernés.

CALIBRATION DE MODÈLE : CARTOGRAPHIE DES COMMUNAUTÉS VÉGÉTALES DE PRAIRIE HUMIDE



La végétation est généralement cartographiée par télédétection par l'application de classifications dites "dures" (RAPINEL, MONY et al., 2019). Celles-ci en imposant une unique classe par pixel implique une limite nette entre les entités qui ne correspond pas au caractère souvent graduel de la distribution des espèces végétales dans leur environnement. Ces représentations entraînent une perte d'information concernant les transitions graduelles (ou écotones) de la composition floristique entre deux communautés végétales (FEILHAUER et al., 2020 ; FOODY, 1996 ; RAPINEL, ROSSIGNOL, HUBERT-MOY et al., 2018). Décrire ces motifs spatiaux de manière plus réaliste est possible via des méthodes de cartographie basées sur la théorie des ensembles flous (BUNEL, 2021 ; WOODCOCK & GOPAL, 2000). Le démélangeage spectral est une méthode de classification "floue" qui estime un mélange de classes à l'échelle sub-pixelique à partir de la décomposition du signal spectral. Contrairement à d'autres approches floues, le démélangeage spectrale ne propose pas une probabilité pour chaque classes mais bien une fraction de couverture de celles-ci dans un pixel donné.

Dans l'article "*Can UAVs fill the gap between in situ surveys and satellites for habitat mapping ?*" publié dans *Remote Sensing of Environment*, une approche pour cartographier les communautés végétales de prairies humides par démélangeage spectral est proposée. Étant donné la nature floue des communautés végétales, c'est-à-dire les changements de composition floristique le long du gradient d'hygrophyllie, il est difficile d'obtenir des pixels considérés comme "purs" avec la résolution spatiale des satellites. Il est supposé que le drone avec sa THRS peut fournir ces pixels "purs" (ou *endmembers*) utiles au démélangeage. Les *endmembers* provenant du drone sont supposés représenter une diversité de spectres caractérisant plus finement la composition floristique des communautés. Cette diversité de spectres doit permettre de mieux caractériser les surfaces les plus hétérogènes, telles que les communautés méso-hygrophiles dont la plus forte diversité spécifique peut impliquer une plus forte diversité spectrale (R. WANG & GAMON, 2019).

Can UAVs fill the gap between in situ surveys and satellites for habitat mapping ?

› **D.O.I** : <https://doi.org/10.1016/j.rse.2020.111780>

› **Résumé** : Habitat mapping is an essential descriptor to monitor and manage natural or semi-natural ecosystems. Habitats integrate both the environmental conditions and the related biodiversity. However, it remains challenging to map certain habitats such as inland wetlands due to spectral, spatial and temporal variability in the vegetation cover. Currently, no satellite constellations optimize the spectral, spatial and temporal resolutions required to map wetlands according to the habitats discriminated from in situ surveys. Our approach aims to combine satellite and unmanned aerial vehicle (UAV) data to exceed their respective limitations. Both data sources were combined through a spectral unmixing algorithm with the hypothesis that endmembers from UAV data are pure enough to enhance plant community abundances estimated from satellite data. The experiment was conducted on the regional preserve of the Sougéal marsh, a wet grassland of 174 ha located upstream of the Mont-Saint-Michel Bay. Two satellite data sources - Sentinel-2 and Pleiades - and three acquisition periods - November 2017, April 2018 and May 2018 - were considered. A reference map of plant community distribution was produced from UAV multitemporal data and floristic surveys to validate the unmixing of satellite data. This study shows innovative results and perspectives : while UAV can improve habitat discrimination, results vary among acquisition periods and habitats. Results illustrate well the great potential of combined UAV and satellite data but also demonstrate the influence of endmembers on the unmixing process and technical limitations (e.g. spectral mismatches between sensors), which can be overcome using domain adaptation.

3.1 Introduction

Global changes caused by human activities are a major threat to ecosystems, leading to a worldwide loss of biodiversity (TILMAN et al., 2017), which calls for an assessment of the conservation status of wetlands. Habitat mapping is essential to describe and monitor ecosystems because habitats result from both environmental conditions and the ecosystem’s biodiversity (LOPEZ & FENNESSY, 2002; LU et al., 2015). Remote sensing (RS) has been identified as a pertinent source of data to derive “essential biodiversity variables”, (O’CONNOR et al., 2015; PEREIRA et al., 2013), which can be used to characterize and monitor natural and semi-natural ecosystems. They also help to discriminate ecosystem distributions at the landscape scale, as well as habitat heterogeneity within these ecosystems (ALLEAUME et al., 2018; SKIDMORE et al., 2015), providing useful indicators for supporting environmental management of landscapes (LU et al., 2015).

While habitats have been adequately mapped using RS for forest, heathland and grassland ecosystems since the early 2000s (CORBANE et al., 2015), mapping inland wetlands remains challenging (ADAM et al., 2010). Indeed, they encompass a wide diversity of ecosystems driven by water stress, including humid and flooded grasslands. These ecosystems are of particular interest since they provide many ecosystem services due to their hydrological, ecological and biogeochemical functionalities (COSTANZA et al., 1997). They provide natural and semi-natural habitats for rare fauna and flora and act as a refuge for wildlife diversity (DENNY, 1994). However, human land use leads to habitat degradation (JOHNSTON et al., 2009; MALEKMOHAMMADI & JAHANISHAKIB, 2017), such as invasion by exotic or eutrophic indigenous species, disturbances due to intensive agriculture or development of late-successional vegetation stages due to land abandonment (ANDREW & USTIN, 2009). Detecting and monitoring habitat degradation in its early stages is of major importance for land and biodiversity management (WALKER & SMITH, 1997). Accurately discriminating habitats and mapping wet and flooded grasslands using optical RS is challenging (ADAM et al., 2010) since they exhibit high spectral and spatial variability in vegetation cover and mixtures, which can become even more confused by local properties and processes (e.g. underlying soil, hydrological regime, atmospheric water vapor, agricultural practices). It is also difficult to define clear boundaries between habitats due to the spatio-temporal dynamics of vegetation cover caused by seasonal and annual effects of climate and human activities (RAPINEL, MONY et al., 2019; ZLINSZKY et al., 2014). Although RS faces these challenges, it remains the only way to exhaustively map large

spatial areas that could not be covered by in-situ surveys. Nevertheless, these surveys are crucial for training and validating RS results.

The accuracy of habitat maps depends strongly on the spectral, spatial and temporal resolutions of RS imagery. First, the use of multispectral and hyperspectral data demonstrates that as the spectral resolution increases, discrimination of habitats or species becomes easier (ADAM et al., 2010). Multispectral data allow for good discrimination (SHA et al., 2008; X. YANG, 2007), although hyperspectral data provide more precise information about biophysical and biochemical characteristics of habitats (ERUDEL et al., 2017; SILVESTRI et al., 2003; C. WANG et al., 2007) or plants (REBELO et al., 2018). However, hyperspectral data is only currently available from airborne systems, which do not provide high frequency observations over large areas except at high cost. Second, high spatial resolution makes it possible to extract features that describe textural or multi-scale characteristics, which allows for habitat mapping at meter (MARTÍNEZ-LÓPEZ et al., 2014) and sub-meter resolutions (SAWAYA et al., 2003; SZANTOI et al., 2013). Very high spatial resolution (VHSR) sensors, such as Ikonos, Quickbird or even Pleiades, however, have an associated cost that does not allow for sufficiently frequent sampling to monitor habitats continuously over large areas (GUO et al., 2017; X. YANG, 2007). Third, RS time series captures changes in vegetation spectra due to phenology and hydrological regimes (ASNER, 1998; L. WANG et al., 2012). Discrimination of wetland and grassland has been improved by the use of the phenological variability in reflectance (GILMORE et al., 2008; OUYANG et al., 2013; RAPINEL, MONY et al., 2019; SCHUSTER et al., 2015). New satellite constellations such as Sentinel-2 provide high temporal frequency and spectral richness, but their spatial resolution remains too low to discriminate small or patchy habitat types effectively (RAPINEL, MONY et al., 2019). Finally, no current satellite constellation offers high-frequency temporal sampling with suitable high spatial and spectral resolutions; however, optimizing the resolutions improved results (RAPINEL, MONY et al., 2019). One way to optimize resolutions is to combine several data sources, such as optical data from unmanned aerial vehicles (UAV) and satellites.

Recent technological advances have made UAVs widely available, providing a new low-cost RS data source with unrivalled properties (ANDERSON & GASTON, 2013). Despite their inability to cover large areas, light UAVs can acquire VHSR multispectral data (ANDERSON & GASTON, 2013). Because of this flexibility, we hypothesized that UAV data can be used to complement satellite data (e.g. Pleiades, Sentinel-2) to improve mapping of wetland habitats. We assume that UAVs can play an important role between field

surveys and satellite data. Indeed, automatic mapping depends on field surveys, which are expensive (ELZINGA et al., 1998) and difficult to combine with satellite imagery due to spatial and temporal topological errors (KARL et al., 2014 ; J. ZHANG et al., 2019) and, as mentioned, satellite resolutions that are too low. Thus, we examined whether UAVs can fill the gap between in situ surveys and satellites.

Our study aimed to test spectral synergies between UAV and satellite data to map plant communities, which were considered as habitat units. Reference spectra can be extracted from UAV data to map habitats at a lower spatial resolution (satellite) using a spectral unmixing approach (ROTH et al., 2015). Unmixing allows the estimation of fractional abundances of distinct habitat classes that have specific spectral signatures (i.e. “endmembers”) (KESHAVA & MUSTARD, 2002). This approach has been applied to habitat mapping (HAMADA et al., 2013 ; SILVESTRI et al., 2003 ; C. WANG et al., 2007) and has the advantage of considering plant communities as fuzzy sets (BASTIN, 1997 ; ROCCHINI et al., 2013), due to the variation in plant abundance along soil or altitudinal gradients. The main limitation of unmixing processes is the need to select pure endmembers (or pixels), although vegetation patterns have fine-grained spatial heterogeneity. HAMADA et al., 2013 pointed out that the purity of endmembers is the key to achieving good accuracy using a spectral unmixing approach. This study assumes that the spatial resolution of UAV data helps in extracting pure endmembers.

To test these hypotheses, this study focused on the contribution of multispectral UAV data, used along with satellite data, to map habitats using three RS datasets (UAV, Sentinel-2 and Pleiades) and in situ floristic surveys. We focused specifically on analyzing the mosaic of habitats of a flooded grassland in France. Their temporal (time series) and spatial (textural information) resolutions were not considered.

3.2 Matériels

3.2.1 Study site

The study was conducted in the Sougéal marsh (western France, 48.52° N, 1.53° W) which is part of the LTSER site “Zone Atelier Armorique”. This site is a large flooded grassland of 174 ha located in the floodplain of the Couesnon River, upstream of Mont-Saint-Michel Bay (Figure 4.2). Due to its high conservation value, it has been included as a sub-site of the Natura 2000 “Baie du Mont Saint-Michel” site. It has been also labelled

as a regional nature reserve. It is regularly flooded from December to April, and managed through extensive mixed-grazing of cows, horses and geese. It includes a network of shallow and stagnant channels, which enables drainage of the site in spring. Plant assemblages are driven strongly by the flooding gradient, encompassing different types of communities, from mesophilic to long-flooded communities (assemblages described in Appendix D.1). The corresponding habitats are identified using EUNIS typology (ICHTER et al., 2014). Possible degradation of these habitats has been detected at the site, particularly the spread of competitive eutrophic plant species (e.g. *Urtica dioica*) and local trampling by cattle, which has created areas of bare soil.




FIGURE 3.1 – (left) Location of the Sougéal marsh study site on the Mont-Saint-Michel Bay Natura 2000 site and (right) locations of floristic surveys in 2017 and 2018 on the orthophotograph acquired by UAV on 18 May 2018.

3.2.2 Field data

Plant assemblages were characterized by floristic surveys performed in May 2017 and May 2018 (106 and 46 sampling plots, respectively ; Figure 4.2). For each plot of both surveys, we recorded all plant species and estimated their abundance as a percentage of cover in the plot. The first survey was performed by distributing plots along four transects parallel to the slope of the site to survey plant communities along the gradient of flooding duration. Plots measured 2×2 m and were located every 5 m along the transects. The second survey was performed to supplement the first. To include all possible variants of the communities identified at the site, plots were randomly placed in spatially homogeneous areas. These plots measured 50×50 cm.

3.2.3 Remotely sensed data

3.2.3.1 UAV data

UAV data were acquired for three dates (6 November 2017, 20 April 2018, 18 May 2018) to provide a multi-seasonal dataset providing information about the phenology and seasonality of the habitats (TOMASELLI et al., 2017). Two periods were selected to provide contrasting phenologies : 1) before the winter floods (i.e. in November) and 2) after the winter floods, starting in April, which corresponded to the flowering period and biomass peak, a key period for identifying floristic patterns with spectral data (DENG et al., 2017 ; FEILHAUER et al., 2013). Although grazing had started by 18 May 2018, an exclusion zone had been established to allow vegetation to grow. Spectral responses for a given community differed depending on whether it was inside or outside this zone.

UAV data were acquired using an eBee+ (SenseFly, Cheseaux-sur-Lausanne, Switzerland), a self-guided, lightweight (1.2 kg) and fixed-wing drone. Its mean duration is 40 min, which allows it to cover up to 14 km² under fair meteorological conditions (low wind). Its multispectral sensor (Sequoia, Parrot SA, Paris, France) acquired 1.2 megapixel images in the green, red, red-edge and near infrared (NIR) bands (Figure 3.2). It flew 148 m above the ground, providing data at a resolution of 14.7 cm, which was resampled to 20 cm to provide consistent spatial data for the study. The orthomosaics were generated for each date/spectral band using Pix4dmapper software (Pix4D, 2019) producing geometric error smaller than the pixel size (root mean square error (RMSE) = 0.048–0.154 m). Data were radiometrically corrected for optical instrument factors (e.g. vignetting, spectral response) and differences in solar irradiance and angle, and calibrated using a

radiometric target to provide top-of-canopy (TOC) reflectance (ASSMANN et al., 2018).




FIGURE 3.2 – Spectral (bandwidth) and spatial features of Sentinel-2, Pleiades and Sequoia (UAV) sensors.

3.2.3.2 Satellite data

Two types of multispectral satellite images were used : Sentinel-2 (ESA) and Pleiades (Airbus) (Table 3.1). Satellite data were pre-processed at level 2A (i.e. orthorectified with absolute ground reflectance values). Pleiades imaging was provided by the Centre National d'Études Spatiales (CNES, the French spatial agency) KALIDEOS program at level 1C : geometric corrections are accurate (<0.7 m), while reflectance is retrieved using the FLAASH algorithm (COOLEY et al., 2002). Sentinel-2 images were pre-processed by the CNES : radiometric corrections using the MACCS algorithm (HAGOLLE et al., 2015) and an estimated positional error with an RMSE of 12.5 m (i.e. a potential offset of >50 pixels compared to UAV data). Pixels were adjusted empirically by shifting them to match ground-control points to minimize geometric mismatches between satellite and UAV data.

Date	Sensor	Local time	Sensor incidence angle	Sensor azimuth angle	Solar zenith angle	Solar azimuth angle
6 Nov 2017	UAV	11 :32 :30	Near-nadir	/	64.181°	177.031°
6 Nov 2017	Pleiades	11 :26 :34	21.2762°	180.0429°	64.639°	173.643°
20 Apr 2018	UAV	11 :36 :30	Near-nadir	/	36.281°	170.816°
19 Apr 2018	Sentinel-2	10 :56 :19	Near-nadir	/	36.992°	166.341°
18 May 2018	UAV	11 :10 :30	Near-nadir	/	29.548°	157.664°
20 May 2018	Pleiades	11 :25 :34	17.7779°	180.0648°	29.298°	161.603°
19 May 2018	Sentinel-2	10 :56 :19	Near-nadir	/	30.369°	151.244°

TABLE 3.1 – Acquisition details for UAV, Sentinel-2 and Pleiades data.

Spectral characteristics of the satellite and UAV images complemented each other (Figure 3.2). All satellite and UAV images were acquired under clear-sky conditions with a maximum temporal mismatch between satellite and UAV acquisition of 2 days. Consequently, we assumed that the two sets of images did not differ significantly in spectral responses.

3.3 Méthodes

The methodological workflow was stratified in four steps (Figure 4.4), as described in the following subsections.

3.3.1 Step 1 : Unsupervised classification of floristic data

Plant groups were defined based on their floristic composition using correspondence analysis (GREENACRE, 2010) performed using the FactoMineR package of R software (R Core Team, 2019). Groups were identified using hierarchical classification analysis based on the coordinates of the sampled plots on the correspondence analysis axes. Four groups were detected based on the plots sampled in 2017. Plots sampled in 2018 were projected




FIGURE 3.3 – The general workflow, composed of four steps : 1) unsupervised classification of floristic data, 2) supervised classification of multi-temporal UAV data to create a reference map, 3) estimation of plant community abundances by habitat based on two types of spectral unmixing (extraction of endmembers in (A) UAV imagery or (B) satellite imagery) and 4) accuracy assessment.

as supplementary individuals on the multivariate plots. Each sampling plot was assigned to a group depending on its location in the multivariate plot. Seven plots that lay on the border between two groups were removed from subsequent analysis. In total, floristic groups 1–4 contained 61, 19, 39 and 26 plots, respectively.

3.3.2 Step 2 : Reference map : supervised classification of UAV data

The spatial distribution of plant communities was mapped using a supervised classification. The entire UAV dataset, composed of spectral bands and three additional indices (NDVI, NDVI-RE and NDWI; GITELSON et MERZLYAK, 1994; ROUSE et al., 1974; XIE et al., 2018) from the three dates, was processed using one random forest (RF) model (BREIMAN, 2001). RF is an ensemble classifier that generates multiple decision trees by randomly selecting a subset of samples and variables (BELGIU & DRĂGUT, 2016). It is useful for RS data because it is non-parametric and thus does not make assumptions about the distribution of the data, which are rarely Gaussian. Moreover, it provides both

hard and soft classifications that correspond to probability maps of each class considered.

The RF classifier was set up to generate 300 trees. Then, the accuracy, choice of hyper-parameters and robustness of RF classification was assessed by cross validation : the sampling dataset from fields plots was divided into 10 subsets, each containing a nearly equal number of each class. Each subset served successively as learning/validation data, allowing the established model to be tested with 10 different sampling sets. The quality of the classification was assessed using the Kappa index of agreement (KIA) and the overall accuracy (OA). To optimize RF hyperparameters (maximum of features, maximum of leaf nodes, ...), 20 values taken randomly have been tested for each subset for each subset and the best one has been kept (see Appendix D.2). The RF and cross validation were performed using the scikit-learn package in Python (PEDREGOSA et al., 2011).

3.3.3 Step 3 : Estimation of abundances of plant communities

3.3.3.1 State-of-the-art : A priori assumption for analyzing spectral mixtures of plant communities

Two steps are crucial in the unmixing process : selection of endmembers and estimation of abundance. The first requires identifying the spectral signature of each endmember, which is essential because spectral unmixing is entirely dependent on - and thus sensitive to - the choice of endmembers (TOMPKINS et al., 1997). The flooding gradient creates fine-grained spatial variability in plant communities, which makes endmember extraction challenging. To include a wider range of variability, Multiple Endmember Spectral Mixing Analysis (MESMA) was performed, in which each endmember is represented by several spectra (ROBERTS et al., 1998). The second step - estimating the abundance matrix - uses the following equation (Eq. (1)) :

$$X = E \times A \quad (3.1)$$

with X the signal received, E the endmember matrix and A the abundance matrix. Then, MESMA attempts to minimize the residuals (Eq. (2)).

$$[L(X, EA) + P(E, A)] \quad (3.2)$$

with L a loss function (measuring the quality of the estimate) and P a penalty function (to force the equation to achieve desired properties).

In this study, the spectral signal was a mixture of photons that interacted with different plant species, soil and potentially water, which is assumed to be highly non-linear (ASNER, 1998; BOREL & GERSTL, 1994; ROBERTS et al., 1993).

3.3.3.2 SAGA+ unmixing algorithm

The unmixing algorithm used to estimate abundances was SAGA+ (NAKHOSTIN et al., 2016), which is based on the geometric concept of finding the simplex that embeds data. The simplex is calculated in a feature space associated with a kernel, which is useful when analyzing non-linear mixtures. Each vertex of the simplex corresponds to an endmember. Two constraints are imposed on the algorithm to avoid having all endmembers contribute to the estimated solution : 1) the sparsity level (λ), which establishes the threshold below which the abundance of an endmember becomes null, and 2) a maximum number of endmembers per pixel (n_E).

3.3.4 Step 4 : Accuracy assessment and optimization

The accuracy of satellite unmixing was assessed by calculating a fuzzy confusion matrix, which is particularly suitable when using fuzzy classification (BINAGHI et al., 1999). Unmixing can indeed be viewed as a “soft” classifier in which the proportions of classes in each pixel is extracted instead of a single class. Analyzing results with a fuzzy confusion matrix is thus more consistent than analyzing only regression between abundances, since false positives and false negatives are considered. The fuzzy confusion matrix was calculated by comparing estimated abundances to reference abundances from RF probability maps. Like hard classifications, this fuzzy matrix preserves the ability to locate errors and to derive the following indicators from soft classifications : fuzzy OA (OA_f), fuzzy KIA (KIA_f), fuzzy producer’s accuracy (PA_f) and fuzzy user’s accuracy (UA_f). Since the unmixing algorithm is configurable, hyperparameter optimization (Kernel sigma, λ , n_E) was performed using KIA_f as a quality criterion. The setting with the highest KIA_f was selected.

3.3.5 Experiments

3.3.5.1 Influence of acquisition features

The first experiment assessed the influence of the spatial/spectral resolutions of the satellite sensor and the acquisition period on the spectral unmixing results. In May 2018, all types of data were acquired almost simultaneously. Comparing results from Sentinel-2 and Pleiades imagery while performing the same unmixing process would allow the respective influence of the spectral and spatial resolution to be determined. The contribution of the spectral resolution of Sentinel-2 was also tested by comparing the results obtained using its full spectral resolution to those obtained with only the spectral bands similar to those in the UAV data. Since satellite images were acquired on three dates, the influence of the state of habitats (i.e. phenology, winter flooding) during a given period could be identified. Each satellite sensor was compared among the acquisition dates. To identify the tests performed, codes were established that combined the acquisition month (nov, apr, may), satellite sensor (pl, s2) and source of endmember data (sat, uav) (Table 3.2).

Date	Sensor	Images used to extract endmembers	Code
6 Nov 2017	Pleiades	Pleiades	nov-pl-sat
		UAV	nov-pl-uav
20 Apr 2018	Sentinel-2	Sentinel-2	apr-s2-sat
		UAV	apr-s2-uav
18 May 2018	Sentinel-2	Sentinel-2	may-s2-sat
		UAV	may-s2-uav
	Pleiades	Pleiades	may-pl-sat
		UAV	may-pl-uav

TABLE 3.2 – Codes given to the unmixing processes tested.

3.3.5.2 Influence of extracting endmembers from UAV vs. satellite data

The second experiment assessed the potential of UAV data to provide suitable endmembers for unmixing habitats. Two sources of endmembers were distinguished. The classic method consisted of extracting spectra from the satellite imagery that will be processed (case B, Figure 4.4). Their pixels are often assumed to be pure. The locations of sampling plots, acquired with a DGPS with a spatial accuracy of 2–3 cm, were used to extract endmembers. Since plots were separated by 5 m, however, a given pixel – especially

in Sentinel-2 images (10 m spatial resolution) – may have covered two plots. If the two plots did not belong to the same habitat (i.e. the pixel covers two habitats), the corresponding spectrum was removed from the endmember matrix. Since sampling plots covered 2×2 m or less, even Pleiades images may have provided mixed spectral signatures, since the plots did not fit the image geometry perfectly (Figure 3.4). The second method consisted of extracting endmembers from UAV images (case A, Figure 4.4), whose high spatial resolution (0.2 m) allowed us to assume that most pixels were pure (Figure 3.4). Given the high spatial resolution of the UAV data, the number of spectra selected was too large to include all of them in the MESMA unmixing process; thus, the median spectral value was calculated for each sampling plot. This approach extracted endmembers of certain types and patches of vegetation that would not be detectable at lower resolutions because of their small size, such as *U. dioica* patches or bare soils, which are mainly long and narrow, corresponding to cattle pathways on the study site. The extracted endmembers are compared in Appendix D.3.




FIGURE 3.4 – Influence of spatial resolution on the spectral response of survey areas. 1) Sentinel-2 resolution (10 m), 2) Pleiades resolution (2 m), 3) UAV resolution (0.2 m), 4) Example of plant community distribution.

3.3.5.3 Influence of radiometric intercalibration

Combining optical RS data sources requires radiometric intercalibration. Each data source was processed for TOC reflectance. Despite these corrections, interoperability between sensors with different characteristics (e.g. spectral response, point spread function, instantaneous field of view) can produce errors (TEILLET et al., 2007). To address this problem, the domain adaptation method was used (TUIA et al., 2016). This family of methods consists of adapting data when one uses two sources with different characteristics (here, UAV and satellite data) in order to compare them effectively (Appendix D.4). In practice, UAV data are transformed to make them compatible with satellite data.

3.4 Résultats

3.4.1 Floristic typology

Four groups of plants were discriminated, which corresponded to plant assemblages (Appendix D.1) along the flooding gradient (Appendix D.5) :

- Group 1 : mesophilic (M) communities (“E2.1 Permanent mesotrophic pastures and aftermath-grazed meadows” in the EUNIS typology), dominated by *Lolium perenne*, *Poa trivialis* and *Ranunculus repens*, with *Rumex obtusifolius*, *R. crispus*, *Taraxacum officinale* and *Deschampsia cespitosa* as interstitial species.
- Groups 2 and 3 : meso-hygrophilic (MH) communities (“E3.4 : Moist or wet eutrophic and mesotrophic grassland” in the EUNIS typology), with group 2 dominated by *Alopecurus geniculatus* and *Poa trivialis*, with *Carex hirta*, *Ranunculus sardous* and *Potentilla anserine* as interstitial species ; and group 3 dominated by *Eleocharis acicularis* and *Agrostis stolonifera*, with *Ranunculus flammula* as an interstitial species.
- Group 4 : hygrophilic (H) communities (“E3.4 : Moist or wet eutrophic and mesotrophic grassland” in the EUNIS typology), dominated by *Glyceria fluitans*, with *Veronica scutellata* and *Eleocharis palustris* as interstitial species.

3.4.2 Sub-pixel reference map

The supervised classification using RF and applied to multi-temporal UAV data discriminated the four plant communities with an OA of 0.83 (± 0.07) and a KIA of 0.77 (± 0.10). The two MH classes showed confusion between them (Appendix D.6), but once merged into a single MH class, it was discriminated well from the two others (M and H). Once merged, its classification had an OA of 0.90 (± 0.08) and a KIA of 0.85 (± 0.12). Analysis of the confusion matrix (Table 3.3) showed little confusion between the classes; the lowest producer's accuracy (PA) was 0.81 for class H. Nearly all commission and omission errors were between classes M and MH or H and MH. The three other classes considered (water, bare soils and *U. dioica*) were discriminated well, with few confusions. The relative importance of features is shown in Appendix D.7.

		Classification							
	Class	M	MH	H	Bs	Ud	W	PA	UA
Reference	M	31.9	4.4	0.2				0.93	0.87
	MH	2.1	38.8	1.8				0.87	0.91
	H		1.5	8.5				0.81	0.85
	Bs				2.8		0.1	0.98	0.98
	Ud	0.3				3.7		1.00	0.92
	W						3.9	0.99	1.00

TABLE 3.3 – Mean confusion matrix (%) between the random forest classification of three plant communities derived from UAV imagery (columns) and sampling plots (lines). Classes : M – mesophilic; MH – meso-hygrophilic; H – hygrophilic; BS - bare soils; Ud – *Urtica dioica* and W – water. PA : Producer's accuracy, UA : User's accuracy, Bold : True positive rate.

Plant community abundances produced by the RF model (Figure 3.5) highlight the complexity of the spatial distribution of habitats and their ecotones (i.e. transitions between two habitats). Some habitats were well discriminated at the southern end of the site, while the ecotones were fuzzier at the northern end, with interlaced habitats (Figure 3.5a). Habitat distribution logically depended on the topography. Drier locations in highest areas corresponded to M class, and vice-versa for H class. MH class was usually located between them. At the northern end of the site, small dikes on either side of channels with MH class on them were clearly identified (Figure 3.5b). Comparing the distribution of RF-classified

communities to field observations confirmed the accuracy of the mapping, except for one artifact : a depression in the southeast corner of the study site that contained only H class was mapped instead as a pattern of all three classes (Figure 3.5c).




FIGURE 3.5 – Topography and plant communities of the Sougéal marsh. Left : digital surface model derived from UAV RGB data. Right : color composite of wet grassland plant communities in the Sougéal marsh derived from random forest classification of UAV imagery. Insets : a) ecotone, b) class MH on small dikes of channels and c) hygrophilic depression. Classes : M – mesophilic ; MH – meso-hygrophilic ; H – hygrophilic.

3.4.3 Abundance estimation

3.4.3.1 Influence of satellite acquisition features

For May 2018, the best unmixing results were obtained for may-pl-sat ($OA_f = 0.68$ and $KIA_f = 0.53$; Table 3.4). May-pl-sat was more effective than may-s2-sat, with a difference of $+0.10 KIA_f$ points. The two satellite sensors identified class M well, with a

UA_f and PA_f exceeding 0.70 for both (Figure 3.7). However, Sentinel-2 did not detect class MH as well ($PA_f = 0.40$ and $UA_f = 0.64$) as Pleiades ($PA_f = 0.63$ and $UA_f = 0.71$). Both satellite sensors yielded poor results for bare soils, especially Sentinel-2, from whose data accurate endmembers for bare soils could not be extracted. Pleiades (Figure 3.6 g and h) clearly identified the channels, unlike Sentinel-2 (Figure 3.6 e and f). However, the latter provided higher abundances for each habitat with less plant community mixing – compared to those obtained from Pleiades – which is more consistent with field observations. Concerning Sentinel-2 data, applying the same processes to a subset of satellite bands corresponding to those of the UAV yielded identical results for both acquisition dates (apr-s2-sat and may-s2-sat).

Acquisition date		6 Nov 2017		20 Apr 2018		18 May 2018			
Sensor		Pleiades		Sentinel-2		Sentinel-2		Pleiades	
Score		OA_f	KIA_f	OA_f	KIA_f	OA_f	KIA_f	OA_f	KIA_f
Satellite	end-members	0.58	0.40	0.76	0.6	0.60	0.43	0.68	0.53
UAV	endmembers	0.48	0.22	0.64	0.44	0.56	0.40	0.65	0.49
UAV	endmembers (with DA)	0.58	0.38	0.71	0.57	0.65	0.51	0.65	0.51

TABLE 3.4 – Unmixing results by endmember sources for each Sentinel-2 and Pleiades acquisition. OA : overall accuracy, KIA : Kappa index of agreement, DA : domain adaptation.

Comparison of results highlighted the strong influence of acquisition date and solar zenith angle : scores were higher for April and lower for November. For Pleiades, scores were higher for May than for November ($OA_f = 0.68$ and 0.58 , respectively). For Sentinel-2, scores were higher for April than for May ($OA_f = 0.76$ and 0.6 , respectively), while Pleiades yielded a higher score than Sentinel-2 for May ($OA_f = 0.65$ and 0.60 , respectively). Apr-s2-sat discriminated class M ($PA_f = 0.80$ and $UA_f = 0.86$) and class H class better ($PA_f = 0.85$ and $UA_f = 0.62$). Estimated abundances for November showed strong confusion between plant communities for nov-pl-sat (Figure 3.66a and b), while apr-s2-sat showed habitat patterns most similar to the reference map. Estimates for May showed clear but different patterns for classes H and MH.




FIGURE 3.6 – Color composites of wet grassland plant communities in the Sougéal marsh derived from spectral unmixing of a) nov-pl-sat, b) nov-pl-uav, c) apr-s2-sat, d) apr-s2-uav, e) may-s2-sat, f) may-s2-uav, g) may-pl-sat, and h) may-pl-uav. See Table 3.2 for unmixing codes. Classes : M – mesophilic ; MH – meso-hygrophilic ; H – hygrophilic.

3.4.3.2 Influence of endmembers extracted from UAV vs. satellite data

UAV-extracted endmembers rarely estimated abundances better than satellite-extracted endmembers (Table 3.4). May-s2-uav was the only experiment in which UAV-extracted endmembers had better results than satellite-extracted endmembers (+0.08 KIAf points compared to may-s2-sat). The other experiments showed slightly lower OAf or KIAf scores when using UAV endmembers. UAV endmembers did not discriminate habitat classes as clearly as satellite ones (Figure 3.6, darker hues). In certain cases, however, UAV endmembers always improved the PAF for classes that were fuzzier (MH) or covered areas often smaller than satellites' pixel size (water, bare soils) (Figure 3.7). For instance, may-pl-uav endmembers estimated class MH better (i.e. higher PAF) than Sentinel-2 or Pleiades endmembers. UAV endmembers discriminated water better, especially may-pl-uav (PAF = 0.76 and UAF = 0.53). For bare soils, UAV-extracted estimates were similar to those extracted from Pleiades but always better than those extracted from Sentinel-2.




FIGURE 3.7 – Fuzzy producer's accuracy (PAf) and user's accuracy (UAf) by class and unmixing process. See Table 3.2 for unmixing codes. Classes : M – mesophilic; MH – meso-hygrophilic; H – hygrophilic; BS - bare soils; Ud – *Urtica dioica* and W – water.

3.4.3.3 Influence of radiometric intercalibration : domain adaptation

Domain adaptation adjusted the TOC reflectance values acquired with UAV to those of the satellite sensor, thus compensating for radiometric mismatches that remained after correcting each type of RS data (Figure 3.8). Domain adaptation improved data intercalibration for all acquisition dates significantly : improvements were greater for November and April but less pronounced for May. Similarly, intercalibration of UAV data was better with Sentinel-2 data (Figure 3.8c and d) than with Pleiades data (Figure 3.8a and b).

Using domain-adapted UAV endmembers improved all unmixing results, regardless of the date of acquisition (Table 3.5). The mean improvement was +0.09 KIA_f points, but improvement varied among dates (+0.01 to +0.16 KIA_f points, +0.01 to +0.09 OA_f points). The accuracy of the results was strongly correlated with the quality of the intercalibration of the data sources.

3.5 Discussion

Broadly, this study demonstrates that UAVs show great potential to fill the gap between in situ surveys and satellite imagery for providing and improving RS essential biodiversity variables. The spectral unmixing approach allowed for estimation of mixed habitats




FIGURE 3.8 – Scatterplots of UAV vs. satellite reflectance with (red) and without (blue) domain adaptation (DA) for the near infrared spectral band : a) Pleiades on 6 November 2017, b) Pleiades on 20 May 2018, c) Sentinel-2 on 19 April 2018 and d) Sentinel-2 on 19 May 2018.

and overcame the spatial resolution constraint of satellite sensors by providing subpixel information. MESMA has already demonstrated its ability to integrate the variability in heterogeneous plant classes but at lower spatial resolutions (LI et al., 2005; MICHISHITA et al., 2012; ROSSO et al., 2005). When used to map natural or semi-natural habitats, it enables 1) discrimination of community patterns with a grain size smaller than the spatial resolution of the sensor (ROTH et al., 2015) and 2) representation of ecotones between two habitats (HILL et al., 2007).

Data source and date	ΔOAf	$\Delta KIAf$	$\Delta RMSE(NIR)$
Pleiades (6 Nov 2017)	+0.09	+0.16	0.116
Pleiades (18 May 2018)	+0.01	+0.01	0.016
Sentinel-2 (20 Apr 2018)	+0.06	+0.09	0.096
Sentinel-2 (19 May 2018)	+0.09	+0.11	0.048

TABLE 3.5 – Improvements in spectral calibration of UAV data (RMSE) and unmixing results with UAV endmembers (overall accuracy (OAf) and Kappa index of agreement (KIAf)) between applying and not applying the domain adaptation method.

3.5.1 Endmember effectiveness in spectral, spatial and temporal dimensions

Endmember selection remains a challenging task that can be controversial. The dataset used made it possible to evaluate influences of spectral, spatial and temporal dimensions in this crucial step of habitat mapping in flooded and humid grasslands in a temperate oceanic climate.

First, spectral resolution is known to be essential for discriminating wetland plant communities (ADAM et al., 2010), and it is an important feature when analyzing the spectral mixture (BIOUCAS-DIAS et al., 2012). Surprisingly, however, we found that including all Sentinel-2 spectral bands did not improve analysis of the spectral mixture for the Sougéal marsh. The increased spectral resolution from the additional bands (6 red-edge, NIR and mid-infrared bands at 20 m) may not have compensated for the decrease in the spatial resolution. This study also shows that spectral intercalibration of RS data is crucial to perform unmixing of satellite data with endmembers from a different source. Even though data were radiometrically corrected to produce TOC reflectance, mismatches in spectral values remained between UAV and satellite data, especially in the green and NIR bands (Appendix D.8). Overestimation of spectral values by the UAV’s Sequoia multispectral sensor is suspected because its grassland reflectances exceeded 0.6 in the NIR. Domain adaptation overcame these problems, although testing the quality and interoperability of the sensor is required for future scientific studies.

Second, most endmembers extracted from high-spatial-resolution imagery yielded better results. Pleiades, with a spatial resolution 5 times as high as that of Sentinel-2, yielded better results in May 2018. One can assume that the VHSR images of Pleiades make it possible to extract endmembers that are not influenced by potential class mixtures (ROTH et al., 2015). Higher-spatial-resolution UAV data can also help extract a pure spectral si-

gnature, but also one that could be too specific, depending on the grain size of plant community patterns. Nonetheless, UAV endmembers always improved discrimination of the meso-hygrophilic class, which is floristically more heterogeneous because of variations in flooding throughout the year (BONIS, 2014). This result suggests that endmembers from VHSR data are more suitable for heterogeneous classes, for which acquisition of pure pixels is more complicated. In future studies, VHSR data could be used to purify endmember spectral bands by identifying and eliminating endmembers influenced by the background (BIAN et al., 2016 ; MA et al., 2015).

Finally, this study strengthens the ability of RS data to discriminate plant communities better during specific periods. Like RAPINEL, MONY et al., 2019, acquiring images in early spring (April), near the biomass peak and flowering of plants, appears to help discriminate plant communities greatly (FEILHAUER et al., 2013). The grain size of plant community patterns may vary among periods depending on the hydrological regime (CORRIALE et al., 2013 ; TODD et al., 2010). The differences in spatial patterns identified between the periods studied (e.g. hygrophilic habitat in April and May) were likely due to confusion caused by certain species common to several habitats but not present in all vegetation belts, due to the flooding gradient over time, which causes spatial and temporal phenological shifts. Depending on land use, vegetation types and vegetation dynamics (i.e. during the acquisition period), selection of endmembers can be even more subtle than expected. Hence, integrating multi-temporal endmembers when a phenological gradient is present is an interesting prospect (DUDLEY et al., 2015).

3.5.2 Synergies among *in situ*, UAV and satellite data

UAV technology shows great potential for successfully mapping habitats of the Sougéal marsh at a spatial resolution never achieved before (20 cm). VHSR imagery played two major roles in this study : clarifying and validating satellite data. First, UAV data were used to extract “pure” endmembers to clarify satellite data using the unmixing algorithm (SCHAAF et al., 2011), which estimated plant community abundances. Second, combining UAV data with in situ surveys provided a spatially exhaustive ground truth to assess these estimated abundances. However, the accuracy of the reference map can be questioned, because spatial and temporal phenological shifts could contribute to a failure to discriminate habitats properly. For instance, ecotones can represent one of these shifts, ultimately belonging to one habitat rather than a mixture of two. Moreover, grazing activities (May–November) are likely to influence spectral signatures of plant communities

and may lead to local misclassifications. Producing a monthly time series of UAV data, for instance, would help discriminate these habitats by monitoring floods and vegetation phenology.

This study focused on spectral complementarities between UAV and satellite data. Spatial and temporal complementarities still need to be explored. Indeed, UAV data provide high-resolution textural (vegetation patterns or heterogeneity) and topographical information that can be useful for habitat mapping. These spatial features can complement spectral information to differentiate complex environments in which vegetation communities have a strong spectral similarity (W. ZHAO & DU, 2016). Object-oriented approaches that include texture information allow for multi-scale analyses (MOFFETT & GORELICK, 2013; TUXEN & KELLY, 2008) and could be used with a convolutional neural network to automatically extract multi-scale spatial features. This method has proven to be even more effective for wetland mapping (MAHDIANPARI et al., 2018; REZAEI et al., 2018) than traditional classifiers such as RF. Finally, an interesting perspective for combining UAV and satellite data is spatio-temporal fusion, which allows for modeling of high-resolution images using two data sources, one at high spatial resolution and the other at high temporal resolution (CHEN et al., 2015).

3.5.3 Remote sensing : A proxy of the state of biodiversity

Using UAVs for RS provides good discrimination or estimation of wetland habitats at level 3 of the EUNIS typology on the Sougéal marsh, despite grazing, which prevents vegetation from developing fully. Classifying species groups into plant communities is based essentially on the presence of certain species that characterize the habitat ; however, the abundances of all of its constituent species contributes most to the spectral signature of the plant community. The spectral signal acquired does not make it possible to identify the typical species of the community, which may have low abundance. On the contrary, the dominant species in the community contribute the most to the spectral signature. Nonetheless, this study demonstrates that UAV data have great potential to enhance discrimination of herbaceous habitats in humid grasslands at a fine level of nomenclature (typological resolution below EUNIS level 3), whether combined with satellite data or not.


Habitat mapping has been recognized for more than 40 years as a good proxy of biodiversity. Beyond its assessment of habitat types, this study also demonstrates that some indices of conservation status can be estimated in wetland habitats, such as the

proliferation of eutrophic species (*U. dioica*) or the occurrence of local disturbances due to intensive grazing (i.e. bare soils). This opens new avenues for using UAV technology in a broader objective of analyzing the ecosystem functioning related to habitat presence, distribution and ecological status.

3.6 Conclusion

This study evaluated the utility of UAV data to fill the gap between in situ survey and satellite data for habitat mapping. The main results showed that UAVs have great potential for habitat mapping : they are flexible (allowing data to be acquired at the same time as satellite data), can map habitats on small areas (up to ca. 100 ha) effectively and provide training (endmember) and validation (habitat class) data for unmixing high-temporal-resolution satellite multispectral data, such as Sentinel-2 (10 m) or Pleiades (2.4 m). Fuzzy classifications of mesophilic, meso-hygrophilic and hygrophilic communities were produced with good to reasonable accuracy when combining UAV endmembers and satellite data, although the study revealed some technical limitations and the challenge of mapping of these habitats. For the former, although it is necessary to intercalibrate sensors to increase the accuracy of habitat maps, domain adaptation can overcome spectral mismatches. For the latter, some acquisition periods were more suitable than others. The influence of climate, hydrological regimes and land use (here, grazing) may lead to spatial and temporal shifts in habitat phenology, making it difficult to discriminate boundaries of flooded grassland habitats accurately. However, UAV data contribute to early detection of invasive species or land degradation whose mean area remains smaller than the spatial resolution of satellite images. Future work is needed to benefit fully from potential synergies between satellite and UAV data for environmental applications. Although focused only on spectral synergies, this study identified promising improvements by combining spatial and temporal characteristics.

FUSION DE DONNÉES : CARTOGRAPHIE DES DYNAMIQUES D'INONDATION DE PRAIRIE HUMIDE



Dans ce chapitre, la fusion des données drone et satellite est abordée. Il s'agit de la synergie la plus forte, au niveau de l'intégration des données. Dans le chapitre précédent, il a été démontré que le drone peut fournir une information spectrale utile au démelangeage des pixels satellitaires. Sans améliorer la résolution spatiale, cette approche permet le changement d'échelle en apportant une information sub-pixelique qui rend compte de la nature floue/graduelle des communautés végétales. Ici, l'objectif est d'améliorer la résolution spatiale des observations satellitaires en exploitant l'information spatiale à résolution fine fournie par le drone. Pour cela, une approche de super-résolution par fusion de données est utilisée. Le modèle est basé sur un réseau de neurones de type FCN pour l'extraction de caractéristiques spatiales multi-échelles. Cette approche est appliquée à la fusion de données multispectrales satellitaires et d'un MNT à résolution fine pour la prédiction des dynamiques d'inondation en prairies humides. Toujours dans la volonté de produire une représentation qui restitue les gradients environnementaux, le modèle est dédié à la cartographie des hauteurs par régression et non à la simple cartographie de l'extension spatiale des surfaces inondées par classification.

Ce chapitre fait l'objet d'un article qui sera soumis prochainement et intitulé "*UAV and satellite data fusion for monitoring the spatio-temporal dynamics of floods in wet grasslands*".

4.1 Introduction

Le fonctionnement écologique, hydrologique et agropastoral des écosystèmes de prairies humides est principalement régi par ses dynamiques d'inondation (BONIS, 2014). Celles-ci se caractérisent par des paramètres comme l'extension spatiale, la hauteur et la durée de résidence des eaux de surface. Mesurer les dynamiques d'inondation est essentiel pour comprendre et gérer leurs effets sur les milieux de prairies humides. De plus, améliorer ces connaissances permet de mieux appréhender les enjeux et conflits de gestion du niveau de l'eau. Les gestionnaires recherchent le meilleur compromis possible entre les différents usages de ces milieux : gestion hydraulique pour favoriser la reproduction piscicole (frayère à brochets par exemple), limitation des perturbations de l'avifaune en période de nidification, exondation pour un pâturage précoce des prairies, etc. Cependant, cartographier les dynamiques d'inondation en prairie humide n'est pas facile car c'est un milieu avec une forte variabilité spatio-temporelle. Collecter ces paramètres sur le terrain est une procédure longue et fastidieuse, difficilement adaptable à des échelles spatiales et temporelles fines. Le manque de mesures est un enjeu majeur étant donné l'importance de ces paramètres dans le fonctionnement des prairies humides.

Les dynamiques d'inondation des prairies humides présentent une variabilité spatio-temporelle. La variabilité spatiale est due à l'hétérogénéité du contexte topographique et à la conductivité hydraulique des sols qui vont créer des discontinuités hydrologiques (HAYASHI et al., 2016). Ces facteurs divisent un site en unités hydrogéomorphologiques (HGMU), c'est-à-dire des portions de l'espace dont la réponse hydrologique est homogène vis-à-vis des sollicitations extérieures (Figure 4.1). Quant à la variabilité temporelle, elle provient des variations de précipitations à l'échelle du bassin versant, donc des facteurs climatiques et météorologiques. Cette variabilité peut être captée à différentes échelles temporelles : les dynamiques inter-annuelles, saisonnières et les événements ponctuels (ex : les inondations rapides). Ces différentes échelles requièrent des séries de données sur le long terme mais avec une fréquence d'acquisition assez importante pour capter des événements spontanés. Les sondes piézométriques *in-situ* (leur fonctionnement est détaillé dans la partie 4.2.2) permettent de capter efficacement ces dynamiques temporelles, en revanche elles sont restreintes à la mesure d'une seule HGMU et donc ne rendent pas compte de la variabilité spatiale du site. De plus, les zones humides de plaine alluviale sont très peu dotées en réseau de sonde bien qu'elles participent significativement aux flux d'eau.




FIGURE 4.1 – Différenciation de la réponse hydrologique en fonction du contexte topographique et pédologique du site. Les surfaces en pointillé représentent une couche du sol à faible conductivité hydraulique permettant le maintien d'une mare éphémère. La mare permanente est maintenue tout le long de l'année via les décharges de la nappe souterraine.

Récemment, la télédétection optique a largement été utilisée pour suivre les dynamiques d'inondation car elle fournit des observations spatialement explicites avec une bonne fréquence temporelle (NOTTI et al., 2018 ; YAN et al., 2015). La haute résolution temporelle permet un suivi intensif des dynamiques des eaux de surfaces, tandis que les hautes résolutions spatiales et spectrales assurent respectivement la précision et la certitude de la délimitation des surfaces en eau. Cependant, aucun système d'observation seul ne peut fournir tous ces avantages simultanément. Il est nécessaire d'utiliser des méthodes de changement d'échelle et de fusion de données pour capter précisément la variabilité spatio-temporelle des niveaux d'eau. Des méthodes avancées telles que le démélangeage spectral, l'interpolation temporelle ou la fusion de données ont été utilisées pour améliorer à la fois la résolution spatiale et temporelle (HUANG et al., 2018). Cependant, ces études concernent principalement les paramètres d'extension spatiale et de durée de résidence sans tenir compte des Hauteurs d'Eau (HE).

Nous nous intéressons ici à la réalisation d'une Cartographie Sub-pixellique des Hauteurs d'Eau (CSHE) à l'aide de l'imagerie satellitaire et d'un MNT à résolution fine. Le MNT est très intéressant pour la modélisation à la fois de l'extension spatiale et de la HE, la répartition spatiale de l'eau étant largement contrôlée par la topographie. L'approche la plus courante consiste à intersecter une cartographie de l'extension spatiale des surfaces inondées à résolution grossière avec un MNT à résolution fine (LING et al., 2008 ; SCHAFFER-SMITH et al., 2018 ; ZWENZNER & VOIGT, 2009). Cette approche a l'avan-

tage d'être simple mais présente quelques inconvénients : 1) elle est sensible aux erreurs de classification, 2) la précision reste dépendante de la résolution spatiale de la donnée satellitaire, et 3) elle est dépendante d'une distinction nette entre surfaces inondées et non-inondées.

Dans cette étude, nous proposons de traiter le problème de la CSHE comme un problème de super-résolution (YUE et al., 2016), c'est-à-dire reconstruire une image HR (carte des HE) à partir d'une image LR (image Sentinel-2). Le satellite Sentinel-2 fournit des séries temporelles d'images multispectrales dont le potentiel a déjà été démontré pour la cartographie de surface en eau (MERCHANT, 2020) ou encore pour de la bathymétrie par inversion de modèle (CASAL et al., 2020). Pour faciliter le changement d'échelle, nous exploitons également l'information topographique via un MNT. La technologie drone rend la production de MNT à haute résolution spatiale facile et accessible grâce aux traitements photogrammétriques (ANNIS et al., 2020 ; SCHUMANN et al., 2019). Pour exploiter à la fois l'information spectrale et topographique, nous utilisons un modèle de fusion de données basé sur les CNN. Plus précisément, l'architecture *UNet* (RONNEBERGER et al., 2015) a été adaptée pour permettre la fusion de données multi-sources. Des approches similaires ont également exploité *UNet* pour la cartographie bathymétrique (MANDLBURGER et al., 2021 ; SONOGASHIRA et al., 2020). Cependant, la cartographie des dynamiques d'inondation en prairie humide se différencie de la bathymétrie par des gammes de HE beaucoup moins importantes. Nous supposons que l'apport de la micro-topographie par la donnée drone peut aider à détecter des faibles variations de HE.

L'étude est structurée de la manière suivante : La Section 4.2 introduit les sites d'étude du marais du Couesnon ainsi que le jeu de données multi-échelle et multi-source. La section 4.3 détaille la méthodologie basée sur l'algorithme *UNet*. Les hyperparamètres et les expérimentations menées sur la robustesse et la sensibilité du modèle y sont présentés. La section 4.4 présente les résultats sur la modélisation des dynamiques d'inondation sur deux sites afin d'évaluer les performances et la transférabilité du modèle. La section 4.5 discute de manière critique les résultats. Enfin, la section 4.6 résume les principaux résultats et introduit des perspectives pour de futures études.

4.2 Matériels

4.2.1 Sites d'étude

Cette étude a été menée sur la zone humide de la basse vallée du Couesnon (France, 48.52° N, 1.53° W) qui fait partie du site *Long Term Socio-Ecological Research* (LTSER) "Zone Atelier Armorique". Cette zone humide occupe la plaine alluviale de la rivière du Couesnon et est située à une vingtaine de kilomètres de son exutoire (Figure 4.2.a et .b). Elle est incluse comme sous-site du site Natura 2000 de la "Baie du Mont-Saint-Michel" en raison de sa haute valeur de conservation. Le site peut être découpé en quatre sous-ensembles distincts, aux caractéristiques paysagères et aux modes de gestions spécifiques. Nous nous intéressons à deux de ces sous-ensembles :

- Le marais de Sougéal (175 ha), situé sur la rive gauche. Le fonctionnement hydrologique du marais est principalement associé aux débordements du Couesnon. L'augmentation des débits en période hivernale associée aux diverses entrées d'eau dans le marais entraînent des inondations fréquentes sur la période de décembre à mars. La gestion à l'aide de portes à flots et d'un réseau de drainage permet de maintenir le stock d'eau jusqu'à la mi-avril avant une vidange progressive afin de se fixer sur le cycle biologique du brochet et de favoriser leur reproduction. De la mi-mai jusqu'à janvier les portes à flots sont remises en place afin de protéger d'éventuelles crues de fin de printemps et d'automne. La microtopographie divise le site en HGMU (Figure 4.2.c) : deux unités principales reliées au réseau de canaux divisent le marais entre le Nord et le Sud et neuf unités adjacentes sont déconnectées du réseau hydrographique permettant la formation de mare temporaire.
- Le marais d'Aucey (130 ha), situé sur la rive droite. Ce sous-ensemble se distingue par son important caractère bocager. Le réseau hydrographique, associé au réseau bocager, est très dense et permet d'assainir le marais afin d'y faciliter l'activité agricole. Ainsi, il se compose d'une unique HGMU.

4.2.2 Données

Cette étude combine plusieurs sources de données : *in-situ*, aéroportées et satellitaire. Les images satellitaires et aéroportées (multispectrales et MNT) sont les données d'entrée




FIGURE 4.2 – Localisation et caractéristiques hydrogéomorphologiques des marais de Sougéal et d'Aucey : a) Localisation à l'échelle européenne ; b) Localisation à l'échelle du bassin versant (fond de carte : Représentation hypsométrique du relief métropolitain par l'IGN) ; c) caractéristiques hydrogéomorphologiques des marais de Sougéal et d'Aucey et localisation des piézomètres sur les sites ; (fond de carte : MNT provenant des données drone et LiDAR). Les HGMU connectées et déconnectées au réseau hydrographique (canaux de drainage et rivière du Couesnon) sont représentées sur le site d'étude.

au modèle, tandis que les mesures *in-situ* provenant des piézomètres servent de "vérité terrain" pour calibrer et évaluer le modèle, celui-ci cherchant à estimer les hauteurs d'eau.

Les piézomètres sont des sondes submersibles qui mesurent de manière ininterrompue et sur du long terme les niveaux d'eau à la surface et/ou sous le sol à l'aide de capteur de pression. Quatre sondes piézométriques ont été installées dans les marais du Couesnon en 2017 (voir Figure 4.2.c). Dans le marais de Sougéal, les sondes *PZ1* et *PZ2* mesurent, respectivement, les HGMU Nord et Sud, tandis que *PZ3* contrôle le niveau d'eau dans une HGMU annexe et non-connectée au réseau hydrographique. Le marais d'Aucey est observé par la sonde *PZ4*. Ce réseau de piézomètres permet de rendre compte de la variabilité

spatio-temporelle (Figure 4.3). Temporellement, il y a peu de variations inter-annuelles en moyenne. Par exemple, la moyenne des HE sur PZ2 oscille entre 6.14 m (2017) et 6.25 m (2018) mais avec des dynamiques saisonnières qui peuvent varier. Celles-ci montrent en moyenne une période humide de décembre à mai et un maximum de l’assèchement vers septembre-octobre. Ponctuellement, de fortes inondations arrivent pendant la période humide comme les deux pics visibles entre novembre 2019 et janvier 2020. La répartition des piézomètres nous permet de rendre compte de la variabilité spatiale de diverses HGMU des marais de la basse vallée du Couesnon. Chaque piézomètre enregistre la même tendance avec un décalage plus ou moins prononcé qui peut aller jusqu’à 60 cm au sein du site du marais de Sougéal et plus de 1 m entre les deux marais.

Deux MNT sont utilisés pour couvrir l’ensemble des sites d’études. Le premier couvre le marais de Sougéal et est généré par photogrammétrie à partir d’imageries aériennes par drone. Les images sont acquises par un eBee+ (SenseFly, Cheseaux-sur-Lausanne, Suisse), une aile-volante auto-guidée de 1.2 kg. Avec des conditions de vol favorables (faible vent), le temps de vol est de 60 min à une hauteur de 120m au-dessus du terrain (limite supérieure autorisée par la législation française). Le capteur embarqué est le *SODA* (SenseFly, Cheseaux-sur-Lausanne, Suisse), une caméra RGB à 20 MP dédié à la photogrammétrie professionnelle. Cette configuration permet de générer un MNT avec une résolution au sol de 5 cm à l’aide du logiciel *Pix4Dmapper* (Pix4D S.A., Prilly, Suisse). Le MNT est ré-échantillonné à 1 m afin de diminuer le facteur d’échelle avec la donnée satellitaire et diminuer les temps de calcul. Les acquisitions ont été effectuées pendant l’été 2020 lorsque le pâturage est bien avancé afin d’avoir une végétation rase. Des corrections manuelles ont été appliquées afin d’éliminer des ensembles de végétation résiduels et les animaux présents lors de l’acquisition. La précision verticale est estimée à 9 cm (+/- 6 cm) à l’aide d’un GNSS différentiel. Le second MNT, qui couvre le marais d’Aucey, est généré à partir d’un relevé LiDAR à 1 m de résolution au sol provenant de la base de donnée *RGE ALTI* de l’IGN. La donnée a été acquise en novembre 2011 et possède une précision verticale de 9.5 cm (+/- 6.6 cm). Nous supposons ici que les changements topographiques sont négligeables sur la période étudiée.

La série de données multispectrales satellitaires provient de la mission Sentinel-2 (ESA) qui fournit de l’imagerie à haute résolution avec une fréquence de revisite de 5 jours. L’imageur multispectral (MSI) de Sentinel-2 fournit 13 bandes spectrales avec une résolution au sol de 10 à 60 m, seulement les bandes à 10 m et 20 m sont utilisées pour cette étude. Les données sont pré-traitées au niveau L2A par le CNES, elles sont donc orthorectifiées et




FIGURE 4.3 – Dynamiques hydrologiques mesurées par les sondes piézométriques et acquisitions Sentinel-2 de 2017 à 2021

corrigées pour obtenir une réflectance du haut de la canopée. La correction radiométrique a été effectuée par la chaîne de traitement MACCS (HAGOLLE et al., 2015) et l'erreur de positionnement est estimée à 12.5 m (DECHOZ et al., 2015). La série de données comprend 74 dates entre le 01-01-2017 et le 23-04-2021 (Figure 4.3). La série a été filtrée pour sélectionner les images sans nuages. Les acquisitions sont majoritairement sélectionnées

lors de la période humide afin d'éviter un déséquilibre de représentation entre les surfaces inondées et non-inondées, cependant on constate que les périodes les plus humides sont souvent manquantes dû à la présence de nuage.

4.3 Méthodes

L'approche consiste à fusionner deux sources d'informations utiles à l'estimation des HE de surface : la signature spectrale d'un pixel satellitaire et l'altitude à haute résolution spatiale. La fusion de données est effectuée à travers un modèle d'apprentissage profond adapté à la fusion de données et à la super-résolution. Un schéma général de l'approche proposée est montré dans la Figure 4.4. Les différentes étapes sont développées dans les sous-sections suivantes : 1) la préparation et l'augmentation des données d'entrée, 2) la génération des données de référence, 3) l'architecture du modèle *Fusion-UNet*, et 4) une fonction de coût mixte adaptée à la super-résolution. Une dernière sous-section présente les expérimentations et les métriques pour évaluer les performances et la sensibilité spatio-temporelle du modèle.




FIGURE 4.4 – Schéma général de l'approche de cartographie subpixelique des hauteurs d'eau basé sur Fusion-UNet. L'étape d'augmentation de donnée n'est appliquée que pendant la phase d'apprentissage.

4.3.1 Préparation des données

Pour permettre la calibration et l'évaluation du modèle, le jeu de données est divisé en trois parties : apprentissage, validation et test. Pour assurer une indépendance entre les sous-ensembles du jeu de données, une division temporelle est effectuée. Ainsi, le jeu d'entraînement rassemble les données du marais de Sougéal sur les années 2017 à 2019 incluses, le jeu de validation sur l'année 2020 et le jeu de test sur l'année 2021.

4.3.1.1 Normalisation et augmentation des données

En premier lieu, l'ensemble des données a été divisée en tuiles de 112x112 pixels afin d'éviter des problèmes de mémoire RAM et le traitement de zones sans données. Les données sont, ensuite, standardisées dans une gamme de valeur entre 0 et 1. Concernant les données multispectrales et de référence de HE, une transformation logarithmique est, dans un premier temps, appliquée. Dans un second temps, toutes les données sont étalées linéairement entre 0 et 1.

Pour assurer une indépendance entre les jeux de données, nous avons appliqué une étape d'augmentation des données avant d'alimenter le modèle avec celles-ci. Le MNT étant invariant entre les différentes dates d'acquisition, c'est donc une information redondante entre les différents lots de données mais aussi entre les jeux d'apprentissage et de validation. Cette étape consiste à transformer les données par un ou plusieurs procédés (voir Figure 4.5) ce qui permet également d'élargir le domaine d'apprentissage en insérant plus de variabilité et donc permettre de mieux généraliser le problème.




FIGURE 4.5 – Séquence de transformation pour l'augmentation des données. La probabilité des différentes transformation est désignée par p .

4.3.1.2 Génération des données de référence

Les données de référence sont générées à partir des relevés piézométriques et du MNT. Pour chaque date d'acquisition de Sentinel-2, une HE moyenne journalière est estimée par piézomètre. Cette hauteur moyenne représente alors la hauteur du plan d'eau pour une HGMU. Pour chaque HGMU observée, le gradient de HE est calculé en soustrayant l'élévation du sol (MNT) à la hauteur du plan d'eau. Ensuite, les données sont validées par photo-interprétation des images Sentinel-2 afin de constater la cohérence de l'extension spatiale des surfaces inondées visibles par les différentes sources de données. Dans

RAPINEL, ROSSIGNOL, GORE et al., 2018, les auteurs ont montré que cette approche permet de restituer la variabilité spatio-temporelle des dynamiques d'inondation en intégrant les subtilités de la topographie.

4.3.2 Modèle de super-résolution adapté à la fusion de données

4.3.2.1 Architecture du réseau de neurones

La fusion de donnée pour estimer les HE est faite via un réseau de type *UNet*. Comme vu dans la section 2.3.1, un tel réseau apprend automatiquement des descripteurs (cartes de caractéristiques) qui sont généralement difficiles à définir manuellement. L'architecture est composée de blocs de convolutions qui permettent d'encoder l'information, et de blocs de déconvolutions qui permettent de recouvrer une information au niveau du pixel. Les déconvolutions prennent en compte le niveau précédent et les données encodées à la même résolution afin de garder des détails.

Pour permettre la fusion entre l'imagerie multispectrale et le MNT, l'architecture du modèle *UNet* a été adaptée. Ce type de fusion est connu dans la communauté de la vision par ordinateur comme le traitement d'images 2.5D (RGB + Profondeur). Dans AUDEBERT et al., 2018, les auteurs proposent différentes stratégies de fusion qui permettent d'aller au delà de la simple concaténation des données en entrée. Ils traitent chaque source de donnée dans des branches d'encodages séparées. Inspirés par ces travaux, nous avons appliqué une fusion précoce à l'aide d'une troisième branche "virtuelle" qui permet la fusion pendant l'encodage de manière symétrique, c'est à dire en traitant les deux sources de données de manière indépendante. Cette approche, qui encode séparément et en parallèle les deux sources de données à travers des blocs de convolution, permet d'éviter des déséquilibres provenant de la nature différente des sources de données. Ensuite, à chaque niveau de décodage, la fusion est effectuée en sommant les sorties des blocs des deux branches correspondantes de l'encodage. Ce sont les cartes de caractéristiques fusionnées de cette branche "virtuelle" qui sont utilisées pour effectuer les connexions explicites (et aussi au niveau d'encodage le plus bas). De plus, dans notre modèle, une étape de régularisation avec une normalisation du *batch*¹ (IOFFE & SZEGEDY, 2015) a été ajouté aux blocs originaux. L'architecture du modèle *UNet* adaptée à la fusion de données (*Fusion-UNet*) est montrée dans la Figure 4.6. Les hyperparamètres du modèle ont été sélectionnés de

1. La normalisation du *batch* est une méthode utilisée pour rendre les réseaux de neurones plus rapides et plus stables via une normalisation (centré-réduit) des couches d'entrées.

manière expérimentale (Annexe E.1). Le modèle a été développé sous *Pytorch* (PASZKE et al., 2019) et est disponible sur *Gitlab*.




FIGURE 4.6 – Architecture du modèle Fusion-UNet. Les boîtes bleues claires correspondent à des cartes de caractéristiques multi-canaux. Les boîtes bleues foncées correspondent aux blocs de convolution. Les boîtes blanches correspondent aux cartes de caractéristiques copiées et concaténées pour effectuer les *skips connections*.

4.3.2.2 Fonction de coût

L'étape d'apprentissage de notre modèle consiste à estimer les paramètres du réseau de neurones en cherchant à réduire l'écart entre l'image générée par le réseau, $\hat{y}$, et l'image de référence, y . Cette différence est capturée au travers d'une fonction, nommée "fonction de coût", qu'on va chercher à minimiser. En pratique, nous avons choisi une fonction de coût mixte, $\ell_{mixte}(y, \hat{y})$, qui intègre des critères à la fois de perception, de contenu et de segmentation. Nous avons donc cherché à estimer l'ensemble des paramètres du réseau de neurones (dont les coefficients de convolution), nommés θ , en résolvant le problème suivant :

$$\theta = \arg \min_{\theta} (\ell_{mixte}(y, g_{\theta}(x)))$$

avec g_{θ} la fonction liée au réseau de neurones, qui prend en entrée x (le couple composé de l'image et du MNT) et qui estime $\hat{y} = g_{\theta}(x)$, l'image des hauteurs d'eau. En ce qui

concerne la fonction de coût, elle est structurée de la manière suivante :

$$\ell_{mixte}(y, \hat{y}) = \ell_{percep.}^{\phi,j}(y, \hat{y}) + \ell_{cont.}(y, \hat{y}) + \lambda_s \ell_{seg.}(y, \hat{y})$$

où :

- $\ell_{percep.}^{\phi,j}(y, \hat{y})$ est une fonction de perception qui va encourager l'image générée à avoir des caractéristiques de différent niveaux similaires à l'image de référence (JOHNSON et al., 2016). Ces caractéristiques sont calculées à l'aide d'un réseau pré-entraîné ϕ , dans notre cas il s'agit de VGG-16 (SIMONYAN & ZISSERMAN, 2015). La valeur de $\phi_j(x)$ représente les sorties de la j ème couche du réseau ϕ quand l'image x est traitée. Puisque j est une couche de convolution alors $\phi_j(x)$ renvoie une carte de caractéristiques dont la taille $C_j \times H_j \times W_j$ dépend du niveau de convolution j . La fonction de coût de perception est alors la distance L_1 entre les représentations des caractéristiques :

$$\ell_{percep.}^{\phi,j}(y, \hat{y}) = \frac{1}{C_j H_j W_j} |\phi_j(\hat{y}) - \phi_j(y)|$$

De telles fonctions sont dites "perceptuelles" car il a été observé que les caractéristiques issues de réseaux entraînés sur de grandes bases de données (comme *VGG-16*) sont des descripteurs pertinents et mettent en jeu des critères perceptuels dans l'image

- $\ell_{cont.}(y, \hat{y})$ est une fonction de coût du contenu, c'est-à-dire que contrairement à la fonction de perception, elle encourage les pixels de l'image générée à correspondre exactement avec la référence. Elle correspond à la distance L_1 entre les deux images (de taille $H \times W$ qui est la taille des données de référence) :

$$\ell_{cont.}(y, \hat{y}) = \frac{1}{HW} |\hat{y} - y|$$

- $\ell_{seg.}(y, \hat{y})$ est une fonction de coût de segmentation qui force à considérer les surfaces non-inondées comme des HE à 0 m. Pour calculer cette fonction, les HE sont regroupées en 2 classes : eau (HE > 0 m) et non-eau (HE ≤ 0 m). Cette reclassification, nous permet de considérer un problème de segmentation sémantique et d'appliquer une fonction de coût d'intersection-sur-union (IoU) :

$$\ell_{seg.}(y, \hat{y}) = 1 - \frac{TP}{FP + TP + FN}$$

où, TP , FP et FN correspondent respectivement aux vrais-positifs, les faux-positifs et les faux-négatifs. Un coefficient λ_s est appliqué à cette fonction de coût afin d'ajuster la gamme de valeur avec les autres fonctions.

4.3.3 Évaluation du modèle

4.3.3.1 Expérimentations

L'évaluation du modèle est effectuée à travers les expérimentations suivantes :

- Évaluation de l'apport du modèle *Fusion-UNet* et de la donnée MNT en comparant notre modèle avec le modèle original *UNet* selon deux configurations : avec (*UNet-MNT-S2*) et sans la donnée MNT (*UNet-S2*) en tant que donnée auxiliaire en entrée du modèle.
- Évaluation de la sensibilité spatiale du modèle sur la période de validation en comparant la précision des prédictions face aux mesures par piézomètres sur les trois HGMU du marais de Sougéal équipé d'une sonde (*PZ1*, *PZ2* et *PZ3*).
- Évaluation de la sensibilité temporelle en calibrant le modèle avec différentes configurations temporelles du jeu de donnée. Une validation croisée à 4 blocs² est effectuée à travers des configurations comprenant 1, 2 ou 3 années pour l'apprentissage. Pour la validation croisée à 4 blocs, le jeu de données est divisé entre les années hydrologiques 2017, 2018, 2019 et 2020.
- Évaluation de la transférabilité du modèle sur le site du marais d'Aucey. Le site est couvert par les mêmes dates pour l'imagerie Sentinel-2. En revanche, le MNT ne provient pas du drone mais d'une acquisition LiDAR.

4.3.3.2 Métrique d'évaluation

Pour évaluer les performances des modèles sur N données estimées $\{\hat{y}_1(i, j), \dots, \hat{y}_N(i, j)\}$ (les valeurs (i, j) étant les coordonnées des pixels dans l'image), nous utilisons une métrique d'erreur absolue moyenne ajustée (EAM_{aj}) qui compare les estimations $\hat{y}(i, j)$ avec

2. La validation croisée à k blocs : on divise le jeu de données original en k blocs, puis on sélectionne un des k blocs comme jeu de validation pendant que les $k - 1$ autres constituent le jeu d'apprentissage. Après apprentissage, on peut calculer une métrique d'évaluation. Puis on répète l'opération en sélectionnant un autre jeu de validation parmi les blocs prédéfinis. La moyenne et l'écart type des k scores de performances obtenus peuvent être calculés pour estimer le biais et la variance de la performance de validation.

les données de références $y(i, j)$ et se base sur l’erreur absolue moyenne (EAM), dont la formule est la suivante :

$$EAM = \frac{1}{N \times H \times W} \sum_{k=1}^N \sum_{i=1}^L \sum_{j=1}^C |\hat{y}_k(i, j) - y_k(i, j)|$$

où H et W correspondent respectivement au nombre de colonne et de ligne de l’image. Étant donné la forte disparité dans la distribution des HE des données de référence - les zones non-inondées et faiblement inondées sont sur-représentées dans le jeu de données - l’utilisation du EAM, seule, peut alors paraître biaisée. C’est pourquoi nous ajustons cette métrique en ré-équilibrant la contribution des HE dans le calcul de celle-ci. L’échantillon est alors divisé en G gammes de HE de 10 cm, soit : $[HE = 0]$, $]0 < HE \leq 10]$, ... , $]G - 10 < HE \leq G]$. La EAM-ajustée correspond alors à la moyenne des EAM de chaque gamme, soit :

$$EAM_{aj} = \frac{1}{G} \sum_{k=0}^G EAM_{10(k-1) < HE \leq 10k}$$

La variabilité de l’EAM entre les différentes gammes de HE est également prise en compte.

4.4 Résultats

4.4.1 Sélection du modèle

L’évaluation des performances de chaque modèle est présentée dans le Tableau 4.1. Le modèle *UNet-S2* présente les moins bonnes performances avec un EAM_{aj} de 0.16 m sur le jeu de données de test. Sur ce même jeu de donnée, les modèles *UNet-MNT-S2* et *Fusion-Unet* montrent tous les deux de meilleures performances avec un EAM_{aj} de 0.09 m. Cependant, sur les jeux de données d’apprentissage et de validation, *Fusion-Unet* surpasse légèrement *UNet-MNT-S2* de +0.01 m. Quel que soit le modèle, les résultats sur le jeu de données de validation et de test sont meilleurs que sur l’apprentissage. Enfin, le modèle de fusion présente les meilleurs résultats.

Visuellement, on constate des différences entre les prédictions des différents modèles (Figure 4.7). On observe que les prédictions du modèle *UNet-S2* sont correctes approximativement. Elles permettent d’identifier grossièrement les zones inondées de celles qui le sont peu ou pas mais on ne retrouve pas les motifs spatiaux fins. Les prédictions des modèles *UNet-MNT-S2* et *Fusion-UNet*, qui intègrent le MNT à résolution fine, sont plus

	Apprentissage	Validation	Test
<i>UNet-S2</i>	0.27	0.24	0.16
<i>UNet-MNT-S2</i>	0.17	0.14	0.09
<i>Fusion-UNet</i>	0.16	0.13	0.09

TABLE 4.1 – Comparaison des performances (EAM_{aj} en m) entre les modèles *UNet-S2*, *UNet-MNT-S2* et *Fusion-UNet*. En gras, les meilleures performances.

proches de la référence avec des motifs spatiaux très similaires. Cependant, le modèle *UNet-MNT-S2* restitue dans ses prédictions la trame des pixels à résolution grossière de la données Sentinel-2 contrairement au modèle *Fusion-UNet*.




FIGURE 4.7 – Comparaison visuelle des prédictions des modèles *UNet-S2*, *UNet-MNT-S2* et *Fusion-UNet*. a) Composition fausse couleur Sentinel-2 (R : B8 - V : B4 - B : B3); b) Modèle numérique de terrain drone; c) référence; d) prédiction de UNet (S2); e) prédiction de UNet (S2 + MNT); et f) prédiction de Fusion-UNet.

Ces résultats montrent visuellement et via la métrique d'évaluation (EAM_{aj}) que le modèle Fusion-UNet possède de meilleures performances que les modèles *UNet-S2* et *UNet-MNT-S2*. La suite de l'évaluation des performances et de la sensibilité se concentre donc sur ce modèle.

4.4.2 Performances de Fusion-UNet

La courbe d’apprentissage du modèle *Fusion-UNet* (Figure 4.8) montre bien une diminution de la fonction de coût au fur et à mesure des itérations à la fois pour le jeu de données d’apprentissage et de validation. La convergence des deux courbes témoigne donc d’un apprentissage réussi bien que l’écart restant entre les courbes témoigne lui d’un léger sur-apprentissage potentiellement dû à une variabilité différente entre les deux jeux de données.




FIGURE 4.8 – Courbe d’apprentissage du modèle *Fusion-UNet* sur les jeux de données d’apprentissage et de validation.

Fusion-UNet présente sur les jeux de données de validation et de test un EAM_{aj} de 0.13 et 0.09 m, respectivement. La Figure 4.9 montre les valeurs d’EAM par catégorie d’HE. Sur les deux jeux de données, on constate que les zones sans eau sont majoritaires et que plus on tend vers des gammes d’HE hautes plus les observations se font rares. Les performances, sur le jeu de données de validation, montrent une gamme d’erreur croissante avec la gamme d’HE atteignant un EAM de 0.3 m dans la gamme 130-140 cm. Les performances sur le jeu de données de test montrent une tendance différente, une erreur qui culmine autour de 0.17 m dans les gammes entre 30 et 70 cm, puis une erreur qui retombe autour de 0.05 m dans les gammes les plus hautes. La Figure 4.10 montre la

répartition des erreurs autour de la ligne 1 :1. Pour les deux jeux de données, la répartition du nuage se rapproche de cette droite ne montrant pas de biais important. Pour le jeu de validation, une plus forte dispersion est visible avec des hautes gammes de HE qui ont tendances à être sous-estimées. Pour le jeu de test, les moyennes gammes où se situaient les principales erreurs sont surestimées.




FIGURE 4.9 – Évolution de la métrique d'EAM (bleu) du nombre de pixels (rouge) en fonction des gammes de hauteurs d'eau. a) le jeu de données de validation et b) de test (Sougéal). Les valeurs d'EAM servent au calcul du EAM_{aj} .

4.4.3 Sensibilité spatio-temporelle

Dans cette partie nous évaluons la capacité du modèle *Fusion-UNet* à rendre compte de la variabilité spatio-temporelle des HE et sa sensibilité au jeu de données d'entrée.

D'abord, l'évaluation de la sensibilité temporelle (Tableau 4.2) montre que plus le nombre d'années hydrologiques utilisées dans le jeu d'apprentissage est important, plus les résultats s'améliorent avec une différence de -0.08 m entre les jeux de données avec 1 année et celui avec 3 années. L'écart-type relativement important de la validation-croisée nous montre qu'en fonction des années choisies pour l'apprentissage, les résultats varient. La variation s'atténue en utilisant plus d'années avec une différence d'écart-type de -0.03 m entre le jeu de données à 1 et 3 années. Le modèle permet également de reconstruire




FIGURE 4.10 – Mise en relation, sous forme d’un nuage de points, entre les prédictions du modèle *Fusion-UNet* et les références pour a) le jeu de données de validation et b) de test (Sougéal).

les trajectoires temporelles pour les différentes HGMU sondées par un piézomètre (Figure 4.11). Le régime hydrologique s’identifie bien avec la période humide de Janvier à Avril, suivie d’une période sèche. Le compartiment *PZ3* étant le plus élevé, il connaît des variations moins fortes dans l’année. Ce compartiment montre aussi les écarts les plus remarquables entre la prédiction et la référence jusqu’à 22 cm à la date du 01-04-2020. Cela peut s’expliquer par des biais dans la mesure piézométrique dus à des précipitations importantes dans la période précédant la mesure (voir partie 4.5.1). De manière générale, le modèle tend légèrement à sur-estimer en période "sèche" et à sous-estimer en période "humide".

	EAM_{aj} (m)
1 année	0.38 ($\pm$ 0.12)
2 années	0.33 ($\pm$ 0.10)
3 années	0.26 ($\pm$ 0.09)

TABLE 4.2 – Comparaison des résultats par validation-croisée du modèle *Fusion-UNet* entraîné avec jeu d’apprentissage sur 1, 2 et 3 années hydrologiques.

Sur le plan spatial, le modèle permet de restituer les différences d’altitude du plan d’eau entre les différents compartiments ou HGMU (Figure 4.11). On retrouve bien les écarts d’altitude entre les compartiments avec l’ordre logique, du plus haut au plus bas : *PZ3*, *PZ2* puis *PZ1*. La comparaison de la prédiction du modèle *Fusion-UNet* à la date

du 06-04-2021 avec une acquisition drone effectuée 5 jours avant (Figure 4.12) permet d'observer la bonne restitution de la structure spatiale fine du site du marais de Sougéal. Par exemple, les variations de HE au niveau des canaux, chenaux ou zones de dépressions peuvent être observées. Cette image permet également de constater que le modèle estime correctement la limite entre les surfaces inondées et non-inondées malgré la présence de la végétation (plantes aquatiques et terrestres) sur le gradient d'hygrophilie.



FIGURE 4.11 – Prédiction de l'altitude du plan d'eau pour chaque compartiments (HGMU) contenant une sonde piézométrique sur Sougéal lors de la période de validation (2020). Lors des périodes les plus sèches l'altitude du plan d'eau du compartiment *PZ3* est sous la surface du sol et donc invisible pour les données satellitaires.

Enfin, le modèle peut être performant malgré la présence d'une couverture nuageuse (Figure 4.13). Étonnamment, la prédiction montre des limites entre les surfaces inondées et non-inondées qui sont cohérentes malgré une identification visuelle difficile sur l'imagerie satellitaire. Cependant bien que les HE estimées semblent assez cohérentes, leur répartition n'est pas homogène avec des surfaces surestimées.




FIGURE 4.12 – Comparaison d’une image drone vraies couleurs (a) avec la prédiction du modèle *Fusion-UNet* (b). Trait orange : limite du niveau d’eau de référence.




FIGURE 4.13 – Comparaison l’imagerie Sentinel-2 (a) avec la prédiction du modèle *Fusion-UNet* (b) lorsque le site est sous une couverture nuageuse. Trait orange : limite du niveau d’eau de référence.

4.4.4 Transférabilité du modèle

Dans cette dernière partie, nous évaluons si le modèle *Fusion-UNet* peut-être transféré sur un site différent de celui d’apprentissage (marais de Sougéal). Ainsi, l’évaluation des prédictions sur le site du marais d’Aucey, à l’aide de la sonde *PZ4*, montre une EAM_{aj} de 0.34 m soit une différence de 0.25 m avec le site d’apprentissage. La gamme d’HE est plus importante que sur le marais d’Aucey avec des HE allant jusqu’à 200 cm (Figure 4.14). L’erreur est également croissante avec la gamme d’HE. De plus, dans les gammes 130-140 cm, l’erreur monte à 0.3 m comme pour le site du marais de Sougéal mais elle

continue à monter dans les gammes supérieures atteignant 0.8 m pour la gamme 190-200 cm. La Figure 4.15 permet d’observer que le modèle sous-estime de manière générale les HE mais encore plus dans les gammes d’HE supérieures à 140 cm.




FIGURE 4.14 – Évolution de la métrique d’EAM (bleu) du nombre de pixels (rouge) en fonction des gammes de hauteurs d’eau pour les prédictions sur le marais d’Aucey.




FIGURE 4.15 – Mise en relation, sous forme d’un nuage de points, entre les prédictions du modèle *Fusion-UNet* et les références sur le site du marais d’Aucey.

4.5 Discussion

Dans cette étude nous évaluons le potentiel d’un modèle de super-résolution par fusion de données (images multispectrales et MNT à résolution fine) à restituer la variabilité spatio-temporelle des dynamiques d’inondation de prairies humides. Les résultats

montrent que le modèle *Fusion-UNet* permet la restitution de la variabilité des HE intra-site jusqu’à une précision moyenne de 0.13 m. Nous discutons ces résultats dans les parties suivantes à travers trois aspects : 1) les données d’observation ; 2) la modélisation des dynamiques d’inondation ; et 3) l’utilisation de ses prédictions comme indicateurs écologiques.

4.5.1 Les données d’observation

Il serait intéressant d’explorer plus en détail la contribution des différentes variables d’entrée à la prédiction des HE. En effet, nous avons vu que le modèle *UNet* intégrant le MNT améliore la tâche de super-résolution. Nous pouvons supposer que la donnée MNT en complément des données multispectrales permet de : 1) contraindre les prédictions en apportant une information contextuelle sur la topographie et 2) forcer la restitution correcte des motifs spatiaux. En effet la donnée satellitaire seule ne permet pas de retrouver ces motifs spatiaux et est plus sensible aux confusions de prédictions (voir Annexe E.2). Ensuite, nous avons constaté que le modèle ne prédit pas toujours avec la même précision en fonction des gammes d’HE. La profondeur de la colonne d’eau (mais aussi sa composition en matière en suspension et la présence de végétaux) influence fortement le signal spectral capté. Par exemple, le domaine du proche-infrarouge possède un fort coefficient d’extinction dans l’eau (BEGET & DI BELLA, 2007) et sera donc plus sensible aux variations des faibles HE, tandis que le domaine du bleu a un pouvoir plus pénétrant le rendant plus sensible aux fortes variations (KUTSER et al., 2020). Pour cela, une analyse des différents descripteurs obtenus par les réseaux de neurones serait intéressante pour évaluer la contribution de chaque bande.

Concernant les données à estimer, il est difficile d’avoir une référence exhaustive et fiable à la fois sur les paramètres d’extension spatiale et de HE. Cette approche permet de spatialiser les mesures de HE par piézomètre à l’aide d’un MNT. Bien que ce dernier soit spatialement explicite, les mesures piézométriques restent ponctuelles forçant l’extrapolation de cette mesure à l’échelle d’un HGMU. Plusieurs facteurs amènent de l’incertitude dans cette approximation. Les mesures d’HE par piézomètre peuvent être biaisées après des périodes de pluies intenses. En effet, la faible conductivité hydraulique des sols argileux du site d’étude favorise la formation de nappes perchées. Le piézomètre ne mesure alors pas la HE en surface mais celle de la nappe dans le sous-sol. Ensuite, la construction du MNT par photogrammétrie à l’aide de l’imagerie drone nécessite d’effectuer les acquisitions à des périodes bien précises pour minimiser l’influence de la hauteur

de végétation et des surfaces en eau (ANNIS et al., 2020). Ici, le MNT ne comprend pas les zones submergées toute l'année (mare et canaux) et l'erreur face aux mesures par GNSS est en moyenne de 9 cm, notamment à cause de la présence de végétation, même rase.

D'autres alternatives pour obtenir un MNT existent mais sont soit trop imprécises, soit encore trop coûteuses. Des produits à l'échelle globale à l'aide de satellite radar (ex : *Shuttle Radar Topography Mission*) sont disponibles avec une résolution autour de 90 m et une précision de 5-9m, ce qui est insuffisant pour capturer la micro-topographie et les gammes d'inondation des zones humides (TRIGG et al., 2012). À des échelles plus fines, les relevés LiDAR avec une précision verticale centimétrique (WU et al., 2019) paraissent comme une bonne alternative. Leur potentiel à révéler les motifs spatiaux fins de la microtopographie a déjà été montré à travers la délimitation de HGMU en zone humide (RAPINEL et al., 2016 ; RAPINEL, ROSSIGNOL, GORE et al., 2018). Le principal inconvénient à leur utilisation est le coût important pour une campagne d'acquisition. Cependant, en France, l'IGN a rendu accessible la base de donnée *RGE alti* qui fournit des MNT LiDAR à 1m de résolution au niveau des zones inondables de France.

Enfin, il a été observé que les niveaux d'eau dans les plaines inondées et les zones humides montrent une variabilité spatio-temporelle significative sur des périodes de 24 h et à des échelles spatiales de 10 à 100 m (BATES et al., 2014). Ici, l'approche par super-résolution a permis d'améliorer la restitution spatiale des HE localement mais la dimension temporelle reste encore limitée à une observation tous les 5 jours au mieux. L'utilisation d'autres systèmes satellitaires permettrait de compléter les séries de données. Des satellites optiques de "suivi environnemental" (ex : *Landsat* ou *Gaofen*) ou des "nano-satellites" (ex : *Planet*) peuvent aider à augmenter la fréquence temporelle mais restent cependant toujours limités par la couverture nuageuse. Pour s'affranchir des nuages, les satellites à radar à synthèse d'ouverture (ex : *TerraSAR-X*, *Sentinel-1*) pourraient être une solution (BETBEDER et al., 2014). Affiner la fréquence temporelle requiert alors d'exploiter différentes sources de données de télédétection et impose donc de produire un modèle par source ou bien un modèle pouvant intégrer les différentes sources (radar ou optique) (ROSTAMI et al., 2019).

4.5.2 Modélisation des dynamiques d'inondation

D'une façon générale, le modèle *Fusion-UNet* présente des erreurs plus importantes dans les gammes hautes des HE, celles-ci étant sous-représentées dans les jeux de données. On peut donc supposer que ces gammes de HE ont été moins considérées dans l'appren-

tissage. Une solution peut être de pondérer la fonction de coût selon les gammes de HE. Le modèle développé présente également de meilleures performances de prédiction sur les jeux de validation et de test que sur celui d'apprentissage. Cela peut s'expliquer par la variabilité inter-annuelle des dynamiques d'inondation mais aussi des facteurs influençant le signal spectral tels que les paramètres biophysiques de la végétation (ex : biomasse) ou la turbidité de l'eau. Augmenter la taille du jeu de données avec des années hydrologiques supplémentaires peut aider à intégrer plus de variabilité. Plus généralement, pour comprendre l'impact de ces facteurs sur les prédictions, d'autres analyses doivent être menées en intégrant un suivi des facteurs impactants, en parallèle des mesures piézométriques.

Une difficulté récurrente en télédétection est la généralisation des modèles établis. En effet, il est difficile d'intégrer la diversité de contextes géographiques dans les modèles. Nous avons voulu tester si le modèle entraîné sur un site, localement, pouvait apprendre des descripteurs assez généraux pour être applicable sur des sites inédits. Le modèle a donc été appliqué sur le site du marais d'Aucey qui est différent dans sa structure (nombreux chenaux) et dans les données de MNT qui le caractérisent (LiDAR), même s'il possède un contexte géographique proche. Les résultats témoignent d'une bonne capacité du modèle à prédire les HE sur ce deuxième site dans des gammes de HE similaires à celles présentes sur le marais de Sougéal. En revanche, dans les gammes qu'il n'a jamais vues, soit entre 1.4 et 2.5 m, le modèle présente une tendance à la sous-estimation. Pour améliorer la généralisation du modèle appris, différentes approches sont possibles. Tout d'abord, il est possible d'appliquer du *fine-tuning*, c'est à dire de ré-entraîner le modèle à partir des paramètres établis sur un premier site à l'aide d'un jeu de données moins conséquent sur le nouveau site. Si aucune donnée de référence n'est disponible sur le second site, il est possible d'utiliser des méthodes d'adaptation de domaine pour faire correspondre les caractéristiques d'un nouveau jeu de données avec celles du jeu de données d'entraînement. Cette approche peut être intéressante pour gérer l'utilisation de produits provenant de sources différentes comme pour le MNT (photogrammétrie Vs LiDAR) dans notre cas mais aussi, comme mentionné plus haut, pour intégrer d'autres sources de données satellitaires susceptibles de capter la dynamique d'inondation. Ces méthodes doivent faciliter le passage à l'échelle et la généralisation d'un modèle appris localement. Ce type de modèle pourrait être appliqué à d'autres régions géographiques, comme les prairies humides de la région semi-aride du Pothole au Nord des États-Unis dont le processus de *fill-spill* amène des discontinuités hydrologiques et donc à une variabilité spatio-temporelle importante (HAYASHI et al., 2016).

L'utilisation de l'architecture du type FCN permet à ce modèle d'être efficace pour la restitution des motifs spatiaux. En revanche, le lien temporel n'a pas été explicitement pris en compte dans notre modèle. Pourtant, les régimes hydrologiques naturels ou artificiels ont un vrai lien temporel (ex : saisonnalité). Il est possible de définir un nouveau réseau de neurone spatio-temporel prenant en entrée les données à chaque date. Il est également possible, dans notre cas, d'estimer les données à chaque date avec notre réseau existant. Ensuite, un réseau temporel de type *Recurent Neural Network* (RNN) ou *Temporal CNN* (TempCNN) (PELLETIER et al., 2019) peut être ajouté pour assurer un lien temporel entre les estimations.

4.5.3 Les dynamiques d'inondation comme indicateurs écologiques

Utiliser la télédétection par drone et satellite est une solution rapide et à faible coût qui permet de caractériser finement les dynamiques d'inondation en prairie humide. Ceci participe à la caractérisation de la structure abiotique du milieu, l'hétérogénéité de celle-ci étant un indicateur d'intégrité écologique. Le suivi du niveau d'eau à travers les paramètres d'extension spatiale, de hauteur d'eau et de temps de résidence renseigne sur la qualité fonctionnelle et le bon état écologique du milieu humide mais aussi conditionne les usages en place.

Les paramètres hydrologiques permettent d'identifier et de caractériser les habitats des milieux humides. Par exemple, ils permettent la modélisation des assemblages d'espèces les plus probables et de mieux comprendre les mécanismes d'assemblages via les traits fonctionnels le long du gradient d'inondation (VIOLLE et al., 2011). Cependant, une précision centimétrique est parfois nécessaire pour ces études. Par exemple, BOUZILLÉ et al., 2001, dans son étude sur les gradients écologiques dans les marais salants, considère qu'une aire est inondée à partir de 1 cm de hauteur. L'habitat de certains oiseaux d'eau est un autre exemple car il se caractérise par des eaux superficielles inférieures à 10 cm de hauteur (ALDABE et al., 2019; SCHAFFER-SMITH et al., 2018). Il est difficile de modéliser les changements de dynamiques dans ces gammes de hauteur d'eau étroite, et cela reste un défi pour la télédétection.

4.6 Conclusion

Cette étude explore la fusion de données multispectrales (satellite) et d’un MNT à résolution fine (drone) pour réaliser une cartographie sub-pixelique des hauteurs d’eau en milieu de prairie humide. Le modèle *UNet* a été adapté à la fusion de ces données au travers de l’utilisation d’une fonction de coût mixte spécifique. A travers cette étude les complémentarités entre les données satellites (haute résolution temporelle) et drone (très haute résolution spatiale) ont été exploitées. La production et l’exploitation de ces données est à faible coût et permet donc un déploiement facile.

Les expérimentations ont démontré de l’apport du modèle *Fusion-UNet* face au modèle original et de sa capacité à restituer la variabilité spatio-temporelle des dynamiques d’inondation. Des tests de transfert vers un nouveau site d’étude ont montré que le modèle restitue correctement les HE dans les gammes qu’il a apprises. Cela démontre de la nécessité d’augmenter et de diversifier le jeu de données avec une plus longue période et d’autres contextes géographiques. Bien que le modèle soit efficace localement, la planification environnementale exige cependant des observations à l’échelle des bassins versants (RAPINEL, CLÉMENT et al., 2019). C’est pourquoi nos résultats sont préliminaires mais d’autres études doivent être menées en diversifiant les sites et en élargissant l’échelle d’analyse.

CONCLUSION GÉNÉRALE

Synthèse des travaux

A travers cette thèse, l'objectif était d'évaluer l'apport des complémentarités entre drone et satellite pour le suivi par télédétection des prairies humides. L'hypothèse formulée était que l'apport du drone en complément de l'imagerie satellitaire permet une caractérisation et une représentation plus précise de la structure de ces milieux. Cependant, exploiter ces complémentarités pose des questions d'ordre méthodologique car il s'agit de données hétérogènes avec différentes échelles d'observation. La synthèse des contributions de cette thèse en regard des objectifs initiaux est présentée ci-dessous.

Formalisation des synergies entre drone et satellite. Cette thèse a contribué à formaliser quatre principales synergies identifiées au travers de la revue de la littérature scientifique : "la comparaison de données", "l'explicitation multi-échelle", "la calibration de modèle" et la "fusion de données". Bien que ces catégories soient apparues clairement dans notre analyse, elles auront tendance à évoluer et tendre vers des approches hybrides avec l'évolution des technologies et des applications. Ce travail a également permis de mettre en évidence des tendances à l'utilisation de ces synergies. Tout d'abord, il a été constaté que la synergie par "comparaison de données" est très présente malgré le fait qu'elle ne permette pas d'intégration forte des deux sources de données. La synergie par "calibration de modèle" reste l'approche la plus exploitée utilisant la donnée drone comme une "vérité terrain" qui complète ou remplace les observations *in-situ*. Enfin, les synergies par "explicitation multi-échelle" et "fusion de données" sont encore sous-exploitées alors qu'elles intègrent mieux les différences d'échelles entre les sources de données. La formalisation des différentes synergies et l'identification de ces tendances doit permettre à la communauté scientifique d'exploiter plus largement les complémentarités entre drone et satellite.

Évaluation des approches méthodologiques. Dans l'objectif d'exploiter pleinement les complémentarités entre les drones et les satellites, plusieurs synergies ont été appliquées au travers de méthodes de changement d'échelle pour produire une information sub-pixelique. Deux approches mobilisant ces méthodes ont été développées au travers de deux applications. Tout d'abord une approche par démélangeage spectral a démontré que l'information spectrale à très haute résolution spatiale du drone permettait de sélectionner une variété de *endmembers* utiles au démélangeage des pixels satellitaires dans le contexte de la cartographie des communautés végétales de prairies humides. Cette

approche hybride entre la "calibration de données" et la "fusion de données" atteste du caractère évolutif des synergies identifiées. Ensuite, il a été démontré que la fusion de séries de données multispectrales satellitaires avec un modèle numérique de terrain drone à résolution fine facilitait l'application de la super-résolution dans le cadre de la cartographie des dynamiques d'inondation. Finalement, le développement méthodologique au travers de cette thèse a contribué à exploiter des approches qui étaient inexploitées dans le contexte du suivi des prairies humides et qui étaient sous-exploitées de manière générale.

Apport pour le suivi des prairies humides. L'utilisation des synergies drone/satellite dans le cadre du suivi des prairies humides contribue à produire des représentations cartographiques plus précises de la structure de ces milieux. En effet, il a été vu que l'utilisation de la logique floue et des données drone à résolution fine permettaient de rendre compte de la nature graduelle des prairies humides. Tout d'abord, le cas de la cartographie des communautés végétales : estimer les abondances de chaque communautés dans les pixels satellitaires, plutôt que définir une classe unique par pixel, a permis de rendre compte des transitions graduelles (écotones). De plus, l'utilisation des *endmembers* provenant des drones a permis de mieux identifier la communauté méso-hygrophyle qui présente la plus forte diversité spécifique. Ensuite, l'apport du modèle numérique de terrain à résolution fine par le drone a permis de représenter les dynamiques d'inondation à travers la variation spatiale et temporelle des hauteurs d'eau et non plus seulement de l'extension spatiale des surfaces inondées. Les hauteurs d'eau étant une variable continue entre l'état inondé et non-inondé, il est ainsi possible de considérer tout le gradient entre ces deux états. Finalement, ces indicateurs de la structure de l'écosystème font parties des EBVs qui aident à la production d'indicateurs de biodiversité et de services écosystémiques de plus haut niveaux.

Apport des drones pour l'observation de la Terre. Finalement, la technologie drone apporte une nouvelle source de données pour l'observation de la Terre qui est très accessible, flexible et qui fournit de la très haute résolution spatiale et temporelle. Elle complète ainsi l'offre déjà existante des données satellitaires et facilite la mise en correspondance avec les observations *in-situ*. En effet, face aux acquisitions systématiques à l'échelle régionale des satellites, l'intérêt du drone est sa capacité à se focaliser et expliciter les observations sur un site à l'échelle locale. Le drone va pouvoir rendre compte de l'hétérogénéité spatiale intra-site - jusqu'à l'échelle de la fleur (SMIGAJ & GAULTON,

2021) - mais aussi d'une variabilité temporelle - jusqu'à une échelle intra-journalière (N. WANG et al., 2021) - qui sont invisibles par satellite. Il joue alors un rôle d'intermédiaire (ou de "pont") entre les observations satellitaires et *in-situ*, comme cela a pu être le cas dans les travaux de cette thèse. Le drone est également un outil d'observation et d'exploration à part entière. D'une part, il permet au "télédéetecteur" d'être présent sur le terrain ce qui lui permet d'appréhender directement la scène observée et les effets d'environnements pouvant impacter les observations. D'autre part, la disponibilité de la masse de données satellitaires a conduit à une vision *data*-centrée de la science où l'extraction de connaissances repose désormais sur l'analyse du *Big Data* plutôt que sur la question scientifique. Le drone en tant qu'outil d'exploration permet alors de rendre la question scientifique centrale. En effet, leur flexibilité et leur échelle d'observation unique permet de nouveaux questionnements sur les processus environnementaux avec une composante spatiale à l'échelle du paysage (DÍAZ-DELGADO & MÜCHER, 2019 ; KLOSTERMAN et al., 2018 ; MARCACCIO et al., 2016).

Perspectives de recherche

La production de séries temporelles à THRS. Le drone n'est pas adapté à des observations systématiques car il implique la présence d'un opérateur sur le terrain. Le satellite est limité soit dans sa résolution spatiale soit dans sa résolution temporelle à cause des compromis technologiques dans la conception de ces instruments. Ainsi la production de séries temporelles à THRS reste encore un défi. Pourtant, des milieux comme les zones humides se caractérisent par une forte hétérogénéité spatiale et temporelle de la couverture du sol (dynamique hydrologique, phénologie du couvert végétale, pâturage). C'est cette hétérogénéité qui fait leur richesse écologique. Aujourd'hui, les réseaux de neurones du type FCN offrent différentes solutions pour palier à ce manque en générant artificiellement des images à très haute résolution spatio-temporelle à l'aide d'une ou plusieurs sources de données. Dans le cadre de cette thèse, ces approches ont été abordées de manière exploratoire. Tout d'abord, une approche par interpolation d'images drone a été considérée dans JIN et al., 2021. Cette étude évalue la capacité d'un réseau de neurones à convolution séparable³ à prédire une image intermédiaire entre deux images drone existantes (voir Figure 4.16). Bien que les résultats avec des métriques techniques soient concluants, l'interprétation thématique des images artificielles montre des aberrations. Une seconde approche tente de contraindre la génération des images artificielles en intégrant des données satellitaires à travers une méthode de fusion spatio-temporelle. Inspiré par les travaux de TAN et al., 2019, le modèle *Fusion-UNet* a été adapté à la tâche de fusion spatio-temporelle de données multispectrales satellitaires (Sentinel-2) et drone. Les travaux en cours ont montré la capacité du modèle à restituer les motifs spatiaux globaux, certains plus fins et des caractéristiques spectrales correctes. Ces séries temporelles de données à THRS en partie artificielles peuvent ensuite être traitées à travers des nouvelles méthodes qui exploitent à la fois les dynamiques temporelles et les motifs spatiaux qui caractérisent la structure de la donnée (CENSI et al., 2021).

Exploitation de la synergie par "explicitation multi-échelle". Dans cette thèse, plusieurs synergies drone/satellite ont été exploitées : 1) "la comparaison de données" pour mettre en évidence des complémentarités entre drone et satellite ; 2) "la calibration de modèles" en utilisant les données drone en tant que "vérité terrain", mais aussi "la

3. La convolution séparable consiste à séparer une convolution 2D en deux convolutions 1D pour diminuer le nombre de paramètres à estimer et ainsi permettre d'utiliser plus de convolutions ou des noyaux de convolution avec une plus grande taille.




FIGURE 4.16 – Résultats d'interpolation des images drones entre 2017 et 2019. Les résultats d'interpolation et les images existantes sont montrés pour la séquence 2019 (A), 2018 (B) et 2017 (C). Les points bleus-foncés correspondent aux images existantes, les rouges à la première interpolation, les verts à la seconde et les bleus-cyans à la troisième (JIN et al., 2021)

calibration de données" à travers l'adaptation de domaine des données multispectrales drone vers les données satellites; et 3) "la fusion de données" à travers l'utilisation des signatures spectrales (*endmembers*) pour le démelangeage des pixels satellitaires mais aussi la fusion direct des données multispectrales satellitaires et d'un modèle numérique de terrain drone. Toutes ces synergies ont été utilisées dans le cadre de la cartographie de la structure de prairies humides. Une dernière synergie n'a pas été exploitée dans nos travaux et reste totalement inexploitée dans le domaine de l'écologie, c'est "l'explicitation multi-échelle" qui consiste à traiter séparément les deux sources de données pour produire des informations à des échelles différentes. Celle-ci peut être appliquée dans le cadre de

la cartographie des fonctions de zones humides (Figure 4.17). En effet, en mesurant des paramètres soit sur le site étudié, soit dans son environnement (zone tampon, paysage, zone contributive), il est possible de déduire par calcul l'expression potentielle de certaines fonctions (hydrologiques, biogéochimiques et écologiques). Le drone peut ainsi contribuer à dériver des paramètres à l'échelle du site et de sa zone tampon (habitats, couvert végétale), alors que l'imagerie satellitaire contribue plus largement à l'échelle du paysage et de la zone contributive (ex : corridors écologiques). Cette perspective d'application fait partie des pistes de recherche qui seront potentiellement explorées dans le cadre du projet SEINE-EO ("Caractérisation et Suivi multi-Echelles et temporelles des zones humides de l'estuaire de la Seine par satellites et drones.") avec le CEREMA dans le cadre d'un post-doctorat si le projet est retenu par le GIP Seine-Aval. Ce projet portant sur la cartographie des fonctions des zones humides de la Seine aval explorera également la fusion de données hétérogènes (LiDAR, multispectrale, thermique).




FIGURE 4.17 – Exemples de paramètres et d'indicateurs mesurés selon les zones et renseignant les fonctions hydrologiques, biogéochimiques et d'accomplissement du cycle biologique des espèces (source : GAYET et al., 2016).

Il est important de souligner que les méthodologies développées dans cette thèse sont

applicables pour le suivi d'autres milieux concernés par la conservation du patrimoine naturel mais aussi plus largement dans d'autres domaines d'application de l'observation de la Terre (agriculture, hydrologie, urbain, etc).

ANNEXES

A Grille de lecture de la revue de littérature

La grille de lecture est accessible par ici : *Lien de téléchargement*

B Calibration géométrique et radiométrique des données Sentinel-2

B.1 Calibration géométrique

Une première calibration interne est effectuée pour améliorer la géolocalisation et les mesures d'angles de vue à l'aide d'un Géolocalisation et Navigation par un Système de Satellite (GNSS), un IMU (Unité de Mesure Inertielle), et trois traceurs d'étoiles installés sur le satellite. Ces instruments permettent d'obtenir une première approximation de la localisation des images acquises.

La calibration du modèle physique de la géométrie (position, attitude, horodatage, matrices de transformation) de Sentinel-2 attribue un angle de vue à chaque pixel. Les paramètres du modèle de vue géométrique sont affinés par corrélation automatique à l'aide d'imageries Pléiades de référence réparties à travers le globe pour couvrir un maximum de latitudes et longitudes. Pour chaque scène le modèle est affiné par triangulation spatiale (ajustement des faisceaux) en déterminant un biais moyen en terme de lacet, tangage et roulis. Cette méthode est appliquée à l'imagerie visible et proche infrarouge du MSI car elles sont systématiquement corrélées avec l'imagerie Pléiades. L'utilisation d'orthophotos et MNT, provenant de Pléiades et de l'IGN, assurent une précision altimétrique et planimétrique consistante. Cette méthode est d'abord appliquée à la calibration du plan focale de B4 qui servira ensuite de référence pour calibrer B2, B3, B5 et B8. B5 servira ensuite à calibrer B1, B6, B7, B11 et B12. B8 sera ensuite utilisée pour B8a et B9. Et enfin B2 pour la bande spectrale B10. Cette étape permet surtout de calibrer l'alignement des différentes bandes spectrales entre elles. Ensuite on utilise une image de référence globale (GRI) bien géoréférencée pour corriger le modèle géométrique par corrélation et reconnaissance d'image automatique (LONJOU et al., 2015). Cette dernière étape couplée à l'utilisation de Point de Contrôle au Sol (PCS) permet d'obtenir une calibration absolue efficace pour aligner les acquisitions multi-temporelles.

Ces traitements assurent une géolocalisation précise des images avec une erreur relative (spectrale et temporelle) $< \text{à } 0.3 \text{ pixel à } 3\sigma$ de niveau de confiance et une erreur absolue $< \text{à } 12,36 \text{ m à } 2\sigma$. L'utilisation du GRI réduit l'erreur à 8 m. Pour des informations complètes, le lecteur devrait se référer à (LANGUILLE et al., 2015 ; LONJOU et al., 2015)

B.2 Calibration radiométrique

Avant la correction atmosphérique, les données Sentinel-2 sont calibrées à l'aide d'instruments à bord du satellite. Le satellite est équipé d'un diffuseur du rayonnement solaire qui est essentiel pour établir une calibration radiométrique absolue. Pour un pixel donné, dans une bande k , l'illuminance du pixel est modélisée par :

$$L_k = K_{slt,k} \frac{\rho_k(\theta_s, \phi_s, \theta_v, \phi_v) E_k \cos(\theta_s)}{d_{sun}^2 \pi} \quad (1)$$

$$E_k = \frac{\int E_0(\lambda) S_k(\lambda) d\lambda}{\int S_k(\lambda) d\lambda} \quad (2)$$

avec :

- d_{sun} la distance Terre-Soleil
- E_0 l'illuminance moyenne du soleil dans la bande k
- $S_k(\lambda)$ la réponse spectrale de la bande k
- $\rho_k(\theta_s, \phi_s, \theta_v, \phi_v)$ la BRDF du diffuseur dont les paramètres ont été estimés au sol avant le lancement
- $K_{slt,k}$ le facteur de correction du rayonnement parasite

Afin d'assurer la consistance des données entre plusieurs capteurs, un étalonnage est effectué sur des sites considérés comme "invariants" (20 sites de $100 \times 100 km^2$ de désert). Le capteur MSI de Sentinel-2 est alors calibré statistiquement par rapport à des capteurs de référence (Landsat, SPOT, MODIS, MERIS). La calibration-croisée avec le capteur MODIS et MERIS, qui est considérée comme le standard dans la communauté, fournit une calibration absolue.

La diffusion de Rayleigh est corrigée pour les bandes du visible (B1 à B4) à partir d'observations au-dessus de l'océan et d'un modèle physique de transfert radiatif calculant la diffusion des molécules dans l'atmosphère.

Des mesures *in-situ* servent à calibrer les valeur de réflectance au-dessus de l'atmosphère (TOA) du satellite. Pour cela un photomètre à été installé par le CNES à Lacrau, France. Celui-ci mesure les propriétés de réflectance au sol et l'illumination incidente dérivant ainsi les propriétés optique de l'atmosphère pour simuler une réflectance TOA au dessus du site.

Pour la correction atmosphérique la chaîne de traitement MAJA (MACCS-ATCOR Joint Algorithm) est utilisée. C'est une fusion des chaînes MACCS (Multi-sensor Atmospheric Correction and Cloud Screening) et ATCOR (Atmospheric Topographic Correction), qui sont développées conjointement par le CNES et le CESBIO (voir figure 18). MAJA a la particularité de s'appliquer à des séries temporelles d'images de résolution décimétrique, et de faire une large utilisation de méthodes multi-temporelles. Cette étape est cruciale et particulièrement difficile au-dessus des surfaces terrestres à causes de deux principaux problèmes : l'identification des pixels sans nuages ; et la séparation entre les effets de la surface et de l'atmosphère.




FIGURE 18 – Chaîne de traitement MAJA

Une première fonctionnalité de MACCS est la détection et le masquage des nuages et de leurs ombres portées à l'aide des bandes du bleu, du proche et moyen infrarouge et de l'information multi-temporelle. La détection et correction des cirrus (nuage de haute altitude dans la haute troposphère) est effectuée après le masquage des nuages et avant la correction atmosphérique. Cette étape consiste à calculer empiriquement un coefficient de correction à partir de la réflectance du cirrus, ce coefficient est ensuite appliqué à toutes

les bandes.

La correction atmosphérique prend en compte deux effets :

- L'absorption du rayonnement par les gaz atmosphériques (vapeur d'eau, ozone, O et CO₂). Les bandes d'observation de la surface évitent les bandes d'absorption fortes. Mais il est tout de même nécessaire de les corriger à partir d'analyses météorologiques et de modèles analytiques simples (SMAC ou 6S). Le contenu en vapeur d'eau est estimé à partir de la bande 940 nm qui correspond à une bande d'absorption importante et une bande de référence (865 nm) en dehors des bandes d'absorption. Pour estimer l'absorption on suppose que la réflectance de la surface est la même pour les bandes 940 et 865 nm et que la vapeur d'eau se situe au-dessus des couches diffusantes. A partir du ratio entre les bandes 940 et 865 nm, de la géométrie d'observation et du modèle de transfert radiatif simple (SMAC), une table de correspondance est calculée pour retrouver l'absorption par la vapeur d'eau. Les compositions des autres gaz sont considérées comme constantes excepté pour l'ozone qui utilise les fichiers de l'ECMWF (European Centre for Medium-Range Weather Forecasts) et est également corrigée par SMAC.
- La diffusion par les molécules et les aérosols. Tant que la composition de l'atmosphère est bien connue, il est possible de modéliser leur diffusion très précisément. La difficulté résulte dans la connaissance des propriétés (type et abondance) des aérosols qui est très variable dans le temps et l'espace, tandis que la composition en molécule d'air est bien connue. Les stratégies de correction se dirigent donc vers une bonne connaissance de l'épaisseur optique liée aux aérosols (AOT). La méthode utilisée par MAJA est dite hybride car elle utilise l'information multi-temporelle et multi-spectrale. D'abord le multi-temporel suppose que l'AOT varie rapidement tandis que la réflectance de la surface varie lentement dans le temps, ainsi il est possible de quantifier le changement d'AOT entre deux acquisitions. Tandis que le multispectrale estime l'AOT au-dessus de zones sombres (ex : forêt dense) pour mesurer le rayonnement principalement renvoyé par l'atmosphère. Une fois l'AOT estimée, la correction de la diffusion se fait à partir de la table de correspondance mentionnée précédemment, et des valeurs de géométrie d'observation, de longueur d'ondes, d'altitude du terrain et de réflectance TOA.

Après la correction de l'absorption et la diffusion de l'atmosphère, MAJA corrige les effets d'environnements et de terrain. Les effets d'environnement sont relativement petits

mais peuvent prendre de l'importance dès que la résolution spatiale est en dessous de 100m. Cette dégradation dépend de l'AOT et des angles solaire et de vue. Dans la figure 19, 4 types de chemins sont identifiés : 1- la diffusion atmosphérique sans interaction avec la surface terrestre ρ_{Atm} ; 2- la surface de réflectance ρ_s , qui est la quantité recherchée ; 3- la réflexion sur la surface (en-dehors du pixel observé) qui est ensuite diffusée par l'atmosphère ; et 4- les multiples réflexions entre la surface et l'atmosphère. La réflectance due aux effets d'environnements ρ_{env} correspond aux chemins 3 et 4. Pour des paysages non-uniforme la formule suivante est appliquée par MAJA pour estimer ρ_s :

$$\rho_s = \frac{\rho_s^{unif} T \uparrow \frac{1-\rho_s^{unif}.s}{1-\rho_{env}.s} - \rho_{env} T_{dif} \uparrow}{T_{dir} \uparrow} \quad (3)$$

avec :

- ρ_s^{unif} , la réflectance de surface obtenue après la correction atmosphérique en supposant que la surface est uniforme.
- ρ_{env} , la réflectance de l'environnement est calculé en moyennant ρ_s^{unif} en utilisant une fonction de point d'étalement gaussienne de 2km.
- $T \uparrow$ est la transmission atmosphérique montante due à la diffusion.
- $T_{dif} \uparrow$ est la part diffuse de la transmission atmosphérique montante.
- $T_{dir} \uparrow$ est la part direct de la transmission atmosphérique montante.
- s est l'albedo de l'atmosphère.

La dernière correction effectuée par MAJA est celle du terrain. Jusqu'à présent on a considéré que le terrain était plat. Quand le terrain n'est pas plat, une pente faisant face au soleil recevra plus de lumière qu'une pente inclinée à l'opposé. Ainsi même si les deux pentes ont la même occupation du sol, la pente face au soleil apparaîtra plus lumineuse. Les propriétés de réflectance corrigées des effets de pente peuvent être obtenues à partir des réflectances assumant un terrain plat ρ_s^h , obtenues précédemment avec l'équation suivante :

$$\rho_s = \rho_s^h \frac{T \downarrow^h}{T \downarrow} \quad (4)$$

avec $T \downarrow^h$ la transmission descendante supposant un terrain plat, et $T \downarrow$ la transmission




FIGURE 19 – Les différents chemins du rayonnement solaire qui contribuent à la réflectance TOA, graphique de (RICHTER et al., 2006)

descendante réelle. $T \downarrow$ est la somme de la transmission direct et diffuse qui dépendent de la visibilité du ciel et du sol qui sont fonction de l'angle de la pente.

Ne connaissant pas les propriétés de BRDF (bidirectional reflectance distribution function) de la surface, cette approximation n'est pas calculée par MAJA. Finalement les propriétés de réflectance estimées par MAJA sont des facteurs de réflectance hémisphérique-directionnelle (HDRF) car on corrige la transmission montante des effets d'environnements (SCHAEPMAN-STRUB et al., 2006).

Pour plus de détail voir (HAGOLLE et al., 2017; LONJOU et al., 2015; LONJOU et al., 2016).

C Calibration géométrique et radiométrique des données Sequoia

C.1 Calibration géométrique

La calibration géométrique des images drone est effectué sur le logiciel de photogrammétrie Pix4D. Deux sources d'informations sur la géolocalisation sont utilisées : les coordonnées géographiques du capteur lors de la prise de vue et les coordonnées des PCS identifiées dans les images.

L'ajustement des faisceaux est la principale méthode dans le processus de photogrammétrie. Cela consiste à l'analyse des faisceaux pour chaque prise de vue pour transformer les coordonnées internes planes du capteur (2D) en coordonnées externes des objets du monde (3D). La représentation 3D doit fournir les vraies perspectives de la scène photographiée dans le vrai monde. C'est une étape qui requiert beaucoup de calcul où les coordonnées des images (X_0, Y_0, Z_0) et leurs attitudes (omega ω , phi ϕ , kappa κ) sont utilisées pour projeter les coordonnées correspondantes de la surface via des équations de co-linéarité. Ce procédé est aussi nommé aérotriangulation. L'ajustement des faisceaux a donc besoin de paramètres d'orientation interne (OI) du capteur (coordonnées et attitude) mais aussi de paramètres d'orientation externe (OE) afin d'orienter les images les unes par rapport aux autres pour reconstruire une mosaïque d'image orthorectifiée. Les paramètres d'OI sont spécifiques à chaque capteur. Les métadonnées peuvent renseigner sur la distance focale (f) et sur d'éventuels décalages (x_d, y_d) par rapport au principal point de focal (C_x, C_y) via des valeurs et coefficients clés de distorsion radiale (R_1, R_2, R_3) et tangentielle (T_1, T_2) selon les formules suivantes :

$$\begin{pmatrix} x_h \\ y_h \end{pmatrix} = \begin{pmatrix} \frac{X'}{Z'} \\ \frac{Y'}{Z'} \end{pmatrix} \quad (5)$$

sont les points d'une répartition homogène sans distorsion,

$$r^2 = x_h^2 + y_h^2 \quad (6)$$

est le carré du rayon 2D à partir du principal point de focal. Les points homogènes

distordus dans le système de coordonnées de la caméra $\begin{pmatrix} x_{hd} \\ y_{hd} \end{pmatrix}$ sont donnés par :

$$\begin{pmatrix} x_{hd} \\ y_{hd} \end{pmatrix} = \begin{pmatrix} (1 + R_1 r^2 + R_2 r^4 + R_3 r^6) x_h + 2T_1 x_h y_h + T^2 (r^2 + 2(x_h)^2) \\ (1 + R_1 r^2 + R_2 r^4 + R_3 r^6) y_h + 2T_1 x_h y_h + T^2 (r^2 + 2(y_h)^2) \end{pmatrix} \quad (7)$$

Les coordonnées du pixel $\begin{pmatrix} x_d \\ y_d \end{pmatrix}$ de la projection 3D avec le modèle de distorsion sont données par :

$$\begin{pmatrix} x_d \\ y_d \end{pmatrix} = - \begin{pmatrix} f x_{hd} \\ f y_{hd} \end{pmatrix} + \begin{pmatrix} C_x \\ C_y \end{pmatrix} \quad (8)$$

Les paramètres d'OE sont fournis par les PCS qui vont définir la relation entre les coordonnées des images et les coordonnées géographiques via un vecteur de translation et des matrices de rotation. Les paramètres d'OE peuvent être étendus grâce à l'utilisation d'algorithmes de détection de points-clés entre les images tel que le "*scale invariant feature transform*" (SIFT). Cet algorithme va détecter des points similaires entre les images et chercher à minimiser la distance euclidienne des positions estimées dans chaque image. Il reste efficace sous des variations d'échelle, d'angle de vue, d'illumination et d'occlusion. Cependant, certaines variations restent difficiles à prendre en compte et induisent des erreurs. C'est le cas de l'angle de vue, de la réflexion de l'atmosphère, des propriétés optiques de la surface (ex : anisotropie), ou encore de la dilatation du capteur due à la température. Les différents capteurs du Sequoia sont liés par des contraintes géométriques. Un capteur est pris en référence avec une position et attitude avec des coordonnées géographiques. Les positions de tous les autres capteurs sont définies par rapport au capteur-référence en connaissant les translations et rotations relatives de chaque capteur. Le recalage entre les différentes bandes de l'image multispectral est de l'ordre de 1 à 2 pixels (ASSMANN et al., 2018).

C.2 Calibration radiométrique

Plusieurs étapes sont nécessaires pour dériver les propriétés de réflectance de la surface : fuite de courant d'obscurité, conversion en luminance énergétique, correction des effets de vignettage, conversion en réflectance, calibration par l'ensoleillement ambiant (capteur *Sunshine*).

Un modèle de calibration du capteur permet de convertir les valeurs de pixels (mesure

brute) en pseudo-luminance énergétique avec une unité arbitraire (homogène à $W.sr^{-1}.m^{-2}$). Les quantités utilisées pour déterminer les coefficients de calibration sont le temps d'exposition ϵ (s), l'ISO γ , la valeur du pixel p , l'ouverture et la luminance L :

$$p = (A\epsilon\gamma + C)\frac{L}{f^2} + B \quad (9)$$

Avec A , B et C des coefficients de calibration spécifique au Sequoia, qui modélisent le comportement non-linéaire du capteur CMOS, et sont mesurés lors de la production pour chaque caméra.

Donc,

$$L = f^2 \frac{p - B}{A\epsilon\gamma + C} \quad (10)$$

Le biais dû à la fuite de courant d'obscurité (correspondant au coefficient B) est compensé par simple soustraction de la valeur estimée lors de la production du capteur. Ce biais est dépendant de la température du capteur mais la variation induite est seulement de 0,1%, donc pouvant être négligée dans le modèle. Il n'y a pas de bruit lié au courant d'obscurité sur le *Sunshine* ADLER, 2018. Après transformation des valeurs de pixel, l'image est dans un espace de "couleur" non-standard : un espace de luminance normalisée avec une gamme de $[0, \infty]$.

Le vignettage affecte l'illuminance L des pixels p en fonction de leurs coordonnées (x_p, y_p) dans la grille photosensible du capteur :

$$p(x_p, y_p) = v(x_p, y_p)L(x_p, y_p) \quad (11)$$

Le vignettage est continue sur (x_p, y_p) et peut-être représenté comme un polynôme $v(x_p, y_p)$. Ce modèle polynomiale est établie à partir d'une acquisition d'image d'une surface plane.

Le calcul des propriétés de réflectance, à l'aide du Sequoia, se base sur plusieurs hypothèses :

- La surface capturée est plate et parallèle au capteur.
- La surface capturée est considérée comme une surface lambertienne (ou orthotrope), c'est-à-dire qu'elle est considérée comme mate induisant des réflexions multiples dans le matériau et une ré-émission de façon uniforme dans toutes les directions. Ainsi, quelque soit l'angle d'observation de la surface, celle-ci renvoie la même quantité de

luminance. La luminance est seulement dépendante de la quantité d'énergie incidente tombant sur la surface. Cette quantité s'exprime comme un cosinus de l'angle entre la normale à la surface et la direction de la source.

- Sur chaque image, la surface capturée est plus grande qu'un pixel (pas de pixels mixtes).
- Le soleil est la seule source de lumière et ses rayons sont tous parallèles ; et perpendiculaires à la surface capturée.
- Il n'y a pas d'objets environnant qui réfléchissent le rayonnement solaire.
- L'atmosphère a une transmission parfaite.
- La surface capturée est suffisamment proche du centre optique de l'image pour que les effets de vignettage et de distorsion puissent être négligés.
- La surface capturée a une réflectance qui est constante sur toute la bande spectrale d'intérêt.
- Le diffuseur *Sunshine* se comporte comme une surface lambertienne.
- La source de lumière est constante sur chaque bande spectrale.
- L'intensité de la source de lumière change dans le temps, mais seulement de manière négligeable pendant l'acquisition.

Pour dériver des valeurs de réflectance HCRF (R) à partir des valeurs de pseudo-luminance énergétique (L) mesurée par le *Sequoia*, *Pix4D* utilise une cible de calibration radiométrique et un modèle empirique simplifié avec un point (SMITH & MILTON, 1999). Afin de passer de L à R ce modèle estime un coefficient de calibration (K) pour chaque bande spectrale à partir du ratio entre la valeur de HCRF connue de la cible (R_{ref}) et la luminance moyennée de celle-ci mesurée par le capteur ($\overline{L_{ref}}$) :

$$K = \frac{R_{ref}}{\overline{L_{ref}}} \quad (12)$$

$$R = LK \quad (13)$$

Ce coefficient est alors le coefficient directeur d'un modèle linéaire dont l'ordonnée à l'origine est 0. Lorsque les conditions lumineuses peuvent être changeantes (couverture nuageuse), on prend en compte les mesures de l'illuminance prise par le *Sunshine*. Avec L_{sq} l'illuminance mesurée par le Sequoia à un angle d'observation θ et L_{ss} l'illuminance mesurée par le *Sunshine*. La réflectance R associée à n'importe quelle valeur de pixel est alors donnée par :

$$R \cos(\theta) = K \frac{L_{sq}}{L_{ss}} \quad (14)$$

Avec :

$$L_{ss} = \frac{v}{g\tau} \quad (15)$$

où v est la valeur mesurée par le *Sunshine*, g est facteur de gain relatif (pour normaliser toutes les mesures à un seul mode de gain) et τ est le temps d'intégration. Il faut indiquer que l'équation convertissant en réflectance suppose que le soleil est au nadir et que le *Sunshine* lui fait directement face (angle solaire 0). Toujours grâce au modèle linéaire à un point, le coefficient de calibration K est estimé à l'aide de la mire de calibration radiométrique :

$$K = R_{ref} \frac{I_{ss}}{I_{sq}} \cos(\theta) \quad (16)$$

Où θ est l'angle d'observation rapporté à 0 pour un angle d'observation au nadir. Après la correction radiométrique, les images corrigées sont interpolées pour créer une ortho-mosaïque. L'interpolation est pondérée par la distance, la position de l'image et l'angle d'observation afin de sélectionner le plus possible les pixels centraux des images et ainsi réduire les potentiels effets liés à la BRDF.

**D Annexes du Chapitre 3 | Calibration de modèle :
Cartographie des communautés végétales de prairie humide**

D.1 Summary table of the grassland plant communities in the Sougeal marsh.


Occurrence and cover rate percentages were derived from 2017 surveys. Classes description : M – Mesophilic ; MH – Meso-Hygrophilic ; H – Hygrophilic.

		Feuille1							
		Occurrence (%)				Cover rate (%)			
Species names	Abreviated name	M	MH1	MH2	H	M	MH1	MH2	H
Lolium perenne	Lper	100	44	6		21	2		
Agrostis stolonifera	Asto	100	100	97	64	33	34	14	8
Poa trivialis	Ptri	93	89	50	9	22	17	2	
Rumex crispus	Rcri	65	61	65	18	1	2	2	
Taraxacum officinale	Toff	60	22	9		2	1		
Carex arvense	Carv	58	50	29		2	2	1	
Ranunculus sardous	Rsar	28	6	21					
Cerastium fontanum	Cfon	19							
Holcus lanatus	Hlan	19				1			
Alopecurus pratensis	Apra	16				1			
Deschampsia cespitosa	Dces	16		3					
Bidens cernua	Bcer	12							
Trifolium repens	Trep	77	83	74	27	5	4	3	
Carex hirta	Chir	60	72	56		2	3	2	
Juncus articulatus	Jart	7	56	56			2	3	
Leotodon automnalis	Laut		11						
Eleocharis acicularis	Eaci	2	78	97	27		13	35	1
Ranunculus repens	Rrep	74	89	91	36	4	9	8	1
Alopecurus geniculatus	Agen	7	39	88	55		2	8	9
Ranunculus flammula	Rfla	2	67	85	45		2	2	1
Cardamine pratense	Cpra	21	78	82	27		1	2	
Eleocharis palustris	Epal		17	74	27		1	3	1
Oenanthe fistulosa	Ofis	5	33	53			1	1	
Potentilla anserina	Pans	23	33	47	18	1	1	1	1
Trifolium fragiferum	Tfra	5	22	35			1	2	
Myosotis scorpioides	Mscs		17	32	18		1	1	
Rorripa sylvestris	Rsyl			15					
Ranunculus peltatus	Rpel			15					
Glyceria fluitans	Gflu		33	53	100		1	3	69
Galium palustre	Gpal		11	47	91		1	2	2
Polygonum amphibium	Pamp	2	39	76	91		1	1	3
Veronica scutellata	Vscu		11	15	73				1
Lemna minor	Lmin		11	6	45				1
Hydrocotyle vulgaris	Hvul			29	36			1	1
Mentha pulegium	Mpul			15	18				
Phleum pratense	Phleum	2	22	9	9		1		
Achillea ptarmica	Apta		12	12					
Plantago major	Pmaj	2	6	9					
Stellaria palustris	Spal			9					
Apium nodiflorum	Anod			6					
Lotus uliginosus	Luli			6					
Ludwigia palustris	Lpal			3					
Phleum pratense	Ppra			3					
Callitriche sp.	Casp	7	6						
Poa annua	Pann	7	6						
Juncus bufonius	Jbuf		6						

D.2 Random forest selected hyperparameters by random search optimization

Hyperparameter names	Selected modality
Number of estimator	300
Bootstrap	False
Criterion	Gini
Maximum depth	None
Maximum features	2
Minimum samples leaf	5
Minimum samples split	7
Minimum weight fraction leaf	0
Minimum impurity decrease	0
Maximum impurty split	None
Maximum leaf nodes	None
Scikit Learn random state	1

D.3 Habitats endmembers extracted from UAV, Pleiades and Sentinel-2 imagery at each acquisition date.




D.4 Domain adaptation methodology for radiometric intercalibration.

Since the data from the different domains were acquired at identical positions and at nearly the same dates, we assume that the distributions for equivalent spectral bands should be similar. The radiometric intercalibration approach used concern the adaptation of the data distributions (TUIA et al., 2016). The data distributions of the target (sentinel-2 bands) and source (sequoia bands) domains are made similar as possible to keep the processing algorithm (unmixing) unchanged. The adaptation is done by relative normalization, a method that not do not provide physical units as an output but that instead provide similarly distributed digital numbers. So source and target domains are known, and one just want to transform the distribution of the first one to make it similar to the second one, so no learning is necessary.

D.5 Correspondence Analysis (Greenacre, 2010)

Axis 12 explained 35.3% of total variance. A) species factorial map ; B) plot factorial map - a classification was done on plots in 2017 to define the habitat groups (1-4).



D.6 Mean confusion matrix between the RF classification of four plant communities derived from UAV imagery (columns) and field plots (lines)

Classes description : M – Mesophilic ; MH – Meso-Hygrophilic ; H – Hygrophilic ; BS - Bare soils ; Ud – Urtica dioica and W – Water. PA : Producer’s accuracy, UA : User’s accuracy.


		Classification									
		Class	M	MH 1	MH 2	H	Bs	Ud	W	PA	UA
Reference	M		32.5	1.6	1.7	0.1	0.1		0.6	0.92	0.89
	MH 1		1.4	7.4	4.8	0.5				0.64	0.53
	MH 2		1.1	2.3	23.7	1.4				0.75	0.83
	H			0.2	1.4	8.4				0.80	0.84
	Bs						2.7		0.1	0.97	0.98
	Ud		0.3					3.7		1.00	0.92
	W								3.9	0.86	1.00

D.7 Table of the relative importance of features computed by the RF algorithm.

Feature names	Features importance (Gini score)
2018-04-20_UAV_ndwi _{green}	0.0870
2018-04-20_UAV_red	0.0839
2018-04-20_UAV_ndvi_red-edge	0.0836
2018-04-20_UAV_ndv	0.0770
2018-04-20_UAV_nir	0.0758
2018-04-20_UAV_green	0.0664
2018-04-20_UAV_red-edge	0.0628
2018-05-18_UAV_red-edge	0.0556
2018-05-18_UAV_nir	0.0461
2018-05-18_UAV_ndwi_green	0.0433
2017-11-06_UAV_nir	0.0383
2017-11-06_UAV_red-edge	0.0342
2018-05-18_UAV_ndvi	0.0325
2017-11-06_UAV_ndwi_green	0.0322
2018-05-18_UAV_ndvi_red-edge	0.0316
2018-05-18_UAV_green	0.0302
2018-05-18_UAV_red	0.0300
2017-11-06_UAV_red	0.0245
2017-11-06_UAV_ndvi	0.0234
2017-11-06_UAV_green	0.0230
2017-11-06_UAV_ndvi_red-edge	0.0176

D.8 Scatter plots of UAV versus Satellite measurements with and without DA for the green spectral band

A) Pleiades at 2017-11-06; B) Pleiades at 2018-05-20; C) Sentinel-2 at 2018-04-19; and C) Sentinel-2 at 2018-05-19.




E Annexes du Chapitre 4 | Fusion de données : Cartographie des dynamiques d'inondation de prairie humide

E.1 Hyperparamètres sélectionnés expérimentalement.

Le planificateur décroît le taux d'apprentissage (t.a.) de l'optimiseur, la descente de gradient stochastique (SGD), par la valeur gamma à un pas défini en nombre d'époque.

Hyperparamètres		Sélection
Taille image		112 x 112
Taille du batch		10
Epoques		50
Planificateur	Optimiseur	SGD
	Momentum	0.9
	Base t.a.	0.01
	Pas	15
	Gamma	0.2

E.2 Mise en relation, sous forme de nuage de points, entre les prédictions du modèle *UNet-S2* et les références pour le jeu de donnée de validation.



BIBLIOGRAPHIE

- ABDULLAH, M. M., GHOLLOUM, M. M. & ABBAS, H. A., (2018), Satellite vs. UAVs Remote Sensing of Arid Ecosystems : A Review with in an Ecological Perspective, *Environmental Analysis & Ecology Studies*, 23, 1-5, Récupérée 16 octobre 2019, à partir de <http://crimsonpublishers.com/eaes/fulltext/EAES.000540.php>
- ADAM, E., MUTANGA, O. & RUGEGE, D., (2010), Multispectral and hyperspectral remote sensing for identification and mapping of wetland vegetation : a review, *Wetlands Ecology and Management*, 183, 281-296, <https://doi.org/10.1007/s11273-009-9169-z>
- ADLER, K., (2018), Radiometric correction of multispectral images collected by a UAV for phenology studies, *Student thesis series INES*, Récupérée 9 juin 2020, à partir de <http://lup.lub.lu.se/student-papers/record/8953564>
- AÏT HSSAÏNE, A., RIES, J. B., PETER, K. D., MARZOLFF, I. & D'OLEIRE-OLTMANN, S., (2011), Monitoring soil erosion in the souss basin, morocco, with a multiscale object-based remote sensing approach using UAV and satellite data, *Proceedings of The 1st World Sustainability Forum*, 562, <https://doi.org/10.3390/wsf-00562>
- ALAVIPANAH, S. K., MATINFAR, H. R., RAFIEI EMAM, A., KHODAEI, K., HADJI BAGHERI, R. & YAZDAN PANAH, A., (2010), Criteria of selecting satellite data for studying land resources, *Desert*, 152, 83-102, <https://doi.org/10.22059/jdesert.2011.23005>
- ALDABE, J., LANCTOT, R. B., BLANCO, D., ROCCA, P. & INCHAUSTI, P., (2019), Managing grasslands to maximize migratory shorebird use and livestock production, *Rangeland Ecology & Management*, 721, 150-159, <https://doi.org/10.1016/j.rama.2018.08.001>
- ALEEM, K., LORENZO, C., BIGLIA, A., RICAUDA AIMONINO, D., MARCELLO, C. & GAY, P., (2019), Comparison of satellite and UAV-based multispectral imagery for vineyard variability assessment, 114, 436-452, <https://doi.org/10.3390/rs11040436>

-
- ALLEAUME, S., DUSSEUX, P., THIERION, V., COMMAGNAC, L., LAVENTURE, S., LANG, M., FÉRET, J.-B., HUBERT-MOY, L. & LUQUE, S., (2018), A generic remote sensing approach to derive operational essential biodiversity variables (EBVs) for conservation planning, *Methods in Ecology and Evolution*, 98, 1822-1836, <https://doi.org/10.1111/2041-210X.13033>
- ALVAREZ-VANHARD, E., HOUET, T., MONY, C., LECOQ, L. & CORPETTI, T., (2020), Can UAVs fill the gap between in situ surveys and satellites for habitat mapping ?, *Remote Sensing of Environment*, 243, 111780, <https://doi.org/10.1016/j.rse.2020.111780>
- ANDERSON, K., (2016), Integrating multiple scales of remote sensing measurement – from satellites to kites, *Progress in Physical Geography : Earth and Environment*, 402, 187-195, <https://doi.org/10.1177/0309133316639175>
- ANDERSON, K. & GASTON, K. J., (2013), Lightweight unmanned aerial vehicles will revolutionize spatial ecology, *Frontiers in Ecology and the Environment*, 113, 138-146, <https://doi.org/10.1890/120150>
- ANDREW, M. E. & USTIN, S. L., (2009), Habitat suitability modelling of an invasive plant with advanced remote sensing data, *Diversity and Distributions*, 154, 627-640, <https://doi.org/10.1111/j.1472-4642.2009.00568.x>
- ANNIS, A., NARDI, F., PETROSELLI, A., APOLLONIO, C., ARCANGELETTI, E., TAURO, F., BELLI, C., BIANCONI, R. & GRIMALDI, S., (2020), UAV-DEMs for small-scale flood hazard mapping, *Water*, 126, 1717, <https://doi.org/10.3390/w12061717>
- ANTOINE, R., LOPEZ, T., TANGUY, M., LISSAK, C., GAILLER, L., LABAZUY, P. & FAUCHARD, C., (2020), Geoscientists in the sky : unmanned aerial vehicles responding to geohazards, *Surveys in Geophysics*, 416, 1285-1321, <https://doi.org/10.1007/s10712-020-09611-7>
- ASNER, G. P., (1998), Biophysical and Biochemical Sources of Variability in Canopy Reflectance, *Remote Sensing of Environment*, 643, 234-253, [https://doi.org/10.1016/S0034-4257\(98\)00014-5](https://doi.org/10.1016/S0034-4257(98)00014-5)
- ASSMANN, J. J., KERBY, J. T., CUNLIFFE, A. M. & MYERS-SMITH, I. H., (2018), Vegetation monitoring using multispectral sensors — best practices and lessons learned

-
- ned from high latitudes, *Journal of Unmanned Vehicle Systems*, 71, 54-75, <https://doi.org/10.1139/juvs-2018-0018>
- ATKINSON, P. M., (2013), Downscaling in remote sensing, *International Journal of Applied Earth Observation and Geoinformation*, 22, 106-114, <https://doi.org/10.1016/j.jag.2012.04.012>
- AUDEBERT, N., (2018), *Classification de données massives de télédétection* (thèse de doct.), Université Bretagne Sud, <https://tel.archives-ouvertes.fr/tel-02073908/document>
- AUDEBERT, N., LE SAUX, B. & LEFÈVRE, S., (2018), Beyond RGB : very high resolution urban remote sensing with multimodal deep networks, *ISPRS Journal of Photogrammetry and Remote Sensing*, 140, 20-32, <https://doi.org/10.1016/j.isprsjprs.2017.11.011>
- BARRERO, O. & PERDOMO, S. A., (2018), RGB and multispectral UAV image fusion for gramineae weed detection in rice fields, *Precision Agriculture*, 195, 809-822, <https://doi.org/10.1007/s11119-017-9558-x>
- BASTIN, L., (1997), Comparison of fuzzy c-means classification, linear mixture modelling and MLC probabilities as tools for unmixing coarse pixels, *International Journal of Remote Sensing*, 1817, 3629-3648, <https://doi.org/10.1080/014311697216847>
- BATES, P. D., NEAL, J. C., ALSDORF, D. & SCHUMANN, G. J.-P., (2014), Observing global surface water flood dynamics, *Surveys in Geophysics*, 353, 839-852, <https://doi.org/10.1007/s10712-013-9269-4>
- BAUMANN, P., MISEV, D., MERTICARIU, V. & HUU, B. P., (2019), Datacubes : towards space/time analysis-ready data, In J. DÖLLNER, M. JOBST & P. SCHMITZ (Éd.), *Service-oriented mapping : changing paradigm in map production and geoinformation management* (p. 269-299), Springer International Publishing, https://doi.org/10.1007/978-3-319-72434-8_14
- BEGET, M. E. & DI BELLA, C. M., (2007), Flooding : the effect of water depth on the spectral response of grass canopies, *Journal of Hydrology*, 3353, 285-294, <https://doi.org/10.1016/j.jhydrol.2006.11.018>

-
- BELGIU, M. & DRĂGUT, L., (2016), Random forest in remote sensing : A review of applications and future directions, *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24-31, <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- BELGIU, M. & STEIN, A., (2019), Spatiotemporal image fusion in remote sensing, *Remote Sensing*, 11 7, 818, <https://doi.org/10.3390/rs11070818>
- BETBEDER, J., RAPINEL, S., CORPETTI, T., POTTIER, E., CORGNE, S. & HUBERT-MOY, L., (2014), Multitemporal classification of TerraSAR-X data for wetland vegetation mapping, *Journal of Applied Remote Sensing*, 8 1, 083648, <https://doi.org/10.1117/1.JRS.8.083648>
- BIAN, J., LI, A., ZHANG, Z., ZHAO, W., LEI, G., XIA, H. & TAN, J., (2016), Grassland fractional vegetation cover monitoring using the composited HJ-1A/B time series images and unmanned aerial vehicles : A case study in Zoige wetland, China, *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 7192-7195, <https://doi.org/10.1109/IGARSS.2016.7730876>
- BINAGHI, E., BRIVIO, P. A., GHEZZI, P. & RAMPINI, A., (1999), A fuzzy set-based accuracy assessment of soft classification, *Pattern Recognition Letters*, 20 9, 935-948, [https://doi.org/10.1016/S0167-8655\(99\)00061-6](https://doi.org/10.1016/S0167-8655(99)00061-6)
- BIOUCAS-DIAS, J. M., PLAZA, A., DOBIGEON, N., PARENTE, M., DU, Q., GADER, P. & CHANUSSOT, J., (2012), Hyperspectral Unmixing Overview : Geometrical, Statistical, and Sparse Regression-Based Approaches, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5 2, 354-379, <https://doi.org/10.1109/JSTARS.2012.2194696>
- BONIS, A., (2014), *Hydropériode des zones humides : un enjeu décisif pour la structure des communautés végétales et leur diversité*, Lavoisier, Récupérée 13 avril 2019, à partir de <https://hal-univ-rennes1.archives-ouvertes.fr/hal-01115313>
- BOREL, C. C. & GERSTL, S. A. W., (1994), Nonlinear spectral mixing models for vegetative and soil surfaces, *Remote Sensing of Environment*, 47 3, 403-416, [https://doi.org/10.1016/0034-4257\(94\)90107-4](https://doi.org/10.1016/0034-4257(94)90107-4)
- BOUZILLÉ, J.-B., KERNÉIS, E., BONIS, A. & TOUZARD, B., (2001), Vegetation and ecological gradients in abandoned salt pans in western france, *Journal of Vegetation Science*, 12 2, 269-278, <https://doi.org/https://doi.org/10.2307/3236611>

-
- BREIMAN, L., (2001), Random forests, *Machine Learning*, 45 1, 5-32, <https://doi.org/10.1023/A:1010933404324>
- BRIGOT, G., COLIN-KOENIGUER, E., PLYER, A. & JANEZ, F., (2016), Adaptation and Evaluation of an Optical Flow Method Applied to Coregistration of Forest Remote Sensing Images, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9 7, 2923-2939, <https://doi.org/10.1109/JSTARS.2016.2578362>
- BRINKHOFF, J., HORNBUCKLE, J. & BARTON, J. L., (2018), Assessment of aquatic weed in irrigation channels using UAV and satellite imagery, *Water*, 10 11, 1497, <https://doi.org/10.3390/w10111497>
- BRIOTTET, X., MARION, R., CARRERE, V., JACQUEMOUD, S., CHEVREL, S., PRASTAULT, P., D'ORIA, M., GILOUPPE, P., HOSFORD, S., LUBAC, B. & BOURGUIGNON, A., (2011), HYPXIM : a new hyperspectral sensor combining science/defence applications, *2011 3rd Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS)*, 1-4, <https://doi.org/10.1109/WHISPERS.2011.6080957>
- BUNEL, M., (2021), Un état de l'art sur l'imprécision spatiale et sa modélisation, *Cybergeo : European Journal of Geography*, <https://doi.org/10.4000/cybergeo.36126>
- CÂNDIDO, A. K. A. A., FILHO, A. C. P., HAUPENTHAL, M. R., da SILVA, N. M., de SOUSA CORREA, J. & RIBEIRO, M. L., (2016), Water quality and chlorophyll measurement through vegetation indices generated from orbital and suborbital images, *Water, Air, & Soil Pollution*, 227 7, 224, <https://doi.org/10.1007/s11270-016-2919-7>
- CARBONNEAU, P. E., BELLETTI, B., MICOTTI, M., LASTORIA, B., CASAIOLI, M., MARIANI, S., MARCHETTI, G. & BIZZI, S., (2020), UAV-based training for fully fuzzy classification of sentinel-2 fluvial scenes, *Earth Surface Processes and Landforms*, n/a, <https://doi.org/10.1002/esp.4955>
- CASAGLI, N., FRODELLA, W., MORELLI, S., TOFANI, V., CIAMPALINI, A., INTRIERI, E., RASPINI, F., ROSSI, G., TANTERI, L. & LU, P., (2017), Spaceborne, UAV and ground-based remote sensing techniques for landslide mapping, monitoring and early warning, *Geoenvironmental Disasters*, 4 1, 9, <https://doi.org/10.1186/s40677-017-0073-1>

-
- CASAL, G., HEDLEY, J. D., MONTEYS, X., HARRIS, P., CAHALANE, C. & MCCARTHY, T., (2020), Satellite-derived bathymetry in optically complex waters using a model inversion approach and sentinel-2 data, *Estuarine, Coastal and Shelf Science*, 241, 106814, <https://doi.org/10.1016/j.ecss.2020.106814>
- CASANOVA, M. T. & BROCK, M. A., (2000), How do depth, duration and frequency of flooding influence the establishment of wetland plant communities ?, *Plant Ecology*, 1472, 237-250, <https://doi.org/10.1023/A:1009875226637>
- CENSI, A. M., IENCO, D., GBODJO, Y. J. E., PENSA, R. G., INTERDONATO, R. & GAETANO, R., (2021), Attentive Spatial Temporal Graph CNN for Land Cover Mapping From Multi Temporal Remote Sensing Data, *IEEE Access*, 9, 23070-23082, <https://doi.org/10.1109/ACCESS.2021.3055554>
- CHEN, B., HUANG, B. & XU, B., (2015), Comparison of spatiotemporal fusion models : a review, *Remote Sensing*, 72, 1798-1835, <https://doi.org/10.3390/rs70201798>
- COLOMINA, I. & MOLINA, P., (2014), Unmanned aerial systems for photogrammetry and remote sensing : A review, *ISPRS Journal of Photogrammetry and Remote Sensing*, 92, 79-97, <https://doi.org/10.1016/j.isprsjprs.2014.02.013>
- COOLEY, T., ANDERSON, G. P., FELDE, G. W., HOKE, M. L., RATKOWSKI, A. J., CHETWYND, J. H., GARDNER, J. A., ADLER-GOLDEN, S. M., MATTHEW, M. W., BERK, A., BERNSTEIN, L. S., ACHARYA, P. K., MILLER, D. & LEWIS, P., (2002), FLAASH, a MODTRAN4-based atmospheric correction algorithm, its application and validation, *IEEE International Geoscience and Remote Sensing Symposium*, 3, 1414-1418 vol.3, <https://doi.org/10.1109/IGARSS.2002.1026134>
- CORBANE, C., LANG, S., PIPKINS, K., ALLEAUME, S., DESHAYES, M., GARCÍA MILLÁN, V. E., STRASSER, T., VANDEN BORRE, J., TOON, S. & MICHAEL, F., (2015), Remote sensing for mapping natural habitats and their conservation status – New opportunities and challenges, *International Journal of Applied Earth Observation and Geoinformation*, 37, 7-16, <https://doi.org/10.1016/j.jag.2014.11.005>
- CORRIALE, M. J., PICCA, P. I. & di FRANCESCANTONIO, D., (2013), Seasonal variation of plant communities and their environments along a topographic gradient in the iberá wetland, ancient paraná floodplain, argentina, *Phytocoenologia*, 53-69, <https://doi.org/10.1127/0340-269X/2013/0043-0539>

-
- COSTANZA, R., D'ARGE, R., GROOT, R. d., FARBER, S., GRASSO, M., HANNON, B., LIMBURG, K., NAEEM, S., O'NEILL, R. V., PARUELO, J., RASKIN, R. G., SUTTON, P. & BELT, M. v. d., (1997), The value of the world's ecosystem services and natural capital, *Nature*, *387*6630, 253, <https://doi.org/10.1038/387253a0>
- CRACKNELL, A. P., (2017), UAVs : regulations and law enforcement, *International Journal of Remote Sensing*, *38*8, 3054-3067, <https://doi.org/10.1080/01431161.2017.1302115>
- CRACKNELL, A. P., (2018), The development of remote sensing in the last 40 years, *International Journal of Remote Sensing*, *39*23, 8387-8427, <https://doi.org/10.1080/01431161.2018.1550919>
- DECHOZ, C., POULAIN, V., MASSERA, S., LANGUILLE, F., GRESLOU, D., de LUSSY, F., GAUDEL, A., L'HELGUEN, C., PICARD, C. & TRÉMAS, T., (2015, octobre 15), Sentinel 2 global reference image, In L. BRUZZONE (Éd.), <https://doi.org/10.1117/12.2195046>
- DENG, C., LI, C., ZHU, Z., LIN, W. & XI, L., (2017), Subpixel urban impervious surface mapping : the impact of input Landsat images, *ISPRS Journal of Photogrammetry and Remote Sensing*, *133*, 89-103, <https://doi.org/10.1016/j.isprsjprs.2017.09.015>
- DENNY, P., (1994), Biodiversity and wetlands, *Wetlands Ecology and Management*, *3*1, 55-611, <https://doi.org/10.1007/BF00177296>
- DÍAZ-DELGADO, R. & MÜCHER, S., (2019), Editorial of special issue “drones for biodiversity conservation and ecological monitoring”, *Drones*, *3*2, 47, <https://doi.org/10.3390/drones3020047>
- DU, Q., (2018), Pixel Unmixing, In S. LIANG (Éd.), *Comprehensive Remote Sensing* (p. 186-198), Elsevier, <https://doi.org/10.1016/B978-0-12-409548-9.10337-9>
- DUDLEY, K. L., DENNISON, P. E., ROTH, K. L., ROBERTS, D. A. & COATES, A. R., (2015), A multi-temporal spectral library approach for mapping vegetation species across spatial and temporal phenological gradients, *Remote Sensing of Environment*, *167*, 121-134, <https://doi.org/10.1016/j.rse.2015.05.004>
- ELKIND, K., SANKEY, T. T., MUNSON, S. M. & ASLAN, C. E., (2019), Invasive buffelgrass detection using high-resolution satellite and UAV imagery on Google Earth Engine,

-
- Remote Sensing in Ecology and Conservation*, 54, 318331, <https://doi.org/10.1002/rse2.116>
- ELZINGA, C., SALZER, D. & WILLOUGHBY, J., (1998), Measuring & Monitoring Plant Populations, *U.S. Bureau of Land Management Papers*, <https://digitalcommons.unl.edu/usblmpub/17>
- ERUDEL, T., FABRE, S., HOUET, T., MAZIER, F. & BRIOTTET, X., (2017), Criteria Comparison for Classifying Peatland Vegetation Types Using In Situ Hyperspectral Measurements, *Remote Sensing*, 9748, pages 1-62, <https://doi.org/10.3390/rs9070748>
- EVERAERTS, J., (2009), NEWPLATFORMS - Unconventional Platforms (Unmanned Aircraft Systems) for Remote Sensing, Récupérée 8 août 2021, à partir de <http://www.eurosdrr.net/publications/official-publication-no-56-2009>
- FAWCETT, D. & ANDERSON, K., (2019), Investigating impacts of calibration methodology and irradiance variations on lightweight drone-based sensor derived surface reflectance products, *Remote Sensing for Agriculture, Ecosystems, and Hydrology XXI*, 11149, 111490D, <https://doi.org/10.1117/12.2533106>
- FAWCETT, D., PANIGADA, C., TAGLIABUE, G., BOSCHETTI, M., CELESTI, M., EVDOKIMOV, A., BIRIUKOVA, K., COLOMBO, R., MIGLIETTA, F., RASCHER, U. & ANDERSON, K., (2020), Multi-scale evaluation of drone-based multispectral surface reflectance and vegetation indices in operational conditions, *Remote Sensing*, 123, 514, <https://doi.org/10.3390/rs12030514>
- FEILHAUER, H., THONFELD, F., FAUDE, U., HE, K. S., ROCCHINI, D. & SCHMIDTLEIN, S., (2013), Assessing floristic composition with multispectral sensors—a comparison based on monotemporal and multiseasonal field spectra, *International Journal of Applied Earth Observation and Geoinformation*, 21, 218-229, <https://doi.org/10.1016/j.jag.2012.09.002>
- FEILHAUER, H., ZLINSZKY, A., KANIA, A., FOODY, G. M., DOKTOR, D., LAUSCH, A. & SCHMIDTLEIN, S., (2020), Let your maps be fuzzy!—class probabilities and floristic gradients as alternatives to crisp mapping for remote sensing of vegetation, *Remote Sensing in Ecology and Conservation*, n/a, <https://doi.org/https://doi.org/10.1002/rse2.188>

-
- FIRLA, M., MUSTAFA, O., PFEIFER, C., SENF, M. & HESE, S., (2019), INTRASEASONAL VARIABILITY OF GUANO STAINS IN a REMOTELY SENSED PENGUIN COLONY USING UAV AND SATELLITE, *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, IV-2-W5, 111-118, <https://doi.org/10.5194/isprs-annals-IV-2-W5-111-2019>
- FOODY, G. M., (1996), Fuzzy modelling of vegetation from remotely sensed imagery, *Ecological Modelling*, 85 1, 3-12, [https://doi.org/10.1016/0304-3800\(95\)00012-7](https://doi.org/10.1016/0304-3800(95)00012-7)
- FORSTER, M., SCHMIDT, T., GONZALEZ, A. R., CABEZAS, J. & FASSNACHT, F. E., (2018), Application of a One-Class Classifier and a Linear Spectral Unmixing Method for Detecting Invasive Species in Central Chile, *IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium*, 2883-2886, <https://doi.org/10.1109/IGARSS.2018.8518873>
- FUGAZZA, D., SENESE, A., AZZONI, R. S., SMIRAGLIA, C., CERNUSCHI, M., SEVERI, D. & DIOLAIUTI, G. A., (2015), High-resolution mapping of glacier surface features. The UAV survey of the Forni Glacier (Stelvio National Park, Italy), 38 1, 25-33, <https://doi.org/10.4461/GFDQ.2015.38.03>
- FYTSILIS, A. L., PROKOS, A., KOUTROUMBAS, K. D., MICHAIL, D. & KONTOES, C. C., (2016), A methodology for near real-time change detection between Unmanned Aerial Vehicle and wide area satellite images, *ISPRS Journal of Photogrammetry and Remote Sensing*, 119, 165-186, <https://doi.org/10.1016/j.isprsjprs.2016.06.001>
- GAMON, J. A., (2015), Reviews and Syntheses : optical sampling of the flux tower footprint, *Biogeosciences*, 12 14, 4509-4523, <https://doi.org/https://doi.org/10.5194/bg-12-4509-2015>
- GAO, F., MASEK, J., SCHWALLER, M. & HALL, F., (2006), On the blending of the Landsat and MODIS surface reflectance : predicting daily Landsat surface reflectance, *IEEE Transactions on Geoscience and Remote Sensing*, 44 8, 2207-2218, <https://doi.org/10.1109/TGRS.2006.872081>
- GARZELLI, A., (2016), A review of image fusion algorithms based on the super-resolution paradigm, *Remote Sensing*, 8 10, 797, <https://doi.org/10.3390/rs8100797>
- GAYET, G., BAPTIST, F. & BARAILLE, L., (2016), *Guide de la méthode nationale d'évaluation des fonctions des zones humides-version 1.0.*, Onema.

-
- GEHLER, P. V. & SCHÖLKOPF, B., (2009), An Introduction to Kernel Learning Algorithms. *Kernel Methods for Remote Sensing Data Analysis* (p. 25-48), John Wiley & Sons, Ltd, <https://doi.org/10.1002/9780470748992.ch2>
- GEVAERT, C., SUOMALAINEN, J. M., TANG, J. & KOOISTRA, L., (2015), Generation of spectral-temporal response surfaces by combining multispectral satellite and hyperspectral UAV imagery for precision agriculture applications, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 86, 3140-3146, <https://doi.org/10.1109/JSTARS.2015.2406339>
- GEVAERT, C., TANG, J., GARCIA-HARO, F., SUOMALAINEN, J. & KOOISTRA, L., (2014), Combining hyperspectral UAV and multispectral formosat-2 imagery for precision agriculture applications, *2014 6th Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS)*, 1-4, <https://doi.org/10.1109/WHISPERS.2014.8077607>
- GHAMISI, P., RASTI, B., YOKOYA, N., WANG, Q., HOFLE, B., BRUZZONE, L., BOVOLO, F., CHI, M., ANDERS, K., GLOAGUEN, R., ATKINSON, P. M. & BENEDIKTSSON, J. A., (2019), Multisource and Multitemporal Data Fusion in Remote Sensing : A Comprehensive Review of the State of the Art, *IEEE Geoscience and Remote Sensing Magazine*, 71, 6-39, <https://doi.org/10.1109/MGRS.2018.2890023>
- GILMORE, M. S., WILSON, E. H., BARRETT, N., CIVCO, D. L., PRISLOE, S., HURD, J. D. & CHADWICK, C., (2008), Integrating multi-temporal spectral and structural information to map wetland vegetation in a lower connecticut river tidal marsh, *Remote Sensing of Environment*, 11211, 4048-4060, <https://doi.org/10.1016/j.rse.2008.05.020>
- GITELSON, A. & MERZLYAK, M. N., (1994), 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*, 1433, 286-292, [https://doi.org/10.1016/S0176-1617\(11\)81633-0](https://doi.org/10.1016/S0176-1617(11)81633-0)
- GIULIANI, G., CAMARA, G., KILLOUGH, B. & MINCHIN, S., (2019), Earth observation open science : enhancing reproducible science using data cubes, *Data*, 44, 147, <https://doi.org/10.3390/data4040147>

-
- GÓRAJ, M., WRÓBLEWSKI, C., CIĘŻKOWSKI, W., JÓŹWIAK, J. & CHORMAŃSKI, J., (2019), Free water table area monitoring on wetlands using satellite and UAV orthophotomaps - Kampinos National Park case study, *Meteorology Hydrology and Water Management. Research and Operational Applications*, Vol. 7, Iss. 1, <https://doi.org/10.26491/mhwm/95086>
- GORELICK, N., HANCHER, M., DIXON, M., ILYUSHCHENKO, S., THAU, D. & MOORE, R., (2017), Google earth engine : planetary-scale geospatial analysis for everyone, *Remote Sensing of Environment*, 202, 18-27, <https://doi.org/10.1016/j.rse.2017.06.031>
- GREENACRE, M., (2010), Correspondence analysis of raw data, *Ecology*, 91 4, 958-963, <https://doi.org/10.1890/09-0239.1>
- GRUEN, A., ZHANG, Z. & EISENBEISS, H., (2012), UAV PHOTOGRAMMETRY IN REMOTE AREAS – 3d MODELING OF DRAPHAM DZONG BHUTAN, *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XXXIX-B1, 375-379, <https://doi.org/10.5194/isprsarchives-XXXIX-B1-375-2012>
- GUO, M., LI, J., SHENG, C., XU, J. & WU, L., (2017), A review of wetland remote sensing, *Sensors*, 17 4, 777, <https://doi.org/10.3390/s17040777>
- HAGOLLE, O., HUC, M., DESJARDINS, C., AUER, S. & RICHTER, R., (2017), MAJA Algorithm Theoretical Basis Document, <https://doi.org/10.5281/zenodo.1209633>
- HAGOLLE, O., HUC, M., VILLA PASCUAL, D. & DEDIEU, G., (2015), A multi-temporal and multi-spectral method to estimate aerosol optical thickness over land, for the atmospheric correction of FormoSat-2, LandSat, VENS and sentinel-2 images, *Remote Sensing*, 7 3, 2668-2691, <https://doi.org/10.3390/rs70302668>
- HAMADA, Y., STOW, D. A., ROBERTS, D. A., FRANKLIN, J. & KYRIAKIDIS, P. C., (2013), Assessing and monitoring semi-arid shrublands using object-based image analysis and multiple endmember spectral mixture analysis, *Environmental Monitoring and Assessment*, 185 4, 3173-3190, <https://doi.org/10.1007/s10661-012-2781-z>
- HARALICK, R. M., SHANMUGAM, K. & DINSTEN, I., (1973), Textural features for image classification, *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3 6, 610-621, <https://doi.org/10.1109/TSMC.1973.4309314>

-
- HASSAN-ESFAHANI, L., EBTEHAJ, A. M., TORRES-RUA, A. & MCKEE, M., (2017), Spatial scale gap filling using an unmanned aerial system : a statistical downscaling method for applications in precision agriculture, *Sensors*, 179, 2106, <https://doi.org/10.3390/s17092106>
- HAYASHI, M., van der KAMP, G. & ROSENBERRY, D. O., (2016), Hydrology of prairie wetlands : understanding the integrated surface-water and groundwater processes, *Wetlands*, 36 2, 237-254, <https://doi.org/10.1007/s13157-016-0797-9>
- HILL, R. A., GRANICA, K., SMITH, G. M. & SCHARDT, M., (2007), Representation of an alpine treeline ecotone in SPOT 5 HRG data, *Remote Sensing of Environment*, 110 4, 458-467, <https://doi.org/10.1016/j.rse.2006.11.031>
- HOUBORG, R. & MCCABE, M. F., (2018), A cubesat enabled spatio-temporal enhancement method (CESTEM) utilizing planet, landsat and MODIS data, *Remote Sensing of Environment*, 209, 211-226, <https://doi.org/10.1016/j.rse.2018.02.067>
- HOUET, T. & ALVAREZ-VANHARD, E., (2021), Série temporelle d'image multispectrale drone (Marais de Sougéal, mise à jour continue) - Zone Atelier Armorique ZAAr., *INDIGEO*, <https://doi.org/10.35110/a2fd0d4b-c41d-4315-85e1-35188b9a587b>
- HUANG, C., CHEN, Y., ZHANG, S. & WU, J., (2018), Detecting, extracting, and monitoring surface water from space using optical sensors : a review, *Reviews of Geophysics*, 56 2, 333-360, <https://doi.org/https://doi.org/10.1029/2018RG000598>
- HUANYU DING, CRISTOFALO, E., WANG, J., CASTAÑÓN, D., MONTIJANO, E., SALIGRAMA, V. & SCHWAGER, M., (2016), A multi-resolution approach for discovery and 3-D modeling of archaeological sites using satellite imagery and a UAV-borne camera, *2016 American Control Conference (ACC)*, 1359-1365, <https://doi.org/10.1109/ACC.2016.7525107>
- ICHTER, J., EVANS, D., RICHARD, D., PONCET, L., SPYROPOULOU, R., PEREIRA MARTINS, I., EUROPEAN ENVIRONMENT AGENCY & MUSEUM NATIONAL D'HISTOIRE NATURELLE (MNHN), (2014), *Terrestrial habitat mapping in europe : an overview.*, Publications Office, Récupérée 29 mars 2019, à partir de <http://dx.publications.europa.eu/10.2800/11055>

-
- IOFFE, S. & SZEGEDY, C., (2015), Batch Normalization : Accelerating Deep Network Training by Reducing Internal Covariate Shift, *arXiv :1502.03167 [cs]*, Récupérée 31 mai 2021, à partir de <http://arxiv.org/abs/1502.03167>
- JACOBSEN, K., (2012), Airborne or spaceborne images for topographic mapping ?, 8.
- JENEROWICZ, A., SIOK, K., WOROSZKIEWICZ, M. & ORYCH, A., (2017), The fusion of satellite and UAV data : simulation of high spatial resolution band, *Remote Sensing for Agriculture, Ecosystems, and Hydrology XIX*, 10421, 104211Z, <https://doi.org/10.1117/12.2278669>
- JENEROWICZ, A. & WOROSZKIEWICZ, M., (2016), The pan-sharpening of satellite and UAV imagery for agricultural applications, *Remote Sensing for Agriculture, Ecosystems, and Hydrology XVIII*, 9998, 99981S, <https://doi.org/10.1117/12.2241645>
- JIN, X., TANG, P., HOUET, T., CORPETTI, T., ALVAREZ-VANHARD, E. G. & ZHANG, Z., (2021), Sequence image interpolation via separable convolution network, *Remote Sensing*, 13 2, 296, <https://doi.org/10.3390/rs13020296>
- JOHNSON, J., ALAHI, A. & FEI-FEI, L., (2016), Perceptual Losses for Real-Time Style Transfer and Super-Resolution, *arXiv :1603.08155 [cs]*, Récupérée 25 février 2021, à partir de <http://arxiv.org/abs/1603.08155>
- JOHNSTON, C. A., ZEDLER, J. B., TULBURE, M. G., FRIESWYK, C. B., BEDFORD, B. L. & VACCARO, L., (2009), A unifying approach for evaluating the condition of wetland plant communities and identifying related stressors, *Ecological Applications*, 19 7, 1739-1757, <https://doi.org/10.1890/08-1290.1>
- JUREČKA, F., LUKAS, V., HLAVINKA, P., SEMERÁDOVÁ, D., ŽALUD, Z. & TRNKA, M., (2018), Estimating crop yields at the field level using landsat and modis products, *Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis*, 66 5, 1141-1150, <https://doi.org/10.11118/actaun201866051141>
- KAKOOEI, M. & BALEGHI, Y., (2017), Fusion of satellite, aircraft, and UAV data for automatic disaster damage assessment, *International Journal of Remote Sensing*, 38 8, 2511-2534, <https://doi.org/10.1080/01431161.2017.1294780>
- KARL, J. W., TAYLOR, J. & BOBO, M., (2014), A double-sampling approach to deriving training and validation data for remotely-sensed vegetation products, *International*

Journal of Remote Sensing, 35 5, 1936-1955, <https://doi.org/10.1080/01431161.2014.880820>

- KATTENBORN, T., LOPATIN, J., FÖRSTER, M., BRAUN, A. C. & FASSNACHT, F. E., (2019), UAV data as alternative to field sampling to map woody invasive species based on combined sentinel-1 and sentinel-2 data, *Remote Sensing of Environment*, 227, 61-73, <https://doi.org/10.1016/j.rse.2019.03.025>
- KEREKES, J. & LANDGREBE, D., (1991), Parameter trade-offs for imaging spectroscopy systems (remote sensing), *IEEE Transactions on Geoscience and Remote Sensing*, 29 1, 57-65, <https://doi.org/10.1109/36.103293>
- KESHA, N. & MUSTARD, J. F., (2002), Spectral unmixing, *IEEE Signal Processing Magazine*, 19 1, 44-57, <https://doi.org/10.1109/79.974727>
- KLOSTERMAN, S., MELAAS, E., WANG, J. A., MARTINEZ, A., FREDERICK, S., O'KEEFE, J., ORWIG, D. A., WANG, Z., SUN, Q., SCHAAF, C., FRIEDL, M. & RICHARDSON, A. D., (2018), Fine-scale perspectives on landscape phenology from unmanned aerial vehicle (UAV) photography, *Agricultural and Forest Meteorology*, 248, 397-407, <https://doi.org/10.1016/j.agrformet.2017.10.015>
- KOŁOS, A. & BANASZUK, P., (2013), Mowing as a tool for wet meadows restoration : effect of long-term management on species richness and composition of sedge-dominated wetland, *Ecological Engineering*, 55, 23-28, <https://doi.org/10.1016/j.ecoleng.2013.02.008>
- KOŁOS, A. & BANASZUK, P., (2018), Mowing may bring about vegetation change, but its effect is strongly modified by hydrological factors, *Wetlands Ecology and Management*, 26 5, 879-892, <https://doi.org/10.1007/s11273-018-9615-x>
- KUENZER, C., DECH, S. & WAGNER, W., (2015), Remote sensing time series revealing land surface dynamics : status quo and the pathway ahead, In C. KUENZER, S. DECH & W. WAGNER (Éd.), *Remote sensing time series : revealing land surface dynamics* (p. 1-24), Springer International Publishing, https://doi.org/10.1007/978-3-319-15967-6_1
- KUTSER, T., HEDLEY, J., GIARDINO, C., ROELFSEMA, C. & BRANDO, V. E., (2020), Remote sensing of shallow waters – a 50 year retrospective and future directions,

-
- Remote Sensing of Environment*, 240, 111619, <https://doi.org/10.1016/j.rse.2019.111619>
- LANGUILLE, F., DÉCHOZ, C., GAUDEL, A., GRESLOU, D., LUSSY, F. d., TRÉMAS, T. & POULAIN, V., (2015), Sentinel-2 geometric image quality commissioning : first results, *Image and Signal Processing for Remote Sensing XXI*, 9643, 964306, <https://doi.org/10.1117/12.2194339>
- LE CUN, Y., JACKEL, L., BOSER, B., DENKER, J., GRAF, H., GUYON, I., HENDERSON, D., HOWARD, R. & HUBBARD, W., (1989), Handwritten digit recognition : applications of neural network chips and automatic learning, *IEEE Communications Magazine*, 2711, 41-46, <https://doi.org/10.1109/35.41400>
- LECUN, Y., BENGIO, Y. & HINTON, G., (2015), Deep learning, *Nature*, 521 7553, 436-444, <https://doi.org/10.1038/nature14539>
- LEWIS, A., OLIVER, S., LYMBURNER, L., EVANS, B., WYBORN, L., MUELLER, N., RAEVSKI, G., HOOKE, J., WOODCOCK, R., SIXSMITH, J., WU, W., TAN, P., LI, F., KILLOUGH, B., MINCHIN, S., ROBERTS, D., AYERS, D., BALA, B., DWYER, J., ... WANG, L.-W., (2017), The australian geoscience data cube — foundations and lessons learned, *Remote Sensing of Environment*, 202, 276-292, <https://doi.org/10.1016/j.rse.2017.03.015>
- LI, L., USTIN, S. L. & LAY, M., (2005), Application of multiple endmember spectral mixture analysis (MESMA) to AVIRIS imagery for coastal salt marsh mapping : a case study in China Camp, CA, USA, *International Journal of Remote Sensing*, 26 23, 5193-5207, <https://doi.org/10.1080/01431160500218911>
- LIANG, H., HUANG, X., SUN, Y., WANG, Y. & LIANG, T., (2017), Fractional snow-cover mapping based on MODIS and UAV data over the tibetan plateau, *Remote Sensing*, 9 12, 1332, <https://doi.org/10.3390/rs9121332>
- LIN, A. Y., NOVO, A., HAR-NOY, S., RICKLIN, N. D. & STAMATIOU, K., (2011), Combining GeoEye-1 Satellite Remote Sensing, UAV Aerial Imaging, and Geophysical Surveys in Anomaly Detection Applied to Archaeology, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 4 4, 870-876, <https://doi.org/10.1109/JSTARS.2011.2143696>

-
- LING, F., XIAO, F., DU, Y., XUE, H. P. & REN, X. Y., (2008), Waterline mapping at the subpixel scale from remote sensing imagery with high-resolution digital elevation models, *International Journal of Remote Sensing*, 29 6, 1809-1815, <https://doi.org/10.1080/01431160701802489>
- LIU, H., DAHLGREN, R. A., LARSEN, R. E., DEVINE, S. M., ROCHE, L. M., O' GEEN, A. T., WONG, A. J. Y., COVELLO, S. & JIN, Y., (2019), Estimating rangeland forage production using remote sensing data from a small unmanned aerial system (sUAS) and PlanetScope satellite, *Remote Sensing*, 11 5, 595, <https://doi.org/10.3390/rs11050595>
- LIU, P., DI, L., DU, Q. & WANG, L., (2018), Remote sensing big data : theory, methods and applications, *Remote Sensing*, 10 5, 711, <https://doi.org/10.3390/rs10050711>
- LIU, W., YANG, M., XIE, M., GUO, Z., LI, E., ZHANG, L., PEI, T. & WANG, D., (2019), Accurate building extraction from fused DSM and UAV images using a chain fully convolutional neural network, *Remote Sensing*, 11 24, 2912, <https://doi.org/10.3390/rs11242912>
- LIU, Y., CHEN, X., WANG, Z., WANG, Z. J., WARD, R. K. & WANG, X., (2018), Deep learning for pixel-level image fusion : Recent advances and future prospects, *Information Fusion*, 42, 158-173, <https://doi.org/10.1016/j.inffus.2017.10.007>
- LONG, J., SHELHAMER, E. & DARRELL, T., (2015), Fully convolutional networks for semantic segmentation, *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 3431-3440, <https://doi.org/10.1109/CVPR.2015.7298965>
- LONJOU, V., LACHÉRADE, S., FOUGNIE, B., GAMET, P., MARCQ, S., RAYNAUD, J.-L. & TREMAS, T., (2015), Sentinel-2/MSI absolute calibration : first results, *Sensors, Systems, and Next-Generation Satellites XIX*, 9639, 963906, <https://doi.org/10.1117/12.2194968>
- LONJOU, V., DESJARDINS, C., HAGOLLE, O., PETRUCCI, B., TREMAS, T., DEJUS, M., MAKARAU, A. & AUER, S., (2016), MACCS-ATCOR joint algorithm (MAJA), *Remote Sensing of Clouds and the Atmosphere XXI*, 10001, 1000107, <https://doi.org/10.1117/12.2240935>

-
- LOPEZ, R. D. & FENNESSY, M. S., (2002), Testing the floristic quality assessment index as an indicator of wetland condition, *Ecological Applications*, 122, 487-497, [https://doi.org/10.1890/1051-0761\(2002\)012\[0487:TTFQAI\]2.0.CO;2](https://doi.org/10.1890/1051-0761(2002)012[0487:TTFQAI]2.0.CO;2)
- LU, Y., WANG, R., ZHANG, Y., SU, H., WANG, P., JENKINS, A., FERRIER, R. C., BAILEY, M. & SQUIRE, G., (2015), Ecosystem health towards sustainability, *Ecosystem Health and Sustainability*, 11, 1-15, <https://doi.org/10.1890/EHS14-0013.1>
- MA, L., ZHOU, Y., CHEN, J., CAO, X. & CHEN, X., (2015), Estimation of Fractional Vegetation Cover in Semiarid Areas by Integrating Endmember Reflectance Purification Into Nonlinear Spectral Mixture Analysis, *IEEE Geoscience and Remote Sensing Letters*, 126, 1175-1179, <https://doi.org/10.1109/LGRS.2014.2385816>
- MA, L., LIU, Y., ZHANG, X., YE, Y., YIN, G. & JOHNSON, B. A., (2019), Deep learning in remote sensing applications : A meta-analysis and review, *ISPRS Journal of Photogrammetry and Remote Sensing*, 152, 166-177, <https://doi.org/10.1016/j.isprsjprs.2019.04.015>
- MAHDIANPARI, M., SALEHI, B., REZAEI, M., MOHAMMADIMANESH, F. & ZHANG, Y., (2018), Very deep convolutional neural networks for complex land cover mapping using multispectral remote sensing imagery, *Remote Sensing*, 107, 1119, <https://doi.org/10.3390/rs10071119>
- MALEKMOHAMMADI, B. & JAHANISHAKIB, F., (2017), Vulnerability assessment of wetland landscape ecosystem services using driver-pressure-state-impact-response (DP-SIR) model, *Ecological Indicators*, 82, 293-303, <https://doi.org/10.1016/j.ecolind.2017.06.060>
- MANDLBURGER, G., KÖLLE, M., NÜBEL, H. & SOERGEL, U., (2021), BathyNet : a deep neural network for water depth mapping from multispectral aerial images, *PFG – Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, <https://doi.org/10.1007/s41064-021-00142-3>
- MARCACCIO, J. V., MARKLE, C. E. & CHOW-FRASER, P., (2016), Use of fixed-wing and multi-rotor unmanned aerial vehicles to map dynamic changes in a freshwater marsh, *International Conference on UAVs in Geomatics (UAV-g)*, 011, 193-202, <https://doi.org/10.1139/juvs-2015-0016@juvs-ic.issue01>

-
- MARTÍNEZ-LÓPEZ, J., CARREÑO, M. F., PALAZÓN-FERRANDO, J. A., MARTÍNEZ-FERNÁNDEZ, J. & ESTEVE, M. A., (2014), Remote sensing of plant communities as a tool for assessing the condition of semiarid Mediterranean saline wetlands in agricultural catchments, *International Journal of Applied Earth Observation and Geoinformation*, 26, 193-204, <https://doi.org/10.1016/j.jag.2013.07.005>
- MARTÍNEZ-SÁNCHEZ, J., GONZÁLEZ-DE SANTOS, L. M., NOVO, A. & GONZÁLEZ-JORGE, H., (2019), UAV AND SATELLITE IMAGERY APPLIED TO ALIEN SPECIES MAPPING IN NW SPAIN, *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-2-W13, 455-459, <https://doi.org/https://doi.org/10.5194/isprs-archives-XLII-2-W13-455-2019>
- MARTONCHIK, J. V., (1994), Retrieval of surface directional reflectance properties using ground level multiangle measurements, *Remote Sensing of Environment*, 50 3, 303-316, [https://doi.org/10.1016/0034-4257\(94\)90080-9](https://doi.org/10.1016/0034-4257(94)90080-9)
- MARX, A., MCFARLANE, D. & ALZHRANI, A., (2017), UAV data for multi-temporal Landsat analysis of historic reforestation : a case study in Costa Rica, *International Journal of Remote Sensing*, 38 8, 2331-2348, <https://doi.org/10.1080/01431161.2017.1280637>
- MATESE, A., TOSCANO, P., DI GENNARO, S. F., GENESIO, L., VACCARI, F. P., PRIMICERIO, J., BELLI, C., ZALDEI, A., BIANCONI, R. & GIOLI, B., (2015), Intercomparison of UAV, aircraft and satellite remote sensing platforms for precision viticulture, *Remote Sensing*, 7 3, 2971-2990, <https://doi.org/10.3390/rs70302971>
- MATOUŠKOVÁ, E., STARKOVÁ, L., PAVELKA, K., NOVÁČEK, K., ŠEDINA, J., FALTÝNOVÁ, M. & HOUSAROVÁ, E., (2016), USING REMOTELY SENSED DATA FOR DOCUMENTATION OF ARCHAEOLOGICAL SITES IN NORTHEASTERN MESOPOTAMIA, *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLI-B5, 335-342, <https://doi.org/https://doi.org/10.5194/isprs-archives-XLI-B5-335-2016>
- MELVILLE, B., FISHER, A. & LUCIEER, A., (2019), Ultra-high spatial resolution fractional vegetation cover from unmanned aerial multispectral imagery, *International Journal of Applied Earth Observation and Geoinformation*, 78, 14-24, <https://doi.org/10.1016/j.jag.2019.01.013>

-
- MENGMENG, D., NOBORU, N., ATSUSHI, I. & YUKINORI, S., (2017), Multi-temporal monitoring of wheat growth by using images from satellite and unmanned aerial vehicle, *International Journal of Agricultural and Biological Engineering*, 105, 1-13, <https://doi.org/10.25165/ijabe.v10i5.3180>
- MERCHANT, M. A., (2020), Classifying open water features using optical satellite imagery and an object-oriented convolutional neural network, *Remote Sensing Letters*, 1112, 1127-1136, <https://doi.org/10.1080/2150704X.2020.1825869>
- MERCIER, G., HUBERT-MOY, L., HOUET, T. & GOUERY, P., (2005), Estimation and monitoring of bare soil/vegetation ratio with SPOT VEGETATION and HRVIR, *IEEE Transactions on Geoscience and Remote Sensing*, 432, 348-354, <https://doi.org/10.1109/TGRS.2004.841628>
- MICHISHITA, R., GONG, P. & XU, B., (2012), Spectral mixture analysis for bi-sensor wetland mapping using Landsat TM and Terra MODIS data, *International Journal of Remote Sensing*, 3311, 3373-3401, <https://doi.org/10.1080/01431161.2011.611185>
- MILAS, A. S., CRACKNELL, A. P. & WARNER, T. A., (2018), Drones – the third generation source of remote sensing data, *International Journal of Remote Sensing*, 3921, 7125-7137, <https://doi.org/10.1080/01431161.2018.1523832>
- MOFFETT, K. B. & GORELICK, S. M., (2013), Distinguishing wetland vegetation and channel features with object-based image segmentation, *International Journal of Remote Sensing*, 344, 1332-1354, <https://doi.org/10.1080/01431161.2012.718463>
- MÜLLEROVÁ, J., BRŮNA, J., BARTALOŠ, T., DVOŘÁK, P., VÍTKOVÁ, M. & PYŠEK, P., (2017), Timing Is Important : Unmanned Aircraft vs. Satellite Imagery in Plant Invasion Monitoring, *Frontiers in Plant Science*, 8, 887, <https://doi.org/10.3389/fpls.2017.00887>
- MÜLLEROVÁ, J., BRŮNA, J., DVOŘÁK, P., BARTALOŠ, T. & VÍTKOVÁ, M., (2016), DOES THE DATA RESOLUTION/ORIGIN MATTER ? SATELLITE, AIRBORNE AND UAV IMAGERY TO TACKLE PLANT INVASIONS, *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLI-B7, 903-908, <https://doi.org/10.5194/isprsarchives-XLI-B7-903-2016>

-
- NAKHOSTIN, S., CLENET, H., CORPETTI, T. & COURTY, N., (2016), Joint Anomaly Detection and Spectral Unmixing for Planetary Hyperspectral Images, *IEEE Transactions on Geoscience and Remote Sensing*, 54 12, 6879-6894, <https://doi.org/10.1109/TGRS.2016.2586188>
- NHAMO, L., VAN DIJK, R., MAGIDI, J., WIBERG, D. & TSHIKOLOMO, K., (2018), Improving the accuracy of remotely sensed irrigated areas using post-classification enhancement through UAV capability, *Remote Sensing*, 10 5, 712, <https://doi.org/10.3390/rs10050712>
- NICODEMUS, F. E., RICHMOND, J. C., HSIA, J. J., GINSBERG, I. W. & LIMPERIS, T., (1977), *Geometrical considerations and nomenclature for reflectance* (NBS MONO 160), National Bureau of Standards, Gaithersburg, MD, <https://doi.org/10.6028/NBS.MONO.160>
- NIKOLAKOPOULOS, K., KYRIOU, A., KOUKOUVELAS, I., ZYGOURI, V. & APOSTOLOPOULOS, D., (2019), Combination of aerial, satellite, and UAV photogrammetry for mapping the diachronic coastline evolution : the case of lefkada island, *ISPRS International Journal of Geo-Information*, 8 11, 489, <https://doi.org/10.3390/ijgi8110489>
- NOTTI, D., GIORDAN, D., CALÓ, F., PEPE, A., ZUCCA, F. & GALVE, J. P., (2018), Potential and limitations of open satellite data for flood mapping, *Remote Sensing*, 10 11, 1673, <https://doi.org/10.3390/rs10111673>
- O'CONNOR, B., SECADES, C., PENNER, J., SONNENSCHNEIN, R., SKIDMORE, A., BURGESS, N. D. & HUTTON, J. M., (2015), Earth observation as a tool for tracking progress towards the aichi biodiversity targets, *Remote Sensing in Ecology and Conservation*, 1 1, 19-28, <https://doi.org/10.1002/rse2.4>
- OH, J., TOTH, C. K. & GREJNER-BRZEZINSKA, D. A., (2011), Automatic Georeferencing of Aerial Images Using Stereo High-Resolution Satellite Images, *Photogrammetric Engineering & Remote Sensing*, 77 11, 1157-1168, <https://doi.org/10.14358/PERS.77.11.1157>
- OUYANG, Z.-T., GAO, Y., XIE, X., GUO, H.-Q., ZHANG, T.-T. & ZHAO, B., (2013), Spectral Discrimination of the Invasive Plant *Spartina alterniflora* at Multiple Phenological Stages in a Saltmarsh Wetland, *PloS One*, 8 6, e67315, <https://doi.org/10.1371/journal.pone.0067315>

-
- PACHECO, A. & MCNAIRN, H., (2010), Evaluating multispectral remote sensing and spectral unmixing analysis for crop residue mapping, *Remote Sensing of Environment*, 114 10, 2219-2228, <https://doi.org/10.1016/j.rse.2010.04.024>
- PADRÓ, J.-C., MUÑOZ, F.-J., ÁVILA, L. Á., PESQUER, L. & PONS, X., (2018), Radiometric correction of landsat-8 and sentinel-2a scenes using drone imagery in synergy with field spectroradiometry, *Remote Sensing*, 10 11, 1687, <https://doi.org/10.3390/rs10111687>
- PAPAKONSTANTINO, A., DOUKARI, M., STAMATIS, P. & TOPOUZELIS, K., (2019), Coastal management using UAS and high-resolution satellite images for touristic areas, *International Journal of Applied Geospatial Research (IJAGR)*, 10 1, 54-72, <https://doi.org/10.4018/IJAGR.2019010103>
- PASZKE, A., GROSS, S., MASSA, F., LERER, A., BRADBURY, J., CHANAN, G., KILLEEN, T., LIN, Z., GIMELSHEIN, N., ANTIGA, L., DESMAISON, A., KÖPF, A., YANG, E., DEVITO, Z., RAISON, M., TEJANI, A., CHILAMKURTHY, S., STEINER, B., FANG, L., ... CHINTALA, S., (2019), PyTorch : An Imperative Style, High-Performance Deep Learning Library, *arXiv :1912.01703 [cs, stat]*, Récupérée 9 juin 2021, à partir de <http://arxiv.org/abs/1912.01703>
- PEDERGNANA, M., MARPU, P. R., DALLA MURA, M., BENEDIKTSSON, J. A. & BRUZZONE, L., (2012), Classification of Remote Sensing Optical and LiDAR Data Using Extended Attribute Profiles, *IEEE Journal of Selected Topics in Signal Processing*, 6 7, 856-865, <https://doi.org/10.1109/JSTSP.2012.2208177>
- PEDREGOSA, F., VAROQUAUX, G., GRAMFORT, A., MICHEL, V., THIRION, B., GRISEL, O., BLONDEL, M., PRETTENHOFER, P., WEISS, R., DUBOURG, V., VANDERPLAS, J., PASSOS, A., COURNAPEAU, D., BRUCHER, M., PERROT, M. & DUCHESNAY, É., (2011), Scikit-learn : Machine Learning in Python, *Journal of Machine Learning Research*, 12, 2825-2830, Récupérée 2 janvier 2019, à partir de <http://www.jmlr.org/papers/v12/pedregosa11a.html>
- PELLETIER, C., WEBB, G. I. & PETITJEAN, F., (2019), Temporal convolutional neural network for the classification of satellite image time series, *Remote Sensing*, 11 5, 523, <https://doi.org/10.3390/rs11050523>

-
- PEREIRA, H. M., FERRIER, S., WALTERS, M., GELLER, G. N., JONGMAN, R. H. G., SCHOLES, R. J., BRUFORD, M. W., BRUMMITT, N., BUTCHART, S. H. M., CARDOSO, A. C., COOPS, N. C., DULLOO, E., FAITH, D. P., FREYHOF, J., GREGORY, R. D., HEIP, C., HÖFT, R., HURTT, G., JETZ, W., ... WEGMANN, M., (2013), Essential biodiversity variables, *Science*, 339 6117, 277-278, <https://doi.org/10.1126/science.1229931>
- PERSSON, M., LINDBERG, E. & REESE, H., (2018), Tree species classification with multi-temporal sentinel-2 data, *Remote Sensing*, 10 11, 1794, <https://doi.org/10.3390/rs10111794>
- PETTORELLI, N., SAFI, K. & TURNER, W., (2014), Satellite remote sensing, biodiversity research and conservation of the future, *Philosophical Transactions of the Royal Society B : Biological Sciences*, 369 1643, 20130190, <https://doi.org/10.1098/rstb.2013.0190>
- PHIRI, D., SIMWANDA, M., SALEKIN, S., NYIRENDA, V. R., MURAYAMA, Y. & RANAGALAGE, M., (2020), Sentinel-2 data for land cover/use mapping : a review, *Remote Sensing*, 12 14, 2291, <https://doi.org/10.3390/rs12142291>
- POHL, C. & GENDEREN, J. L. V., (1998), Review article Multisensor image fusion in remote sensing : Concepts, methods and applications, *International Journal of Remote Sensing*, 19 5, 823-854, <https://doi.org/10.1080/014311698215748>
- QI, C. R., SU, H., MO, K. & GUIBAS, L. J., (2017), PointNet : Deep Learning on Point Sets for 3D Classification and Segmentation, 652-660, Récupérée 22 août 2021, à partir de https://openaccess.thecvf.com/content_cvpr_2017/html/Qi_PointNet_Deep_Learning_CVPR_2017_paper.html
- RAPINEL, S., CLÉMENT, B. & HUBERT-MOY, L., (2019), Cartographie des zones humides par télédétection : approche multi-scalaire pour une planification environnementale, *Cybergeo : European Journal of Geography*, <https://doi.org/10.4000/cybergeo.31606>
- RAPINEL, S., HUBERT-MOY, L., CLÉMENT, B. & MALTBY, E., (2016), Mapping wetland functions using earth observation data and multi-criteria analysis, *Environmental Monitoring and Assessment*, 188 11, 641, <https://doi.org/10.1007/s10661-016-5644-1>

-
- RAPINEL, S., MONY, C., LECOQ, L., CLÉMENT, B., THOMAS, A. & HUBERT-MOY, L., (2019), Evaluation of Sentinel-2 time-series for mapping floodplain grassland plant communities, *Remote Sensing of Environment*, 223, 115-129, <https://doi.org/10.1016/j.rse.2019.01.018>
- RAPINEL, S., ROSSIGNOL, N., GORE, O., JAMBON, O., BOUGER, G., MANSON, J. & BONIS, A., (2018), Daily monitoring of shallow and fine-grained water patterns in wet grasslands combining aerial LiDAR data and in situ piezometric measurements, *Sustainability*, 10 3, 708, <https://doi.org/10.3390/su10030708>
- RAPINEL, S., ROSSIGNOL, N., HUBERT-MOY, L., BOUZILLÉ, J.-B. & BONIS, A., (2018), Mapping grassland plant communities using a fuzzy approach to address floristic and spectral uncertainty, *Applied Vegetation Science*, 00, <https://doi.org/10.1111/avsc.12396>
- RAU, J.-Y., JHAN, J.-P. & RAU, R.-J., (2014), Semiautomatic Object-Oriented Landslide Recognition Scheme From Multisensor Optical Imagery and DEM, *IEEE Transactions on Geoscience and Remote Sensing*, 52 2, 1336-1349, <https://doi.org/10.1109/TGRS.2013.2250293>
- REBELO, A. J., SOMERS, B., ESLER, K. J. & MEIRE, P., (2018), Can wetland plant functional groups be spectrally discriminated?, *Remote Sensing of Environment*, 210, 25-34, <https://doi.org/10.1016/j.rse.2018.02.031>
- REBEYROL, S., (2021, octobre 6), *Apport d'une voie panchromatique pour le démixage d'images hyperspectrales* (thèse de doct.), Université Toulouse 3 - Paul Sabatier, Toulouse.
- REZAEI, M., MAHDIANPARI, M., ZHANG, Y. & SALEHI, B., (2018), Deep Convolutional Neural Network for Complex Wetland Classification Using Optical Remote Sensing Imagery, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11 9, 3030-3039, <https://doi.org/10.1109/JSTARS.2018.2846178>
- RICHTER, R., BACHMANN, M., DORIGO, W. & MULLER, A., (2006), Influence of the Adjacency Effect on Ground Reflectance Measurements, *IEEE Geoscience and Remote Sensing Letters*, 3 4, 565-569, <https://doi.org/10.1109/LGRS.2006.882146>
- RIIHIMÄKI, H., LUOTO, M. & HEISKANEN, J., (2019), Estimating fractional cover of tundra vegetation at multiple scales using unmanned aerial systems and optical

-
- satellite data, *Remote Sensing of Environment*, 224, 119-132, <https://doi.org/10.1016/j.rse.2019.01.030>
- ROBERTS, D. A., GARDNER, M., CHURCH, R., USTIN, S., SCHEER, G. & GREEN, R. O., (1998), Mapping Chaparral in the Santa Monica Mountains Using Multiple End-member Spectral Mixture Models, *Remote Sensing of Environment*, 65 3, 267-279, [https://doi.org/10.1016/S0034-4257\(98\)00037-6](https://doi.org/10.1016/S0034-4257(98)00037-6)
- ROBERTS, D. A., SMITH, M. O. & ADAMS, J. B., (1993), Green vegetation, nonphotosynthetic vegetation, and soils in AVIRIS data, *Remote Sensing of Environment*, 44 2, 255-269, [https://doi.org/10.1016/0034-4257\(93\)90020-X](https://doi.org/10.1016/0034-4257(93)90020-X)
- ROCCHINI, D., FOODY, G. M., NAGENDRA, H., RICOTTA, C., ANAND, M., HE, K. S., AMICI, V., KLEINSCHMIT, B., FÖRSTER, M., SCHMIDTLEIN, S., FEILHAUER, H., GHISLA, A., METZ, M. & NETELER, M., (2013), Uncertainty in ecosystem mapping by remote sensing, *Computers & Geosciences*, 50, 128-135, <https://doi.org/10.1016/j.cageo.2012.05.022>
- RONNEBERGER, O., FISCHER, P. & BROX, T., (2015), U-Net : Convolutional Networks for Biomedical Image Segmentation, *arXiv :1505.04597 [cs]*, Récupérée 5 mai 2021, à partir de <http://arxiv.org/abs/1505.04597>
- ROOSJEN, P. P. J., SUOMALAINEN, J. M., BARTHOLOMEUS, H. M., KOOISTRA, L. & CLEVERS, J. G. P. W., (2017), Mapping reflectance anisotropy of a potato canopy using aerial images acquired with an unmanned aerial vehicle, *Remote Sensing*, 9 5, 417, <https://doi.org/10.3390/rs9050417>
- ROSSO, P. H., USTIN, S. L. & HASTINGS, A., (2005), Mapping marshland vegetation of San Francisco Bay, California, using hyperspectral data, *International Journal of Remote Sensing*, 26 23, 5169-5191, <https://doi.org/10.1080/01431160500218770>
- ROSTAMI, M., KOLOURI, S., EATON, E. & KIM, K., (2019), Deep transfer learning for few-shot SAR image classification, *Remote Sensing*, 11 11, 1374, <https://doi.org/10.3390/rs11111374>
- ROTH, K. L., ROBERTS, D. A., DENNISON, P. E., PETERSON, S. H. & ALONZO, M., (2015), The impact of spatial resolution on the classification of plant species and functional types within imaging spectrometer data, *Remote Sensing of Environment*, 171, 45-57, <https://doi.org/10.1016/j.rse.2015.10.004>

-
- ROUSE, J. W., Jr., HAAS, R. H., SCHELL, J. A. & DEERING, D. W., (1974), Monitoring Vegetation Systems in the Great Plains with ERTS, *NASA Special Publication*, 351, 309, Récupérée 6 mars 2019, à partir de <http://adsabs.harvard.edu/abs/1974NASSP.351..309R>
- RUPASINGHE, P. A., MILAS, A. S., AREND, K., SIMONSON, M. A., MAYER, C. & MACKEY, S., (2019), Classification of shoreline vegetation in the Western Basin of Lake Erie using airborne hyperspectral imager HSI2, Pleiades and UAV data, *International Journal of Remote Sensing*, 40 8, 3008-3028, <https://doi.org/10.1080/01431161.2018.1539267>
- RUWAIMANA, M., SATYANARAYANA, B., OTERO, V., MUSLIM, A. M., A, M. S., IBRAHIM, S., RAYMAEKERS, D., KOEDAM, N. & DAHDOUNH-GUEBAS, F., (2018), The advantages of using drones over space-borne imagery in the mapping of mangrove forests, *PLOS ONE*, 13 7, e0200288, <https://doi.org/10.1371/journal.pone.0200288>
- SAWAYA, K. E., OLMANSON, L. G., HEINERT, N. J., BREZONIK, P. L. & BAUER, M. E., (2003), Extending satellite remote sensing to local scales : land and water resource monitoring using high-resolution imagery, *Remote Sensing of Environment*, 88 1, 144-156, <https://doi.org/10.1016/j.rse.2003.04.006>
- SCHAAF, A. N., DENNISON, P. E., FRYER, G. K., ROTH, K. L. & ROBERTS, D. A., (2011), Mapping Plant Functional Types at Multiple Spatial Resolutions Using Imaging Spectrometer Data, *GIScience & Remote Sensing*, 48 3, 324-344, <https://doi.org/10.2747/1548-1603.48.3.324>
- SCHAEPMAN-STRUB, G., SCHAEPMAN, M. E., PAINTER, T. H., DANGEL, S. & MARTONCHIK, J. V., (2006), Reflectance quantities in optical remote sensing—definitions and case studies, *Remote Sensing of Environment*, 103 1, 27-42, <https://doi.org/10.1016/j.rse.2006.03.002>
- SCHAFFER-SMITH, D., SWENSON, J. J., REITER, M. E. & ISOLA, J. E., (2018), Quantifying shorebird habitat in managed wetlands by modeling shallow water depth dynamics, *Ecological Applications*, 28 6, 1534-1545, <https://doi.org/https://doi.org/10.1002/eap.1732>
- SCHMELLER, D. S., WEATHERDON, L. V., LOYAU, A., BONDEAU, A., BROTONS, L., BRUMMITT, N., GEIJZENDORFFER, I. R., HAASE, P., KUEMMERLEN, M., MARTIN,

-
- C. S., MIHOUB, J.-B., ROCCHINI, D., SAARENMAA, H., STOLL, S. & REGAN, E. C., (2018), A suite of essential biodiversity variables for detecting critical biodiversity change, *Biological Reviews*, *93*1, 55-71, <https://doi.org/10.1111/brv.12332>
- SCHUMANN, G. J.-P., MUHLHAUSEN, J. & ANDREADIS, K. M., (2019), Rapid mapping of small-scale river-floodplain environments using UAV SfM supports classical theory, *Remote Sensing*, *11* 8, 982, <https://doi.org/10.3390/rs11080982>
- SCHUSTER, C., SCHMIDT, T., CONRAD, C., KLEINSCHMIT, B. & FÖRSTER, M., (2015), Grassland habitat mapping by intra-annual time series analysis – Comparison of RapidEye and TerraSAR-X satellite data, *International Journal of Applied Earth Observation and Geoinformation*, *34*, 25-34, <https://doi.org/10.1016/j.jag.2014.06.004>
- SCHUYT, K. & BRANDER, L., (2004), Living Waters : The economic values of the world's Wetlands, Récupérée 5 août 2021, à partir de <https://research.vu.nl/en/publications/living-waters-the-economic-values-of-the-worlds-wetlands>
- SHA, Z., BAI, Y., XIE, Y., YU, M. & ZHANG, L., (2008), Using a hybrid fuzzy classifier (HFC) to map typical grassland vegetation in Xilin River Basin, Inner Mongolia, China, *International Journal of Remote Sensing*, *29* 8, 2317-2337, <https://doi.org/10.1080/01431160701408436>
- SILVESTRI, S., MARANI, M. & MARANI, A., (2003), Hyperspectral remote sensing of salt marsh vegetation, morphology and soil topography, *Physics and Chemistry of the Earth, Parts A/B/C*, *28* 1, 15-25, [https://doi.org/10.1016/S1474-7065\(03\)00004-4](https://doi.org/10.1016/S1474-7065(03)00004-4)
- SIMONYAN, K. & ZISSERMAN, A., (2015), Very Deep Convolutional Networks for Large-Scale Image Recognition, *arXiv :1409.1556 [cs]*, Récupérée 7 juin 2021, à partir de <http://arxiv.org/abs/1409.1556>
- SKAGEN, S. K. & KNOPF, F. L., (1994), Migrating Shorebirds and Habitat Dynamics at a Prairie Wetland Complex, *The Wilson Bulletin*, *106* 1, 91-105, Récupérée 7 décembre 2020, à partir de <https://www.jstor.org/stable/4163388>
- SKIDMORE, A. K., PETTORELLI, N., COOPS, N. C., GELLER, G. N., HANSEN, M., LUCAS, R., MÜCHER, C. A., O'CONNOR, B., PAGANINI, M., PEREIRA, H. M., SCHAEPMAN, M. E., TURNER, W., WANG, T. & WEGMANN, M., (2015), Envi-

-
- ronmental science : agree on biodiversity metrics to track from space, *Nature News*, 523 7561, 403, <https://doi.org/10.1038/523403a>
- SMIGAJ, M. & GAULTON, R., (2021), Capturing hedgerow structure and flowering abundance with UAV remote sensing, *Remote Sensing in Ecology and Conservation*, n/a, <https://doi.org/10.1002/rse2.208>
- SMITH, G. M. & MILTON, E. J., (1999), The use of the empirical line method to calibrate remotely sensed data to reflectance, *International Journal of Remote Sensing*, 20 13, 2653-2662, <https://doi.org/10.1080/014311699211994>
- SOILLE, P., BURGER, A., DE MARCHI, D., KEMPENEERS, P., RODRIGUEZ, D., SYRRIS, V. & VASILEV, V., (2018), A versatile data-intensive computing platform for information retrieval from big geospatial data, *Future Generation Computer Systems*, 81, 30-40, <https://doi.org/10.1016/j.future.2017.11.007>
- SOLAZZO, D., SANKEY, J. B., SANKEY, T. T. & MUNSON, S. M., (2018), Mapping and measuring aeolian sand dunes with photogrammetry and LiDAR from unmanned aerial vehicles (UAV) and multispectral satellite imagery on the Paria Plateau, AZ, USA, *Geomorphology*, 319, 174-185, <https://doi.org/10.1016/j.geomorph.2018.07.023>
- SONOGASHIRA, M., SHONAI, M. & IYAMA, M., (2020), High-resolution bathymetry by deep-learning-based image superresolution, *PLOS ONE*, 15 7, e0235487, <https://doi.org/10.1371/journal.pone.0235487>
- SOULÉ, M. E., (1985), What is Conservation Biology? : A new synthetic discipline addresses the dynamics and problems of perturbed species, communities, and ecosystems, *BioScience*, 35 11, 727-734, <https://doi.org/10.2307/1310054>
- SPENCE, C. & MENGISTU, S., (2016), Deployment of an unmanned aerial system to assist in mapping an intermittent stream, *Hydrological Processes*, 30 3, 493-500, <https://doi.org/10.1002/hyp.10597>
- STARK, B., ZHAO, T. & CHEN, Y., (2016), An analysis of the effect of the bidirectional reflectance distribution function on remote sensing imagery accuracy from Small Unmanned Aircraft Systems, *2016 International Conference on Unmanned Aircraft Systems (ICUAS)*, 1342-1350, <https://doi.org/10.1109/ICUAS.2016.7502566>

-
- STEVEN, M. D., (1987), Ground truth An underview †, *International Journal of Remote Sensing*, 8 7, 1033-1038, <https://doi.org/10.1080/01431168708954745>
- ST-ONGE, B. & GRANDIN, S., (2019), Estimating the height and basal area at individual tree and plot levels in canadian subarctic lichen woodlands using stereo WorldView-3 images, *Remote Sensing*, 11 3, 248, <https://doi.org/10.3390/rs11030248>
- STOW, D., NICHOL, C. J., WADE, T., ASSMANN, J. J., SIMPSON, G. & HELFTER, C., (2019), Illumination geometry and flying height influence surface reflectance and NDVI derived from multispectral UAS imagery, *Drones*, 3 3, 55, <https://doi.org/10.3390/drones3030055>
- SU, L., CHOPPING, M. J., RANGO, A., MARTONCHIK, J. V. & PETERS, D. P. C., (2007), Differentiation of semi-arid vegetation types based on multi-angular observations from MISR and MODIS, *International Journal of Remote Sensing*, 28 6, 1419-1424, <https://doi.org/10.1080/01431160601085995>
- SUN, A. Y. & SCANLON, B. R., (2019), How can big data and machine learning benefit environment and water management : a survey of methods, applications, and future directions, *Environmental Research Letters*, 14 7, 073001, <https://doi.org/10.1088/1748-9326/ab1b7d>
- SZANTOI, Z., ESCOBEDO, F., ABD-ELRAHMAN, A., SMITH, S. & PEARLSTINE, L., (2013), Analyzing fine-scale wetland composition using high resolution imagery and texture features, *International Journal of Applied Earth Observation and Geoinformation*, 23, 204-212, <https://doi.org/10.1016/j.jag.2013.01.003>
- SZANTOI, Z., SMITH, S. E., STRONA, G., KOH, L. P. & WICH, S. A., (2017), Mapping orangutan habitat and agricultural areas using Landsat OLI imagery augmented with unmanned aircraft system aerial photography, *International Journal of Remote Sensing*, 38 8, 2231-2245, <https://doi.org/10.1080/01431161.2017.1280638>
- TAN, Z., DI, L., ZHANG, M., GUO, L. & GAO, M., (2019), An enhanced deep convolutional model for spatiotemporal image fusion, *Remote Sensing*, 11 24, 2898, <https://doi.org/10.3390/rs11242898>
- TEILLET, P. M., FEDOSEJEVS, G., THOME, K. J. & BARKER, J. L., (2007), Impacts of spectral band difference effects on radiometric cross-calibration between satellite

-
- sensors in the solar-reflective spectral domain, *Remote Sensing of Environment*, 1103, 393-409, <https://doi.org/10.1016/j.rse.2007.03.003>
- TILMAN, D., CLARK, M., WILLIAMS, D. R., KIMMEL, K., POLASKY, S. & PACKER, C., (2017), Future threats to biodiversity and pathways to their prevention, *Nature*, 546 7656, 73, <https://doi.org/10.1038/nature22900>
- TODD, M. J., MUNEEPEERAKUL, R., PUMO, D., AZAELE, S., MIRALLES-WILHELM, F., RINALDO, A. & RODRIGUEZ-ITURBE, I., (2010), Hydrological drivers of wetland vegetation community distribution within Everglades National Park, Florida, *Advances in Water Resources*, 33 10, 1279-1289, <https://doi.org/10.1016/j.advwatres.2010.04.003>
- TOMASELLI, V., ADAMO, M., VERONICO, G., SCIANDRELLO, S., TARANTINO, C., DIMOPOULOS, P., MEDAGLI, P., NAGENDRA, H. & BLONDA, P., (2017), Definition and application of expert knowledge on vegetation pattern, phenology, and seasonality for habitat mapping, as exemplified in a Mediterranean coastal site, *Plant Biosystems - An International Journal Dealing with all Aspects of Plant Biology*, 151 5, 887-899, <https://doi.org/10.1080/11263504.2016.1231143>
- TOMPKINS, S., MUSTARD, J. F., PIETERS, C. M. & FORSYTH, D. W., (1997), Optimization of endmembers for spectral mixture analysis, *Remote Sensing of Environment*, 59 3, 472-489, [https://doi.org/10.1016/S0034-4257\(96\)00122-8](https://doi.org/10.1016/S0034-4257(96)00122-8)
- TRANSON, J., D'ANDRIMONT, R., MAUGNARD, A. & DEFOURNY, P., (2018), Survey of hyperspectral earth observation applications from space in the sentinel-2 context, *Remote Sensing*, 10 2, 157, <https://doi.org/10.3390/rs10020157>
- TRIGG, M. A., BATES, P. D., WILSON, M. D., SCHUMANN, G. & BAUGH, C., (2012), Floodplain channel morphology and networks of the middle amazon river, *Water Resources Research*, 48 10, <https://doi.org/10.1029/2012WR011888>
- TSCHUDI, M. A., MASLANIK, J. A. & PEROVICH, D. K., (2008), Derivation of melt pond coverage on Arctic sea ice using MODIS observations, *Remote Sensing of Environment*, 112 5, 2605-2614, <https://doi.org/10.1016/j.rse.2007.12.009>
- TUIA, D., PERSELLO, C. & BRUZZONE, L., (2016), Domain Adaptation for the Classification of Remote Sensing Data : An Overview of Recent Advances, *IEEE Geoscience*

and *Remote Sensing Magazine*, 42, 41-57, <https://doi.org/10.1109/MGRS.2016.2548504>

- TUXEN, K. & KELLY, M., (2008), Multi-scale functional mapping of tidal marsh vegetation using object-based image analysis, In T. BLASCHKE, S. LANG & G. J. HAY (Éd.), *Object-based image analysis : spatial concepts for knowledge-driven remote sensing applications* (p. 415-442), Springer Berlin Heidelberg, https://doi.org/10.1007/978-3-540-77058-9_23
- VIHERVAARA, P., AUVINEN, A.-P., MONONEN, L., TÖRMÄ, M., AHLROTH, P., ANTILA, S., BÖTTCHER, K., FORSIUS, M., HEINO, J., HELIÖLÄ, J., KOSKELAINEN, M., KUUSSAARI, M., MEISSNER, K., OJALA, O., TUOMINEN, S., VIITASALO, M. & VIRKKALA, R., (2017), How Essential Biodiversity Variables and remote sensing can help national biodiversity monitoring, *Global Ecology and Conservation*, 10, 43-59, <https://doi.org/10.1016/j.gecco.2017.01.007>
- VIOLLE, C., BONIS, A., PLANTEGENEST, M., CUDENNEC, C., DAMGAARD, C., MARION, B., CŒUR, D. L. & BOUZILLÉ, J.-B., (2011), Plant functional traits capture species richness variations along a flooding gradient, *Oikos*, 1203, 389-398, <https://doi.org/10.1111/j.1600-0706.2010.18525.x>
- VIOLLE, C., CUDENNEC, C., PLANTEGENEST, M., DAMGAARD, C., LE COEUR, D., BOUZILLE, J.-B. & BONIS, A., (2005), Indirect assessment of flooding duration as a driving factor of plant diversity in wet grasslands, *VIIth International Association for Hydrological Sciences Scientific Assembly*, 303, Récupérée 14 avril 2021, à partir de <https://hal.archives-ouvertes.fr/hal-00015294>
- WALKER, L. R. & SMITH, S. D., (1997), Impacts of invasive plants on community and ecosystem properties, In J. O. LUKE & J. W. THIERET (Éd.), *Assessment and management of plant invasions* (p. 69-86), Springer New York, https://doi.org/10.1007/978-1-4612-1926-2_7
- WANG, C., MENENTI, M., STOLL, M.-P., BELLUCO, E. & MARANI, M., (2007), Mapping mixed vegetation communities in salt marshes using airborne spectral data, *Remote Sensing of Environment*, 1074, 559-570, <https://doi.org/10.1016/j.rse.2006.10.007>
- WANG, L., DRONOVA, I., GONG, P., YANG, W., LI, Y. & LIU, Q., (2012), A new time series vegetation–water index of phenological–hydrological trait across species and

-
- functional types for poyang lake wetland ecosystem, *Remote Sensing of Environment*, 125, 49-63, <https://doi.org/10.1016/j.rse.2012.07.003>
- WANG, N., SUOMALAINEN, J., BARTHOLOMEUS, H., KOOISTRA, L., MASILIŪNAS, D. & CLEVERS, J. G. P. W., (2021), Diurnal variation of sun-induced chlorophyll fluorescence of agricultural crops observed from a point-based spectrometer on a UAV, *International Journal of Applied Earth Observation and Geoinformation*, 96, 102276, <https://doi.org/10.1016/j.jag.2020.102276>
- WANG, R. & GAMON, J. A., (2019), Remote sensing of terrestrial plant biodiversity, *Remote Sensing of Environment*, 231, 111218, <https://doi.org/10.1016/j.rse.2019.111218>
- WANG, R., ZHANG, S., PU, L., YANG, J., YANG, C., CHEN, J., GUAN, C., WANG, Q., CHEN, D., FU, B. & SANG, X., (2016), Gully erosion mapping and monitoring at multiple scales based on multi-source remote sensing data of the sancha river catchment, northeast china, *ISPRS International Journal of Geo-Information*, 5 11, 200, <https://doi.org/10.3390/ijgi5110200>
- WILKINSON, M. D., DUMONTIER, M., AALBERSBERG, I. J., APPLETON, G., AXTON, M., BAAK, A., BLOMBERG, N., BOITEN, J.-W., da SILVA SANTOS, L. B., BOURNE, P. E., BOUWMAN, J., BROOKES, A. J., CLARK, T., CROSAS, M., DILLO, I., DUMON, O., EDMUNDS, S., EVELO, C. T., FINKERS, R., ... MONS, B., (2016), The FAIR guiding principles for scientific data management and stewardship, *Scientific Data*, 3 1, 160018, <https://doi.org/10.1038/sdata.2016.18>
- WOODCOCK, C. E. & GOPAL, S., (2000), Fuzzy set theory and thematic maps : accuracy assessment and area estimation, *International Journal of Geographical Information Science*, 14 2, 153-172, <https://doi.org/10.1080/136588100240895>
- WU, Q., LANE, C. R., LI, X., ZHAO, K., ZHOU, Y., CLINTON, N., DEVRIES, B., GOLDEN, H. E. & LANG, M. W., (2019), Integrating LiDAR data and multi-temporal aerial imagery to map wetland inundation dynamics using google earth engine, *Remote Sensing of Environment*, 228, 1-13, <https://doi.org/10.1016/j.rse.2019.04.015>
- XIA, H., ZHAO, W., LI, A., BIAN, J. & ZHANG, Z., (2017), Subpixel inundation mapping using landsat-8 OLI and UAV data for a wetland region on the zoige plateau, china, *Remote Sensing*, 9 1, 31, <https://doi.org/10.3390/rs9010031>

-
- XIE, Q., DASH, J., HUANG, W., PENG, D., QIN, Q., MORTIMER, H., CASA, R., PIGNATTI, S., LANEVE, G., PASCUCCI, S., DONG, Y. & YE, H., (2018), Vegetation Indices Combining the Red and Red-Edge Spectral Information for Leaf Area Index Retrieval, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11 5, 1482-1493, <https://doi.org/10.1109/JSTARS.2018.2813281>
- YAN, K., BALDASSARRE, G. D., SOLOMATINE, D. P. & SCHUMANN, G. J.-P., (2015), A review of low-cost space-borne data for flood modelling : topography, flood extent and water level, *Hydrological Processes*, 29 15, 3368-3387, <https://doi.org/10.1002/hyp.10449>
- YANG, J. & HUANG, T., (2011), Image Super-Resolution : Historical Overview and Future Challenges. *Super-Resolution Imaging*, CRC Press.
- YANG, W., ZHANG, X., TIAN, Y., WANG, W. & XUE, J.-H., (2019), Deep Learning for Single Image Super-Resolution : A Brief Review, *IEEE Transactions on Multimedia*, 21 12, 3106-3121, <https://doi.org/10.1109/TMM.2019.2919431>
- YANG, X., (2007), Integrated use of remote sensing and geographic information systems in riparian vegetation delineation and mapping, *International Journal of Remote Sensing*, 28 2, 353-370, <https://doi.org/10.1080/01431160600726763>
- YUE, L., SHEN, H., LI, J., YUAN, Q., ZHANG, H. & ZHANG, L., (2016), Image super-resolution : The techniques, applications, and future, *Signal Processing*, 128, 389-408, <https://doi.org/10.1016/j.sigpro.2016.05.002>
- ZHANG, J., (2010), Multi-source remote sensing data fusion : status and trends, *International Journal of Image and Data Fusion*, 1 1, 5-24, <https://doi.org/10.1080/19479830903561035>
- ZHANG, J., OKIN, G. S. & ZHOU, B., (2019), Assimilating optical satellite remote sensing images and field data to predict surface indicators in the western u.s. : assessing error in satellite predictions based on large geographical datasets with the use of machine learning, *Remote Sensing of Environment*, 233, 111382, <https://doi.org/10.1016/j.rse.2019.111382>
- ZHANG, S., ZHAO, G., LANG, K., SU, B., CHEN, X., XI, X. & ZHANG, H., (2019), Integrated satellite, unmanned aerial vehicle (UAV) and ground inversion of the SPAD of

-
- winter wheat in the reviving stage, *Sensors*, *19* 7, 1485, <https://doi.org/10.3390/s19071485>
- ZHAO, W. & DU, S., (2016), Learning multiscale and deep representations for classifying remotely sensed imagery, *ISPRS Journal of Photogrammetry and Remote Sensing*, *113*, 155-165, <https://doi.org/10.1016/j.isprsjprs.2016.01.004>
- ZHAO, Y., CHEN, N., CHEN, J. & HU, C., (2018), Automatic extraction of yardangs using Landsat 8 and UAV images : A case study in the Qaidam Basin, China, *Aeolian Research*, *33*, 53-61, <https://doi.org/10.1016/j.aeolia.2018.05.002>
- ZHENFENG, S. & CAI, J., (2018), Remote Sensing Image Fusion With Deep Convolutional Neural Network, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, *11* 5, 1656-1669, <https://doi.org/10.1109/JSTARS.2018.2805923>
- ZHU, F., (2017), Hyperspectral Unmixing : Ground Truth Labeling, Datasets, Benchmark Performances and Survey, *arXiv :1708.05125 [cs]*, Récupérée 11 août 2021, à partir de <http://arxiv.org/abs/1708.05125>
- ZHU, X., CAI, F., TIAN, J. & WILLIAMS, T. K.-A., (2018), Spatiotemporal fusion of multisource remote sensing data : literature survey, taxonomy, principles, applications, and future directions, *Remote Sensing*, *10* 4, 527, <https://doi.org/10.3390/rs10040527>
- ZLINSZKY, A., SCHROIFF, A., KANIA, A., DEÁK, B., MÜCKE, W., VÁRI, Á., SZÉKELY, B. & PFEIFER, N., (2014), Categorizing grassland vegetation with full-waveform airborne laser scanning : a feasibility study for detecting natura 2000 habitat types, *Remote Sensing*, *6* 9, 8056-8087, <https://doi.org/10.3390/rs6098056>
- ŻMIHORSKI, M., PÄRT, T., GUSTAFSON, T. & BERG, Å., (2016), Effects of water level and grassland management on alpha and beta diversity of birds in restored wetlands, *Journal of Applied Ecology*, *53* 2, 587-595, <https://doi.org/10.1111/1365-2664.12588>
- ZWENZNER, H. & VOIGT, S., (2009), Improved estimation of flood parameters by combining space based SAR data with very high resolution digital elevation data, *Hydrology and Earth System Sciences*, *13* 5, 567-576, <https://doi.org/10.5194/hess-13-567-2009>

Titre : Les synergies de la télédétection optique par drone et satellite

Mot clés : Télédétection multi-source, Démélangeage spectral, Fusion de données, Cartographie d'habitats, Dynamiques d'inondation

Résumé : La technologie drone est une nouvelle source de données de télédétection qui offre de nouvelles perspectives aux sciences de l'observation de la Terre. Elle permet un nouveau régime d'observation flexible et à très haute résolution spatiale qui apparaît comme complémentaire à celui des systèmes satellitaires et favorise l'application du changement d'échelle. Cette thèse a pour objectif d'évaluer l'apport des complémentarités entre drone et satellite pour le suivi des prairies humides - des milieux à fort enjeux écologiques et économiques. Pour cela, les principales synergies entre les données drone et satellite ont été identifiées dans la littérature scientifique. Un jeu de données multi-sources et multi-échelles alliant observations drone, sa-

tellitaires et *in-situ* a été constitué sur le site de la réserve régionale du marais de Sougéal, France. Ainsi, deux synergies adaptées au changement d'échelle - la "calibration de modèle" et la "fusion de données" - ont été appliquées à la cartographie de la structure des prairies humides - la distribution des communautés végétales et les dynamiques d'inondation. Les résultats montrent que le drone apporte une information sur la structure spatiale fine qui est utile pour dépasser les effets de pixels mixtes présents dans les données satellitaires. Par ailleurs, ces synergies facilitent la réalisation de représentations cartographiques qui intègrent la nature graduelle des milieux de prairies humides.

Title: UAV and satellite synergies for optical remote sensing

Keywords: Multi-source remote sensing, Spectral unmixing, Data fusion, Habitats mapping, Flood dynamics

Abstract: Unmanned aerial vehicles (UAV) are a new source of remote sensing data that offers new perspectives to Earth observation sciences. It allows a new flexible and very high spatial resolution observation regime that appears to be complementary to that of satellite systems and supports the application of the downscaling. The objective of this thesis is to evaluate the contribution of complementarities between UAV and satellite for the monitoring of wet grasslands - environments with high ecological and economic stakes. To this end, the main synergies between drone and satellite data have been identified in the scientific literature. A multi-source and multi-

scale dataset combining drone, satellite and *in-situ* observations has been established on the site of the Sougéal marsh regional reserve, France. Thus, two synergies adapted to the downscaling - "model calibration" and "data fusion" - have been applied to the mapping of wet grassland structure - plant community distribution and flooding dynamics. The results show that the UAV provides fine spatial structure information that is useful to overcome the mixed pixel effects present in satellite data. Furthermore, these synergies facilitate the production of map representations that take into account the gradual character of wet grassland environments.