
Caractérisation de la dynamique de compétition entre froment d'hiver et adventices en essai agroécologique par imagerie à deux échelles

Auteur : Arquin, Neo

Promoteur(s) : Mercatoris, Benoît

Faculté : Gembloux Agro-Bio Tech (GxABT)

Diplôme : Master en bioingénieur : sciences et technologies de l'environnement, à finalité spécialisée

Année académique : 2023-2024

URI/URL : <http://hdl.handle.net/2268.2/21098>

Avertissement à l'attention des usagers :

Tous les documents placés en accès ouvert sur le site le site MatheO sont protégés par le droit d'auteur. Conformément aux principes énoncés par la "Budapest Open Access Initiative"(BOAI, 2002), l'utilisateur du site peut lire, télécharger, copier, transmettre, imprimer, chercher ou faire un lien vers le texte intégral de ces documents, les disséquer pour les indexer, s'en servir de données pour un logiciel, ou s'en servir à toute autre fin légale (ou prévue par la réglementation relative au droit d'auteur). Toute utilisation du document à des fins commerciales est strictement interdite.

Par ailleurs, l'utilisateur s'engage à respecter les droits moraux de l'auteur, principalement le droit à l'intégrité de l'oeuvre et le droit de paternité et ce dans toute utilisation que l'utilisateur entreprend. Ainsi, à titre d'exemple, lorsqu'il reproduira un document par extrait ou dans son intégralité, l'utilisateur citera de manière complète les sources telles que mentionnées ci-dessus. Toute utilisation non explicitement autorisée ci-avant (telle que par exemple, la modification du document ou son résumé) nécessite l'autorisation préalable et expresse des auteurs ou de leurs ayants droit.

**CARACTÉRISATION DE LA DYNAMIQUE DE
COMPÉTITION ENTRE FROMENT D'HIVER ET
ADVENTICES EN ESSAI AGROÉCOLOGIQUE PAR
IMAGERIE À DEUX ÉCHELLES**

ARQUIN NEO

**TRAVAIL DE FIN D'ÉTUDES PRÉSENTÉ EN VUE DE L'OBTENTION DU DIPLÔME DE MASTER
BIOINGÉNIEUR EN SCIENCES ET TECHNOLOGIES DE L'ENVIRONNEMENT**

ANNÉE ACADÉMIQUE 2023-2024

PROMOTEUR : PR BENOIT MERCATORIS

Toute reproduction du présent document, par quelque procédé que ce soit, ne peut être réalisée qu'avec l'autorisation de l'auteur et de l'autorité académique de Gembloux Agro-Bio Tech.

Le présent document n'engage que son auteur.

**CARACTÉRISATION DE LA DYNAMIQUE DE
COMPÉTITION ENTRE FROMENT D'HIVER ET
ADVENTICES EN ESSAI AGROÉCOLOGIQUE PAR
IMAGERIE À DEUX ÉCHELLES**

ARQUIN NEO

**TRAVAIL DE FIN D'ÉTUDES PRÉSENTÉ EN VUE DE L'OBTENTION DU DIPLÔME DE MASTER
BIOINGÉNIEUR EN SCIENCES ET TECHNOLOGIES DE L'ENVIRONNEMENT**

ANNÉE ACADÉMIQUE 2023-2024

PROMOTEUR : PR BENOIT MERCATORIS

Remerciements

Ce travail a été réalisé au sein de l'axe BioDyne avec l'appui du plateau mécatronique. Il s'intègre pleinement dans le projet EcoFoodSystem mené par la CARE AgricultureIsLife.

Je tiens à remercier le promoteur de ce travail de fin d'études, le Professeur Benoit Mercatoris, pour son encadrement tout au long du quadrimestre, mais aussi pour son écoute attentive lors de mes périodes de questionnement sur la suite de mon parcours professionnel. Je remercie également Messieurs Arnaud Monty, Benjamin Dumont et Jean-François Bastin d'avoir accepté de faire partie de mon jury.

Je souhaite également remercier Jesse, technicien sur le plateau mécatronique, sans qui les vols de drone auraient été impossibles. Merci pour ton écoute et ta disponibilité lors des problèmes rencontrés. Je salue également toutes les personnes que j'ai croisées au Génie Rural pour les quelques morceaux de tarte et parties de ping-pong partagés. Merci aussi à Antoine, stagiaire sur le même projet que moi, pour les nombreux coups de pouce apportés lors des sorties terrain.

Je remercie les personnes présentes sur le projet EcoFoodSystem, en particulier Nina, Celia et Tom, pour les moments passés au champ ainsi que pour les réponses apportées à mes questions concernant le projet.

Merci à Adrien Michez, qui a pris le temps de résoudre avec moi des problèmes concernant les images acquises par drone. Merci aussi à Julien pour les quelques échanges sur toute l'acquisition des images drone ainsi que leur traitement.

Je remercie toutes les personnes que j'ai rencontrées ces cinq dernières années et qui m'ont permis de m'épanouir dans nos vieux murs de Gembloux. J'embrasse chaleureusement tous les Tfistes de cette année, qui ont rendu ce dernier quadrimestre de nos études exceptionnel, et vous souhaite à tous bon vent. Tfistes, todi hors piste POUM!

Parmi ces Tfistes, j'aimerais remercier en particulier Joran et Aubin pour les nombreux projets réalisés ensemble tout au long de notre master et qui m'ont permis d'évoluer et d'apprendre à aller jusqu'au bout d'un projet. Aubin nous ayant laissés seuls au GR, je remercie Joran pour les innombrables heures passées dans le même bureau ces derniers mois. Merci pour ta compagnie mais aussi pour tes idées et tes conseils toujours appréciables qui m'ont permis plus d'une fois d'avancer sur mon travail.

Merci à celle avec qui j'ai partagé mon quotidien ces trois dernières années. Merci pour tous ces moments de bonheur, de joie, de rires, d'échanges et d'autres émotions plus complexes les unes que les autres. Merci Pauline d'être qui tu es et d'être là.

Enfin, je remercie du fond du cœur tous les membres de ma famille qui m'ont toujours soutenu et encouragé, et en particulier Sandrine, ma maman, sans qui je ne serais sûrement pas arrivé là où j'en suis aujourd'hui. Un immense merci.

Résumé

La compréhension des dynamiques de compétition entre les cultures et les adventices est cruciale pour développer des systèmes agronomiques durables. Le phénotypage par imagerie offre un moyen non-destructif de caractériser ces interactions. Dans le cadre de ce travail, vingt quadrats ont été suivis durant six semaines à l'aide d'images terrestres RVB et aériennes multispectrales. Un indicateur de pression adventice a été développé, égal au rapport des fractions de couvert végétal des adventices et du froment. Pour ce faire, douze variables de couleur et de texture ont été extraites de superpixels, calculés sur les images terrestres à l'aide d'un groupement itératif linéaire simple. Deux modèles de différenciation culture / adventices ont ensuite pu être entraînés, suggérant une meilleure identification après la floraison des adventices. La pression sur le froment a présenté deux périodes d'augmentation : lors de la première, les adventices s'étendaient sur le plan horizontal mais aussi en hauteur ; lors de la seconde, leurs fleurs se développaient ce qui leur a permis de prendre de plus en plus d'espace. Différents indices de végétation ont été extraits des images aériennes et comparés à l'indicateur de pression issu des images terrestres. Aucun d'entre eux ne s'est avéré efficace pour estimer la pression au sol. Cependant, une régression linéaire multiple alimentée par les valeurs de réflectances dans plusieurs bandes spectrales a suggéré que la pression adventice pouvait être prédite à partir des images aériennes. La principale perspective de ce travail est l'acquisition d'informations supplémentaires, notamment à l'aide de capteurs 3D et hyperspectraux.

Mots-clés : pression adventice ; compétition culture/adventices ; phénotypage au sol ; télédétection ; superpixels ; apprentissage automatique ; indice de végétation

Abstract

Understanding the dynamics of competition between crops and weeds is crucial to developing sustainable agronomic systems. Imaging phenotyping offers a non-destructive means of characterizing these interactions. Twenty quadrats were monitored over a six-week period using RGB terrestrial and multispectral aerial imagery. A weed pressure indicator was developed, equal to the ratio of the vegetation cover fractions of weeds and wheat. To this end, twelve color and texture variables were extracted from superpixels, calculated on terrestrial images using a simple linear iterative clustering. Two crop/weed differentiation models were then trained, suggesting better identification after weed flowering. The pressure on wheat showed two periods of increase: during the first, weeds expanded both horizontally and in height; during the second, their flowers developed, enabling them to take up more and more space. Various vegetation indices were extracted from aerial images and compared with the pressure indicator derived from terrestrial images. None of them proved effective in estimating ground pressure. However, multiple linear regression fed by reflectance values in several spectral bands suggested that weed pressure could be predicted from aerial images. The main perspective of this work is the acquisition of additional information, notably using 3D and hyperspectral sensors.

Keywords: weed pressure; crop/weed competition; ground-based phenotyping; remote sensing; superpixels; machine learning; vegetation index

Table des matières

Table des figures	v
Liste des tableaux	vii
Liste des abréviations	viii
1 Introduction	1
1.1 Contexte	1
1.1.1 Froment d’hiver et adventices	1
1.1.2 Gestion des adventices	2
1.1.3 EcoFoodSystem	2
1.2 État de l’art	3
1.2.1 Évaluation de la pression des adventices	3
1.2.2 Échelles spatio-temporelles	3
1.2.3 RVB	5
1.2.4 3D	5
1.2.5 Multispectral	6
1.2.6 Hyperspectral	6
1.3 Objectifs	6
2 Matériels et méthodes	7
2.1 Site d’étude, données de référence et fréquence d’acquisition	7
2.2 Images terrestres	10
2.2.1 Acquisition	10
2.2.2 Récupération de la zone d’intérêt	10
2.2.3 Segmentation sol / végétation	12
Rappel théorique : Groupement Itératif Linéaire Simple	12
2.2.4 Différenciation culture / adventices	14
Rappel théorique : Matrice de co-occurrence des niveaux de gris	16
2.2.5 Calcul de la pression adventice	18
2.2.6 Comparaison aux données de terrain	18
2.2.7 Caractérisation de la dynamique de compétition froment / adventices	18
2.3 Images aériennes	19
2.3.1 Acquisition	19
2.3.2 Génération des orthomosaïques	19
2.3.3 Extraction des données dans les quadrats	21
2.3.4 Comparaison aux images terrestres	21
2.3.5 Calcul des indices de végétation	22
2.3.6 Prédiction de la pression adventice	22
3 Résultats	23
3.1 Images terrestres	23
3.1.1 Segmentation sol / végétation	23
3.1.2 Différenciation culture / adventices	24
3.1.3 Comparaison aux données terrain	31
3.1.4 Caractérisation de la dynamique de compétition froment / adventices	32

3.2	Images aériennes	37
3.2.1	Comparaison des tailles des quadrats extraits	37
3.2.2	Comparaison aux images terrestres	38
3.2.3	Calcul des indices de végétation	39
3.2.4	Prédiction de la pression adventice	44
4	Discussion	45
4.1	Limites de l'étude	45
4.1.1	Acquisition des images	45
4.1.2	Quantité de données	47
4.1.3	Modèles de classification	48
4.2	Discussion des résultats	49
4.2.1	Différenciation culture / adventices	49
4.2.2	Comparaison aux données terrain	50
4.2.3	Caractérisation de la dynamique de compétition froment / adventices	51
4.2.4	Comparaison des tailles des quadrats extraits	52
4.2.5	Comparaison aux images terrestres	52
4.2.6	Calcul des indices de végétation	53
4.2.7	Prédiction de la pression adventice	53
4.3	Perspectives	53
4.3.1	Acquisition des images	53
4.3.2	Quantité de données	54
4.3.3	Modèles de classification	55
5	Conclusions	56
6	Bibliographie	57

Table des figures

1	Rotations mises en place sur le projet EcoFoodSystem.	7
2	Localisation et organisation des parcelles sur le projet EcoFoodSystem.	7
3	Schématisme d'une parcelle sur le projet EcoFoodSystem.	8
4	Cadre en bois et piquets en plastique utilisés afin de marquer les quadrats.	8
5	Tuteur en bambou et cylindre en mousse utilisés afin de mieux repérer les quadrats.	9
6	Perche en profilés aluminium utilisée pour l'acquisition des images terrestres.	10
7	Exemple d'image terrestre acquise.	11
8	Schéma du système d'acquisition des images terrestres.	11
9	Comparaison d'un algorithme classique de regroupement de k-moyennes avec l'algorithme SLIC.	12
10	Illustration du processus d'annotation des superpixels pour la segmentation sol / végétation.	13
11	Segmentation sol / végétation.	14
12	Illustration du processus d'annotation des superpixels pour la différenciation culture / adventices.	15
13	Exemple d'une image en nuances de gris et des valeurs de niveau de gris correspondant à chaque pixel.	16
14	Différenciation froment / adventices.	17
15	Dessin du plan de vol et localisation des quadrats et des cibles de contrôle.	19
16	Exemple d'orthomosaïque reconstruite et rognée selon les contours du champ.	20
17	Exemple de tampon de 50 × 50 cm.	21
18	Résultats des régressions linéaires réalisées pour comparer la biomasse de chaque espèce dans chaque quadrat à sa FCV correspondante.	31
19	Résultat de la régression linéaire réalisée pour comparer la PA_{image} et la $PA_{biomasse}$	32
20	Évolution des FCV du froment et des adventices et de la pression adventice sur les quadrats de la parcelle 1 au cours de la saison.	33
21	Évolution des FCV du froment et des adventices et de la pression adventice sur les quadrats de la parcelle 2 au cours de la saison.	34
22	Évolution des FCV du froment et des adventices et de la pression adventice sur les quadrats de la parcelle 3 au cours de la saison.	35
23	Évolution des FCV du froment et des adventices et de la pression adventice sur les quadrats de la parcelle 4 au cours de la saison.	36
24	Comparaison des réflectances moyennes extraites pour chaque bande des quadrats de 50 × 50 cm avec celles extraites des quadrats de 100 × 100 cm.	37
25	Comparaison des valeurs de réflectances mesurées sur les images au sol avec celles mesurées sur les images aériennes pour les canaux RVB.	38
26	Résultat de la régression linéaire réalisée pour comparer la PA_{image} au NDVI extrait des quadrats de 50 × 50 cm.	39
27	Résultat de la régression linéaire réalisée pour comparer la PA_{image} au GNDVI extrait des quadrats de 50 × 50 cm.	40
28	Résultat de la régression linéaire réalisée pour comparer la PA_{image} au RVI extrait des quadrats de 50 × 50 cm.	40
29	Résultat de la régression linéaire réalisée pour comparer la PA_{image} au DVI extrait des quadrats de 50 × 50 cm.	41
30	Résultat de la régression linéaire réalisée pour comparer la PA_{image} au VDVI extrait des quadrats de 50 × 50 cm.	41

TABLE DES FIGURES

31	Résultat de la régression linéaire réalisée pour comparer la PA_{image} au NDVI extrait des quadrats de 100×100 cm.	42
32	Résultat de la régression linéaire réalisée pour comparer la PA_{image} au GNDVI extrait des quadrats de 100×100 cm.	42
33	Résultat de la régression linéaire réalisée pour comparer la PA_{image} au RVI extrait des quadrats de 100×100 cm.	43
34	Résultat de la régression linéaire réalisée pour comparer la PA_{image} au DVI extrait des quadrats de 100×100 cm.	43
35	Résultat de la régression linéaire réalisée pour comparer la PA_{image} au VDVI extrait des quadrats de 100×100 cm.	44
36	Comparaison de la hauteur de végétation de deux quadrats à la même date.	46
37	Illustration du décalage possible entre les images terrestres et aériennes.	47
38	Illustration de l'évolution des FCV du froment et des adventices au cours de la saison. . .	51
39	Illustration d'une erreur possible due aux cibles placées trop au bord du plan de vol. . .	54
40	Identification de différentes adventices sur les orthomosaïques.	55

Liste des tableaux

1	Résumé des dates d'acquisition des images terrestres et aériennes.	9
2	Matrice de confusion pour le jeu de validation de la segmentation sol / végétation pour le 08/05/2024.	23
3	Matrice de confusion pour le jeu de validation de la segmentation sol / végétation pour le 14/05/2024.	23
4	Matrice de confusion pour le jeu de validation de la segmentation sol / végétation pour le 23/05/2024.	23
5	Matrice de confusion pour le jeu de validation de la segmentation sol / végétation pour le 30/05/2024.	23
6	Matrice de confusion pour le jeu de validation de la segmentation sol / végétation pour le 06/06/2024.	24
7	Matrice de confusion pour le jeu de validation de la segmentation sol / végétation pour le 13/06/2024.	24
8	Matrices de confusion pour le jeu de validation de la différenciation culture / adventices pour le modèle pré-floraison avec les 6 variables sélectionnées par RFE : R, B, T, S, V, Homogénéité.	24
9	Matrices de confusion pour le jeu de validation de la différenciation culture / adventices pour le modèle pré-floraison avec les 8 variables sélectionnées par RFE : R, V, B, T, S, V, Homogénéité, Énergie.	25
10	Matrices de confusion pour le jeu de validation de la différenciation culture / adventices pour le modèle pré-floraison avec les 10 variables sélectionnées par RFE : R, V, B, T, S, V, Homogénéité, Énergie, Corrélation, ASM.	25
11	Matrices de confusion pour le jeu de validation de la différenciation culture / adventices pour le modèle pré-floraison avec les 12 variables : R, V, B, T, S, V, Homogénéité, Énergie, Corrélation, ASM, Dissimilarité, Contraste.	26
12	Matrices de confusion pour le jeu de validation de la différenciation culture / adventices pour le modèle post-floraison avec les 6 variables sélectionnées par RFE : R, V, T, S, V, Homogénéité.	27
13	Matrices de confusion pour le jeu de validation de la différenciation culture / adventices pour le modèle post-floraison avec les 8 variables sélectionnées par RFE : R, V, B, T, S, V, Homogénéité, Énergie.	28
14	Matrices de confusion pour le jeu de validation de la différenciation culture / adventices pour le modèle post-floraison avec les 10 variables sélectionnées par RFE : R, V, B, T, S, V, Homogénéité, Énergie, Corrélation, ASM.	29
15	Matrices de confusion pour le jeu de validation de la différenciation culture / adventices pour le modèle post-floraison avec les 12 variables sélectionnées par RFE : R, V, B, T, S, V, Homogénéité, Énergie, Corrélation, ASM, Dissimilarité, Contraste.	30
16	Résultats des ANOVA réalisées pour comparer les valeurs moyennes extraites pour chaque canal des deux tailles de quadrats.	37
17	Résultat des RLM réalisées pour prédire la PA_{image} dans chaque quadrat à partir des données extraites des rasters multibandes.	44

Liste des abréviations

Abréviation	Définition
ANOVA	Analyse de la variance
FCV	Fraction de couvert végétal
GLCM	Matrice de co-occurrence des niveaux de gris
HFOV	Champ de vision horizontal
IV	Indice de végétation
NDVI	Indice de végétation par différence normalisée
NIR	Proche infrarouge
NN	Réseau neuronal
PA	Pression de la flore adventice
RFE	Élimination récursive des variables
RLM	Régression linéaire multiple
RVB	Rouge - vert - bleu
SLIC	Groupement itératif linéaire simple
SP	Superpixel
SVM	Séparateur à vastes marges
TSV	Teinte - saturation - valeur

1 Introduction

1.1 Contexte

1.1.1 Froment d'hiver et adventices

Le froment d'hiver, *Triticum aestivum* L., est défini par la classification APG III comme une plante monocotylédone de la famille des *Poaceae*. Domestiqué il y a environ 10.000 ans dans la région du Croissant fertile, sa culture s'est rapidement étendue à d'autres régions du monde (Feldman, 2001). De nos jours, le froment d'hiver est cultivé sur plus de 220 millions d'hectares, pour une production atteignant les 788,5 millions de tonnes en 2023 (FAO, 2024), faisant de lui la deuxième céréale la plus cultivée au monde. Ainsi, 76% de cette production servent pour l'alimentation humaine (Couturier & Doublet, 2022), fournissant 20% des apports caloriques dans le monde et jusqu'à 50% dans certaines régions (Shewry, 2021). Il représente une source importante de glucides, mais également de protéines, de fibres, de vitamines et de minéraux (Shewry & Hey, 2015).

Les adventices sont définies comme les espèces végétales qui se développent dans une culture sans avoir été semées par l'homme (Chauvel et al., 2018). Ce sont des plantes généralement caractérisées par un cycle de vie rapide et un haut taux de reproduction (Kuester et al., 2014). Les adventices sont la source majeure de pertes de rendement des cultures, avec une diminution de production potentielle de 23% pour le froment (Oerke, 2006). Ces pertes sont dues à différents types de nuisibilités causées par les adventices sur les cultures (Caussanel, 1989).

L'impact principal des adventices sur le froment est la compétition. De nombreuses définitions de la compétition au sein de communautés de plantes existent (Zimdahl, 2004), mais elle est souvent expliquée comme « *les effets négatifs sur le développement de la plante dus à la présence de voisins qui réduisent la disponibilité des ressources* » (Keddy & Cahill, 2012). Les adventices entrent donc en concurrence avec les cultures pour différentes ressources telles que la lumière, les nutriments, l'eau ou encore l'espace (Chhokar et al., 2012). Par exemple, elles sont souvent plus compétitives pour les nutriments que le froment (Jabran et al., 2017), limitant la croissance de ce dernier.

D'autres perturbations causées par les adventices proviennent de l'allélopathie, définie comme « *l'ensemble des interactions entre plantes via la production de composés secondaires relâchés dans la rhizosphère* » (Weston & Duke, 2003). Ces interférences peuvent être bénéfiques pour les cultures, mais les impacts négatifs de ces produits allélochimiques sont difficiles à réduire (Qasem & Foy, 2001). Ils peuvent être la source de toxicité, réduisant ainsi la croissance des cultures et donc le rendement final (Ahmed & Wardle, 1994), ou perturber leur germination par divers mécanismes (Rice, 1984).

De nombreuses adventices s'adaptent à un large éventail de conditions climatiques et édaphiques (Zimdahl, 2018). Elles sont en effet plus souvent caractérisées par des traits de tolérance au stress que les cultures (Kuester et al., 2014). Cette élasticité morphologique et physiologique, expliquée par leur diversité génétique (Sharma et al., 2021), a permis aux adventices de persister malgré les nombreuses tentatives de l'homme de s'en débarrasser.

Enfin, les adventices sont considérées comme des vecteurs et refuges de pathogènes (Wisler & Norris, 2005). Elles sont une ressource primaire pour de nombreux insectes phytophages (Capinera, 2005) et servent d'hôtes pour des champignons, des bactéries et des virus (Kumar et al., 2021).

1.1.2 Gestion des adventices

Pour tenter de limiter les impacts des adventices sur les cultures, et donc limiter les pertes de rendement, l'homme a imaginé une multitude de techniques pour s'en débarrasser. Les plus répandues sont les méthodes chimiques, dont notamment les herbicides. Bien que très efficaces dans la lutte contre les adventices (Marin-Morales et al., 2013), ces produits ne sont pas sans danger pour l'environnement et la santé humaine. Ils sont en effet à la source de nombreuses perturbations du sol (Rose et al., 2016) et des eaux (Hanke et al., 2010). Pour l'homme, les pesticides peuvent engendrer des problèmes dermatologiques, neurologiques et bien d'autres encore, dont des cancers (World Health Organization, 1990). De plus, l'utilisation répétée d'herbicides similaires durant ces 25 dernières années a placé une pression de sélection sur les adventices, augmentant ainsi la fréquence d'allèles et d'individus résistants à ces produits (Murphy & Lemerle, 2006).

D'autres stratégies de gestion des adventices sont de nature mécanique. Ces méthodes dépendent d'instruments de travail du sol qui enfouissent et déracinent les adventices entre les rangées de cultures (Abbas et al., 2018). Malgré leurs avantages, ces techniques mécaniques présentent de nombreux inconvénients, dont le coût et le temps investis, l'efficacité dépendante des conditions météorologiques ou encore la difficulté d'atteindre les adventices en intra-rang (Hussain et al., 2018). De plus, le labour favorise l'érosion des sols et le lessivage des nutriments (Ahlgren, 2004) et détruit des habitats naturels et la faune sauvage (Culliney, 2005).

La gestion intégrée des adventices met l'accent sur la compréhension des causes des problèmes que ces plantes engendrent plutôt que sur les problèmes eux-mêmes (Buhler, 2005). Elle s'appuie sur des techniques chimiques et mécaniques, mais également biologiques et culturales (Merfield, 2023). Ce mode de gestion a pour objectif d'optimiser le contrôle des adventices, tout en limitant les impacts environnementaux, en augmentant la durabilité des systèmes de culture et en diminuant la pression de sélection des adventices face aux herbicides (Harker & O'Donovan, 2013). Des pratiques agronomiques s'appuyant sur les interactions entre les cultures et les adventices, comme la densité de culture ou la période de semis, peuvent par exemple être utilisées (Korres, 2018).

1.1.3 EcoFoodSystem

L'amélioration de l'efficacité de l'utilisation et de la conservation des ressources naturelles est nécessaire pour parvenir aux demandes d'aliments prévues pour les horizons de 2050 (FAO, 2017). Le développement de la gestion intégrée des adventices est donc un atout majeur pour répondre aux enjeux environnementaux et à la croissance démographique mondiale. C'est dans ce cadre que s'est créé le projet de longue durée EcoFoodSystem, mené à la Faculté de Gembloux Agro-Bio Tech. Il a pour objectif d'étudier différentes rotations de cultures, s'inscrivant dans une agriculture durable et se basant sur une alimentation suivant les recommandations du rapport EAT-Lancet. Ces différentes formes d'agriculture incorporent des techniques de gestion intégrée et offrent ainsi un laboratoire à ciel ouvert pour étudier les dynamiques de compétition entre les cultures et les adventices en contexte agroécologique.

La compréhension de ces dynamiques est cruciale pour garantir le développement de systèmes de cultures durables et représente aujourd'hui un important domaine de recherche (Westwood et al., 2018). Pour ce faire, des techniques de phénotypage par imagerie peuvent être employées. En plus de permettre leur détection, ces techniques offrent le potentiel de caractériser les cultures et les adventices de manière non-destructive (Walter et al., 2015).

1.2 État de l'art

1.2.1 Évaluation de la pression des adventices

L'évaluation de la pression de la flore adventice (PA) sur les cultures nécessite de recueillir des données quantitatives et qualitatives, comme la densité d'adventices, l'indice foliaire des adventices et des cultures ou encore le couvert relatif (Sattin & Berti, 2003). Ces campagnes de mesures sont importantes car la qualité des décisions en termes de gestion des adventices dépend de leur précision, mais elles sont souvent chronophages et requièrent de la main d'œuvre qualifiée. De plus, la distribution inégale des adventices dans les champs demande des méthodes d'échantillonnage qui la prennent en compte. Berti et al. (1992) ont montré que la densité d'adventices pouvait être estimée en lançant une trentaine de fois un cadre métallique de 25×30 cm au hasard dans le champ et en comptant les adventices présentes à l'intérieur. Plus simplement, les adventices peuvent être identifiées à l'aide d'un quadrat placé sur un quadrillage prédéterminé (Rew & Cousens, 2001), mais ces méthodes requièrent une expertise directement sur le terrain.

La PA peut également être définie comme le pourcentage du volume de végétation que représentent les adventices : 0 en l'absence complète d'adventices, 100 en l'absence complète de cultures. En évaluant visuellement cette pression, Harvey & Wagner (1994) ont estimé les pertes de rendements de différentes cultures. Cependant, cette méthode d'estimation de la PA présente deux inconvénients (Sattin & Berti, 2003). Bien qu'il soit possible d'estimer à l'œil la proportion d'adventices et de cultures dans un champ une fois un certain stade de développement atteint, la tâche reste très compliquée durant la période suivant directement le semis. Le second problème est la haute variabilité de la valeur attribuée pour un même niveau de pression par différentes personnes, dépendante de leur perception et de leur expérience.

Pour limiter le besoin d'un expert sur le terrain, des images des quadrats étudiés peuvent être prises et analysées ultérieurement (Ribeiro et al., 2005). Différentes techniques d'analyse d'images et de classification peuvent également être utilisées afin d'automatiser la caractérisation des plantes et ainsi atténuer les problèmes cités au paragraphe précédent. Défini comme « *la description de leurs caractéristiques anatomiques, ontogénétiques, physiologiques et biochimiques à l'aide de capteurs sans contact* » (Walter et al., 2015), le phénotypage des plantes par imagerie s'est rapidement développé durant ces dernières décennies (Mulla, 2013). Il s'appuie sur différents systèmes de vision comme le rouge-vert-bleu (RVB), la 3D, le multispectral, l'hyperspectral etc. (Li et al., 2014) et offre de nombreuses applications en agriculture de précision, dont la détection d'adventices. Cette section établit l'état de l'art sur le suivi par imagerie des adventices en parcelles culturales.

1.2.2 Échelles spatio-temporelles

Les données satellites sont utilisées depuis les années 1970 pour classifier les cultures sur base de leurs réflectances dans différentes bandes spectrales (Bauer & Cipra, 1973). Leurs applications se sont ensuite étendues à l'estimation des rendements (Mulla, 1997), des déficiences en azote (Seelan et al., 2003) ou encore des surfaces de cultures (García Torres et al., 2008). Différents indices de végétation peuvent également être calculés à partir d'images obtenues par satellite afin d'étudier les cultures (Doraiswamy et al., 2003). Les résolutions spatiale, temporelle et spectrale des images acquises par satellite se sont grandement améliorées depuis le début de leur utilisation en agriculture (Mulla, 2013), mais la première reste encore trop grossière que pour travailler à l'échelle de l'individu. Pour la détection d'adventices, il n'est donc pas efficace de se baser sur des images satellite (Rasmussen et al., 2021). De plus, l'utilisation de ces images est souvent limitée par la couverture nuageuse (Moran et al., 1997).

Pour évaluer la croissance et le stress des cultures tout en évitant les contraintes des satellites, la détection proximale s'est également fortement développée durant ces trente dernières années (Peteinatos et al., 2014). Elle fait référence aux systèmes de vision au sol qui peuvent être placés sur des tracteurs, des épandeurs ou des pulvérisateurs (Mulla, 2013), mais aussi sur des structures fixes (Bi et al., 2021). Les premières applications concernaient l'estimation des déficiences en azote de cultures de maïs (Schepers et al., 1992) ou de froment (Stone et al., 1996). D'autres applications ont vu le jour pour le phénotypage de plantes cultivées en intérieur (Wang et al., 2017), mais elles ne sont généralement pas adaptées aux conditions extérieures qui varient fortement, contrairement aux conditions contrôlées pour lesquelles elles sont développées. De nos jours, l'imagerie au sol est principalement utilisée dans le cadre de gestion intégrée des adventices. Elle permet en effet leur détection au champ en temps réel et leur traitement individuel (Gerhards & Oebel, 2006). Les techniques de détection proximale permettent donc de développer des systèmes de contrôle localisé des adventices et ainsi de réduire le travail du sol et l'utilisation d'herbicides (Peteinatos et al., 2014). Elles peuvent également servir à évaluer la pression de la flore adventice en comparant la fraction de couvert végétal (FCV) de celle-ci à celle de la culture. Sur base d'images prises au sol, Gée & Denimal (2020) ont développé un indicateur de pression nommé "weed pressure" (WP), défini comme le rapport entre la FCV des adventices et celle de la culture. Ils ont montré que cet indicateur offrait une bonne approximation du rapport des biomasses des adventices et de la culture, lui-même considéré comme un des meilleurs indicateurs de compétition en ce qui concerne la biomasse (Caussanel, 1989).

À mi-chemin entre les satellites et la détection proximale, l'utilisation des drones en agriculture de précision s'est démocratisée au début des années 2000. Leurs applications sont assez similaires à celles de la détection proximale : phénotypage, estimation de rendements, détection de stress (Olson & Anderson, 2021). Concernant la détection d'adventices, les drones sont plus efficaces que les satellites (Rasmussen et al., 2021) et offrent une couverture spatiale plus importante que des systèmes de détection proximale fixes. La télédétection d'adventices par drone permet ainsi de créer des cartes d'infestation qui peuvent ensuite servir à leur gestion intégrée (Wang et al., 2019). Les problèmes principaux des drones sont leurs vibrations qui peuvent affecter les images acquises (Esposito et al., 2021) ainsi que les limitations dues à leurs batteries (Anderegg et al., 2023).

Afin d'améliorer les méthodes de gestion intégrée des adventices, les techniques de détection proximale et de télédétection doivent être combinées pour ainsi additionner leurs avantages et combler leurs lacunes respectives. Seulement, ces approches multi-échelles sont encore peu étudiées dans la littérature scientifique. Dans leur étude, Anderegg et al. (2023) ont mis en avant l'importance de développer des cartes d'infestation des adventices avec une haute résolution spatiale mais aussi temporelle. En comparant des images acquises par drone à des estimations visuelles de la pression de la flore adventice, ils ont évalué l'utilisation des drones dans le cadre de détection d'adventices et ont conclu que le développement de systèmes de détection proximale des adventices était crucial, surtout pour les stades suivant le semis. Néanmoins, ils soulignent le fait que le drone reste un outil intéressant pour la gestion des adventices pour les stades plus tardifs. Marino (2023) a quant à lui étudié des images satellites d'un champ de céréales à différents stades de développement et a montré qu'une échelle multi-temporelle permettait de mieux estimer la variabilité de la pression des adventices sur la culture. À l'heure actuelle, les algorithmes de traitement des données sont encore adaptés à une seule échelle, créant ainsi d'importantes différences entre les sources de données et les modèles utilisés. La transférabilité des méthodes à travers plusieurs échelles reste encore un domaine de recherche en développement (Weiss et al., 2020).

1.2.3 RVB

De nombreux capteurs sont utilisés dans le monde de l'imagerie, mais les plus connus sont les capteurs rouge-vert-bleu (RVB). Dans cet espace colorimétrique, chaque couleur est exprimée comme la combinaison des intensités des trois couleurs primaires RVB (Sonka et al., 2015). De nombreuses recherches ont développé des outils d'évaluation de la pression adventice sur des systèmes placés au sol (Gée & Denimal, 2020). Mais d'autres études ont également eu recours aux capteurs RVB embarqués sur drone pour détecter les adventices (Islam et al., 2021) et pour améliorer leur gestion tout au long de la saison (Anderegg et al., 2023). Plusieurs méthodes de segmentation des adventices sont utilisées : classification au niveau du pixel (Moazzam et al., 2023), détection d'objet (Rahman et al., 2023) ou encore annotation de vignettes (Gée & Denimal, 2020). Des traits de couleur mais aussi de texture, notamment de co-occurrence, sont extraits de ces images RVB pour différencier les adventices de la culture en place (Bakhshipour et al., 2017).

Pour ce faire, les séparateurs à vastes marges (Support Vector Machines, SVM) et les réseaux neuronaux (Neural Networks, NN) sont les plus souvent utilisés comme classificateurs (Behmann et al., 2015). Les SVM présentent de nombreux avantages : apprentissage efficace avec peu de données d'entraînement, robustesse face aux erreurs des modèles ou encore performance computationnelle par rapport à d'autres méthodes d'apprentissage automatique comme les réseaux neuronaux (Gholami & Fakhari, 2017). Concernant ces derniers, les NN ont une forte capacité d'apprentissage et peuvent travailler avec des données non entraînées (Bakhshipour et al., 2017). Des méthodes d'apprentissage profond peuvent également être utilisées pour limiter les besoins d'annotations manuelles (Hasan et al., 2021).

1.2.4 3D

Pour combler le manque d'information de profondeur des techniques 2D, qui ne peuvent pas correctement estimer le volume et la biomasse de la végétation (Paturkar et al., 2020) ou détecter les couches inférieures de la canopée (Smith et al., 2018), des techniques d'imagerie 3D sont également utilisées pour le phénotypage des plantes. Elles peuvent être classées en deux groupes : les méthodes actives et les méthodes passives (Sonka et al., 1993). Les premières utilisent une source contrôlée d'émission d'énergie, comme le LiDAR ou les capteurs temps de vol, tandis que les secondes n'utilisent pas de telles sources, comme la stéréovision ou la Structure from Motion (Beltran & Basañez, 2014). Les techniques d'acquisition passives reconstruisent un nuage de points 3D en analysant différentes images prises avec des perspectives différentes (Siudak & Rokita, 2014). Elles sont moins coûteuses et permettent d'acquérir directement de l'information sur les couleurs (Harandi et al., 2018).

L'imagerie 3D permet d'étudier les paramètres morphologiques des plantes, mais également de leurs organes (Li et al., 2020). Elle peut améliorer les systèmes automatiques de détection et de caractérisation des adventices à différents stades (Wu et al., 2020). De plus, les techniques d'imagerie 3D offrent une nouvelle approche dans la compréhension des dynamiques des adventices en réponse à des méthodes de gestion intégrée. Elles permettent par exemple de générer des modèles descriptifs des communautés d'adventices à l'aide des mesures de surface et de densité des feuilles et de taille des plantes (Dobbs et al., 2022). La plupart des techniques d'imagerie 3D utilisées pour la détection d'adventices sont placées sur des systèmes de détection proximale, qu'il s'agisse de méthodes passives (Badhan et al., 2021) ou actives (Shahbazi et al., 2021). Dans le cadre de l'évaluation de la PA, encore peu d'études se sont intéressées à l'utilisation de la 3D embarquée sur drone (Singh et al., 2020).

1.2.5 Multispectral

Les images RVB sont également pauvres en information spectrale, étant donné qu'elles ne contiennent l'information que de trois bandes dans le visible. L'imagerie multispectrale permet d'acquérir de l'information dans d'autres parties du spectre électromagnétique, notamment dans le proche infrarouge (Sahin et al., 2023). Il est alors possible de calculer différents indices de végétation, mesures quantitatives renseignant sur la vigueur de la végétation sur base des réflectances acquises dans plusieurs bandes spectrales (Campbell, 1987). L'indice de végétation par différence normalisée (Normalized Difference Vegetation Index, NDVI), développé par Rouse (1974), est parmi les indices les plus utilisés en télédétection, mais d'autres ont déjà été étudiés pour caractériser la pression adventice (Anderegg et al., 2023). À cette fin, la plupart des recherches ont employé une caméra multispectrale embarquée sur un drone.

1.2.6 Hyperspectral

Plusieurs études se sont penchées sur l'utilisation de l'imagerie hyperspectrale pour la détection d'adventices. Grâce à l'acquisition de données spectrales à haute résolution, elle permet de différencier des objets aux couleurs et textures similaires (Dammer et al., 2013), comme des plantes de la même famille (Lin et al., 2022). Elle pourrait donc être une solution pour l'identification des adventices en début de saison, quand leur gestion est la plus importante mais qu'elles ressemblent encore à la culture (Ram et al., 2024). Les techniques d'imagerie hyperspectrale sont autant employées avec des systèmes de détection proximale (Wendel & Underwood, 2016) qu'avec des drones (Lou et al., 2022) pour évaluer la compétition entre culture et adventices. Des capteurs hyperspectraux peuvent aussi être embarqués sur des avions ou des satellites, mais ces méthodes ne se montrent efficaces que pour la détection de larges taches d'adventices et non d'individus (Atkinson et al., 2014).

1.3 Objectifs

L'objectif principal de ce travail est de chercher et d'identifier des indicateurs de la pression adventice par imagerie. Cette recherche est effectuée sur des images acquises par détection proximale et télédétection. Pour tester la pertinence de ces indicateurs, ils sont comparés à des mesures de terrain. La dynamique de compétition entre la culture et les adventices est ensuite évaluée en étudiant l'évolution des indicateurs de pression au cours de la saison dans les quadrats de référence. La démarche adoptée est la suivante :

1. Acquisition d'images terrestres et aériennes de quadrats géolocalisés ;
2. Recherche d'indicateurs de pression sur les images terrestres en discriminant la culture de froment de la population d'adventices ;
3. Comparaison de ces indicateurs aux données de référence ;
4. Évaluation de l'évolution de la pression adventice au cours de la saison dans les quadrats ;
5. Recherche d'indicateurs de pression sur les images aériennes en les comparant aux images terrestres.

2 Matériels et méthodes

2.1 Site d'étude, données de référence et fréquence d'acquisition

Le site d'étude est situé à Gembloux en Belgique (50°33' N, 4°41' E), sur les parcelles du projet EcoFoodSystem mené à la Faculté de Gembloux Agro-Bio Tech. Ce projet a pour objectif d'étudier quatre rotations de huit années sur le long terme, illustrées à la figure 1. La première rotation, nommée "*business as usual*", s'inscrit dans un régime alimentaire actuel et est testée selon deux modalités : avec et sans pesticides. La deuxième rotation, "*integrated crop-livestock system*", se base sur une consommation locale saine et durable et sur le rapport EAT-Lancet. Enfin, la dernière rotation dite "*vegan*" est similaire à la précédente mais n'intègre aucun animal d'élevage. Chaque année, deux temporalités sont prises en compte. La saison 2023-2024 représente la quatrième année de l'essai, ce sont donc les cultures 4 et 8 qui sont en place. Seules les parcelles en culture 4, toutes en froment, ont été étudiées dans le cadre de ce travail.



FIGURE 1 – Rotations mises en place sur le projet EcoFoodSystem.

La figure 2 illustre l'organisation spatiale du projet sur les 30 ha de terres agricoles qui y sont allouées. Les parcelles de l'essai longue durée sont distribuées aléatoirement sur 4 blocs de 84 × 144 m. Chaque bloc est divisé en 8 parcelles, chacune correspondant à une des 2 temporalités des 4 rotations. Par contrainte de temps et de main d'œuvre, seules les parcelles du bloc 1 ont été suivies.




FIGURE 2 – Localisation et organisation des parcelles sur le projet EcoFoodSystem.

Chaque parcelle brute de 18×84 m, schématisée à la figure 3, contient une parcelle nette de 15×42 m au sein de laquelle les conditions sont considérées comme parfaitement homogènes. Cette parcelle nette est divisée en deux zones : une autorisant les tests destructifs et une les interdisant. Un suivi annuel de la flore adventice est réalisé dans chaque parcelle. Pour ce faire, 5 points d'échantillonnage sont disposés en "W" selon une distance horizontale régulière.




FIGURE 3 – Schématisation d'une parcelle sur le projet EcoFoodSystem.

Pour les céréales, un quadrat de 50×50 cm est défini dans un rayon de 3 m autour de chacun de ces points et géolocalisé à l'aide d'une station GNSS Reach RS+ (Emlid, Budapest, Hongrie). Il est marqué à l'aide de deux piquets en plastique placés dans la diagonale d'un cadre en bois, comme montré à la figure 4. Deux relevés sont effectués chaque année dans ces quadrats : le premier avant la première intervention de désherbage et le second à floraison de la culture. Lors du premier relevé, les adventices présentes sont identifiées, comptées et encodées. Lors du second relevé, les mêmes mesures sont prises, en plus des biomasses aériennes sèches des adventices et de la céréale. Toutes ces données de terrain, récoltées dans le cadre de la thèse de Nina Leclef, ont servi de base de comparaison pour les données extraites par techniques d'imagerie.



FIGURE 4 – Cadre en bois et piquets en plastique utilisés afin de marquer les quadrats.

En milieu de saison, un tuteur en bambou surmonté d'un cylindre en mousse rose, illustré à la figure 5, a été placé à côté de chaque quadrat afin de faciliter leur localisation. Cela a permis d'éviter de devoir utiliser la station Reach à chaque sortie et ainsi gagner du temps sur le terrain.



FIGURE 5 – Tuteur en bambou et cylindre en mousse utilisés afin de mieux repérer les quadrats.

Afin de pouvoir caractériser la dynamique de compétition entre le froment et les adventices, un suivi temporel des quadrats a été réalisé. Des images terrestres et aériennes ont donc été prises chaque semaine durant 6 semaines, entre le 08/05/2024 et le 12/06/2024. Pour limiter les variations des conditions d'illumination, toutes les sorties terrain ont été effectuées entre 10 et 16 heures. Dans la même logique, les acquisitions au sol et par drone étaient faites, si possible, le même jour. Pour des raisons logistiques et météorologiques, il est arrivé que la prise des images terrestres et celle des images aériennes soient espacées de deux jours. La table 1 reprend les dates d'acquisition des deux types d'images. Un V indique que la prise d'image a eu lieu, un X indique qu'elle n'a pas eu lieu. Au total, 120 images terrestres ont été acquises (6 dates \times 4 parcelles \times 5 quadrats par parcelle) et 6 vols de drone ont été effectués.

TABLE 1 – Résumé des dates d'acquisition des images terrestres et aériennes.

Date	Bloc 1	
	Images terrestres	Images aériennes
08/05/2024	V	V
14/05/2024	V	V
23/05/2024	V	V
28/05/2024	X	V
30/05/2024	V	X
06/06/2024	V	V
13/06/2024	V	V

2.2 Images terrestres

2.2.1 Acquisition

Les images terrestres ont été acquises à l'aide d'une caméra OAK-D S2 (Luxonis, Westminster, États-Unis), munie d'un capteur RVB de 12 MP (4056×3040 px). Elle a été fixée à une structure en profilés aluminium, illustrée à la figure 6, et imaginée afin de pouvoir prendre des images des quadrats tout en limitant les potentiels problèmes d'ombres engendrées par la structure. La hauteur de la caméra était ajustée à chaque sortie, environ 1 mètre au-dessus de la canopée de la culture. Enfin, la perche était positionnée de sorte à placer la caméra au-dessus du centre du quadrat.



FIGURE 6 – Perche en profilés aluminium utilisée pour l'acquisition des images terrestres.

2.2.2 Récupération de la zone d'intérêt

Les images ont été acquises avec une définition de 4056×3040 px, mais enregistrées avec une taille de 3840×2160 px après avoir été rognées. Ainsi, elles couvraient une surface plus étendue que celle des quadrats étudiés. La première opération de traitement a donc été d'extraire, pour chaque image, la zone d'intérêt de 50×50 cm correspondant au quadrat.

Pour ce faire, les images ont été importées dans l'environnement Spyder IDE (version 5.1.1) à l'aide du module Python 3 *opencv* (version 4.6.0). La zone carrée de 1538×1538 px au centre de l'image, représentée en rouge sur la figure 7, a ensuite été conservée et considérée comme la région couverte par le quadrat. Les calculs pour obtenir la valeur de 1538 px sont détaillées ci-dessous et basés sur la figure 8.



FIGURE 7 – Exemple d’image terrestre acquise. Le carré rouge représente la zone d’intérêt, correspondant au quadrat étudié.

En connaissant d’une part la distance H entre le haut de la canopée et la caméra, et d’autre part le champ de vision horizontal (HFOV) 2α de la caméra, il est aisé de calculer la distance horizontale $2x$ couverte par l’image grâce aux équations 1 et 2.

$$\tan \alpha = \frac{x}{H} \quad (1)$$

$$2x = 2H \times \tan \alpha \quad (2)$$

Lors de la première sortie, la distance H a été mesurée à 101,5 cm, valeur conservée pour toutes les autres sorties afin d’assurer une homogénéité dans les calculs. Le HFOV de la caméra est quant à lui renseigné par le constructeur à un angle de 66° . Enfin, la distorsion tangentielle d’échelle due à la prise de vue nadir a été négligée. La distance $2x$, correspondant à 4056 px sur l’image, peut alors être calculée : $2x = 131,83$ cm, et une simple règle de trois permet de déterminer que 1538 px sur l’image correspondent à 50 cm sur le haut de la canopée.




FIGURE 8 – Schéma du système d’acquisition des images terrestres. La perche en aluminium est représentée en gris, la caméra en noir, la végétation en vert, et le HFOV de la caméra en rouge.

2.2.3 Segmentation sol / végétation

Après avoir extrait la zone d'intérêt de chaque image, l'étape suivante a été de séparer la végétation de l'arrière-plan, c'est-à-dire du sol. Cette segmentation s'est appuyée sur la classification de superpixels (SP), groupes de pixels partageant une information spatiale et de couleur commune. Ces superpixels ont été calculés sur base des images RVB à l'aide d'un algorithme de groupement itératif linéaire simple (simple linear iterative clustering, SLIC), issu du module Python 3 *scikit-image* (version 0.22.0).

Rappel théorique : Groupement Itératif Linéaire Simple

Plusieurs algorithmes permettent de regrouper les pixels en régions perceptuellement similaires, appelées superpixels (SP). Ces derniers offrent la possibilité d'extraire des caractéristiques d'une image tout en réduisant fortement la complexité des traitements effectués par la suite (Achanta et al., 2012). Ces algorithmes ont notamment été utilisés à des fins de segmentation (Shotton et al., 2009) ou de localisation d'objet (Kumar et al., 2004).

La fonction *segmentation.slic* du module *scikit-image* se base sur l'algorithme SLIC développé par Achanta et al. (2012). Cette méthode s'appuie sur le regroupement de k-moyennes en utilisant cinq caractéristiques : 3 issues de l'espace colorimétrique CIELAB et 2 des coordonnées des pixels sur l'image. Les centres $C_i = [l_i, a_i, b_i, x_i, y_i]$ sont échantillonnés sur un quadrillage régulier espacé de S pixels, valeur égale à $\sqrt{N/k}$ pour obtenir des superpixels de tailles similaires, avec N le nombre de pixels sur l'image et k le nombre de groupements souhaités.

Chaque pixel i est ensuite assigné au centre du groupement le plus proche, dont la région de recherche chevauche sa position. Contrairement aux autres algorithmes de regroupement de k-moyennes, l'algorithme SLIC n'effectue pas la recherche sur toute l'image, comme le montre la figure 9. Cela permet de limiter fortement le nombre de distances à calculer et donc de réduire grandement les temps de calcul. La région de recherche, illustrée sur la figure 9b, est une région de taille $2S \times 2S$ concentrique au centre du superpixel étant donné que ce SP a une taille approximative de $S \times S$.




FIGURE 9 – Comparaison d'un algorithme de regroupement classique de k-moyennes (a) avec l'algorithme SLIC (b). (a) La recherche s'effectue sur l'image entière. (b) La recherche s'effectue sur une région limitée de l'image. (Achanta et al., 2012)

Après que chaque pixel a été assigné au centre du groupement le plus proche, ce centre est recalculé comme le vecteur moyen $[l, a, b, x, y]$ des pixels qui lui sont affectés. La norme L_2 sert à évaluer l'erreur résiduelle entre la position du centre du nouveau regroupement et celle de l'ancien. Ces deux étapes sont ensuite effectuées jusqu'à la convergence de l'erreur. Une dernière étape de post-traitement oblige la connectivité en réaffectant les pixels disjointes aux superpixels voisins.

Afin de prendre en compte le développement et le changement rapide de la végétation, un modèle de segmentation sol / végétation a été développé pour chaque sortie terrain. Pour chaque date d'acquisition, quatre images ont été sélectionnées pour créer le jeu d'entraînement du classificateur. Ces quatre images provenaient respectivement des quatre parcelles étudiées, afin de prendre en compte les possibles variations de développement mais aussi d'illumination, l'acquisition pouvant prendre un certain temps.

De chacune de ces images de 1538×1538 px a été créée une vignette de 500×500 px. Ce recadrage a permis d'alléger le temps et le travail d'annotation, tout en gardant une représentativité de la végétation et du sol. La fonction *segmentation.slic* du module *scikit-image* a ensuite été appliquée à chaque vignette. Deux paramètres de cette fonction ont été adaptés pour obtenir un bon compromis entre le nombre de superpixels et leur taille : le nombre approximatif de SP sur l'image de sortie, *n_segments*, et leur compacité, *compactness*. Le premier a été fixé à 5.000 et le second à 10. Ces valeurs permettaient de limiter le nombre de superpixels et donc les temps de calcul, tout en évitant que ces SP ne contiennent des pixels appartenant à la végétation et au sol.

Ces vignettes ont été annotées en suivant la méthode illustrée à la figure 10. Les superpixels marqués par du vert composaient la classe d'entraînement de la végétation, tandis que ceux marqués par du rouge composaient celle du sol. Si par erreur un SP était annoté par du vert et du rouge, il n'était pas repris dans le jeu d'entraînement. Six variables ont été extraites des superpixels annotés : les valeurs moyennes des canaux rouge-vert-bleu (RVB) et teinte-saturation-valeur (TSV). L'espace TSV a été ajouté au RVB car il permet d'être plus robuste face aux variations de conditions d'illumination.




FIGURE 10 – Illustration du processus d'annotation des superpixels pour la segmentation sol / végétation.

La classification a ensuite été réalisée à l'aide d'un algorithme séparateur à vastes marges (SVM), implémenté par la fonction *svm.SVC* du module Python 3 *scikit-learn* (version 1.5.0). Les paramètres de cette fonction ont été laissés à leur valeur par défaut. Le modèle a été alimenté par les six variables citées au paragraphe précédent. Afin d'évaluer le modèle ainsi créé, une cinquième vignette sélectionnée au hasard était annotée pour servir de jeu de validation. Son exactitude a été calculée à l'aide d'une matrice de confusion.

Pour chaque sortie terrain, un classificateur SVM a donc été entraîné et toutes les images des quadrats ont pu être classifiées. Pour ce faire, elles ont également été segmentées au moyen de la fonction *segmentation.slic*. Pour obtenir des superpixels comparables à ceux des vignettes, les paramètres *n_segments* et *compactness* ont été fixés respectivement à 45.000 et 10. En effet, les images des quadrats étaient environ 9 fois plus grandes que les vignettes annotées ($1538 \times 1538 \cong 9 \times 500 \times 500$), le nombre approximatif de SP voulu a donc été multiplié par 9. Les moyennes des valeurs RVB et TSV ont ensuite été extraites de chaque superpixel afin de déterminer, à l'aide du modèle SVM créé, s'il s'agissait de végétation ou de sol. Un masque binaire de végétation a ainsi pu être obtenu pour chaque image de quadrat, représenté à la figure 11b, et appliqué à l'image RVB comme sur la figure 11c.




FIGURE 11 – Segmentation sol / végétation. (a) Image RVB. (b) Masque de végétation binaire obtenu par SVM. (c) Image RVB à laquelle le masque a été appliqué.

2.2.4 Différenciation culture / adventices

L'étape précédant l'évaluation de la pression adventice dans chaque quadrat était l'identification de ces adventices sur les images. Un protocole similaire à celui de la segmentation sol / végétation a été suivi, à quelques changements près, détaillés ci-dessous.

Tout d'abord, les images des quadrats ont été segmentées en superpixels avec la même fonction *segmentation.slic* citée auparavant. Ses paramètres *n_segments* et *compactness* ont été fixés respectivement à 5.000 et 10, et une option supplémentaire de la fonction a été utilisée. En effet, le paramètre *mask* permet d'appliquer l'algorithme SLIC uniquement sur une région d'intérêt. Le masque de végétation binaire de chaque quadrat a donc servi à fixer ce paramètre pour son image RVB respective. De la même manière que pour la segmentation sol / végétation, les valeurs des deux premiers paramètres ont été ajustées afin de créer des SP assez petits que pour ne pas contenir de pixels représentant différentes espèces de plantes, tout en limitant leur nombre une fois le masque de végétation appliqué.

Cette fois-ci, seulement deux modèles de classification ont été développés : un pour les sorties effectuées avant la floraison des adventices (08/05/2024, 14/05/2024 et 23/05/2024) et un pour les sorties après cette floraison (30/05/2024, 06/06/2024 et 13/06/2024). Cette séparation a été faite pour deux raisons, la première étant de pouvoir commencer l'identification des adventices sur les images avant la fin du protocole d'acquisition et donc de gagner du temps en répartissant le travail au cours de la saison. La seconde raison était d'éviter d'identifier à tort certaines régions des images comme des fleurs de certaines adventices, alors qu'il était certain que cela ne pouvait pas être le cas. Cela a ainsi permis d'améliorer le modèle pré-floraison. Pour chacun des deux modèles, six images, deux par date, ont été sélectionnées pour créer le jeu d'entraînement du classificateur. Elles ont été choisies pour représenter au mieux les différentes espèces d'adventices et le froment à différents stades de développement.

Ces images ont été annotées en suivant la méthode illustrée à la figure 12. Les images acquises ne permettaient pas d'identifier toutes les adventices en présence dans les quadrats, seules les plus visibles ont donc été étudiées : froment d'hiver (TRZAX), chardon des champs (CIRAR), camomille sauvage (MATCH), coquelicot (PAPRH) et moutarde des champs (SINAR). Pour le modèle pré-floraison, les superpixels ont été marqués à l'aide de quatre couleurs différentes représentant quatre classes : froment, feuilles de chardon, tiges de camomille et feuilles de moutarde. Pour celui post-floraison, les SP ont été marqués de sept couleurs différenciant sept classes : froment, feuilles de chardon, tiges de camomille, fleurs de camomille, coquelicot, feuilles de moutarde et fleurs de moutarde.

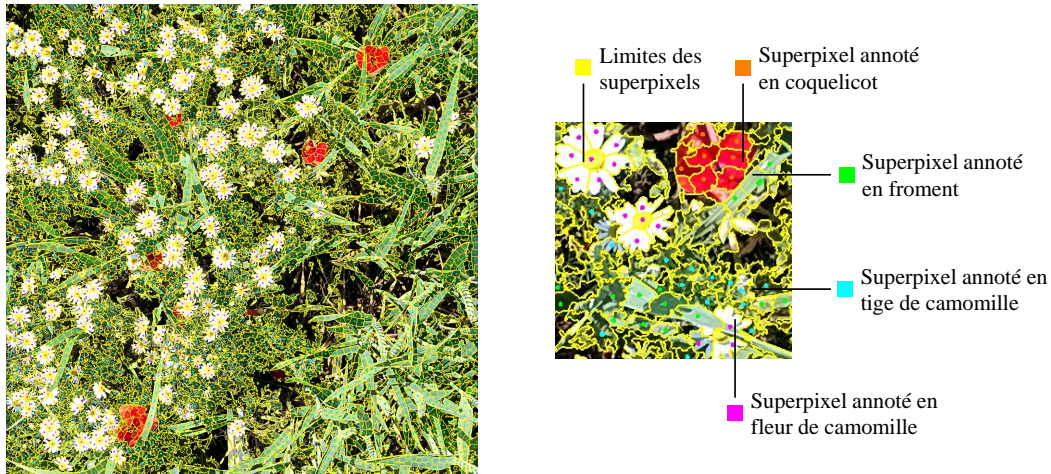


FIGURE 12 – Illustration du processus d'annotation des superpixels pour la différenciation culture / adventices.

Douze variables ont ensuite été extraites des superpixels annotés : 6 traits de couleurs et 6 de textures. En effet, un avantage qu'a l'utilisation des SP pour la discrimination culture / adventices est qu'elle permet d'obtenir des informations sur la texture, contrairement aux classifications basées sur les pixels (Strothmann et al., 2017). Les traits de couleurs étaient les mêmes que pour la segmentation sol/végétation, tandis que ceux de texture ont été calculés à partir de la matrice de co-occurrence des niveaux de gris (GLCM) correspondante à chaque SP, à l'aide des fonctions *graycomatrix* et *graycoprops* du module *scikit-image*.

Rappel théorique : Matrice de co-occurrence des niveaux de gris

Les matrices de co-occurrence se basent sur l'apparition répétée d'une certaine configuration de niveaux de gris dans la texture (Sonka et al., 2015). La fonction *graycomatrix* utilise des calculs de texture du deuxième ordre, dans le sens où elle considère les relations entre groupes de deux pixels sur l'image originale (Hall-Beyer, 2017).

La figure 13 illustre un exemple d'image en nuances de gris. Il s'agit d'une image enregistrée en 2 bits, les niveaux de gris correspondant à chaque pixel sur la droite de l'image peuvent donc prendre une valeur comprise entre 0 et 3. L'occurrence d'une configuration de niveaux de gris est décrite selon deux paramètres : la direction ϕ de la relation entre les deux pixels et la distance d les séparant. Elle est donc définie comme la matrice des fréquences $P_{\phi,d}(a,b)$ avec ϕ la direction, d la distance et a et b les deux niveaux de gris étudiés (Sonka et al., 2015). Par exemple, $P_{0,1}(0,0) = 4$ car 4 pixels de niveau de gris égal à 0 ont un voisin direct de même niveau selon la direction 0° .




FIGURE 13 – Exemple d'une image en nuances de gris et des valeurs de niveau de gris correspondant à chaque pixel (Hall-Beyer, 2017).

Une fois la matrice calculée pour une direction et une distance, il est possible d'en extraire différents indicateurs de la texture de l'image. La fonction *graycoprops* en calcule six : le contraste (3), la dissimilarité (4), l'homogénéité (5), le second moment angulaire (ASM) (6), l'énergie (7) et la corrélation (8). Les équations définissant ces indicateurs sont reprises ci-dessous :

$$Contrast = \sum_{i,j=0}^{N-1} P_{i,j}(i-j)^2 \quad (3) \quad ASM = \sum_{i,j=0}^{N-1} P_{i,j}^2 \quad (6)$$

$$Dissimilarity = \sum_{i,j=0}^{N-1} P_{i,j}|i-j| \quad (4) \quad Energy = \sqrt{ASM} \quad (7)$$

$$Homogeneity = \sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1+(i-j)^2} \quad (5) \quad Correlation = \sum_{i,j=0}^{N-1} P_{i,j} \left[\frac{(i-\mu_i)(j-\mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \quad (8)$$

Douze traits ont donc été extraits des superpixels annotés : les valeurs moyennes des canaux RVB et TSV, ainsi que les six indicateurs de texture cités ci-dessus (avec $\phi = 0^\circ, 45^\circ, 90^\circ$ et 135° et $d=1$).

Une sélection de variables sur ces douze traits a ensuite été réalisée au moyen d'une élimination récursive des variables (RFE). La RFE est une méthode de sélection efficace avec les SVM. En effet, ceux-ci se basent sur un sous-ensemble de points d'apprentissage pour définir les frontières de décision, tout comme la RFE s'appuie sur la sélection d'un sous-ensemble de variables les plus pertinentes pour la classification. Elle a été implémentée à l'aide de la fonction *feature_selection.RFE* du module *scikit-learn*.

Pour chacun des modèles pré- et post-floraison des adventices, la RFE a été faite en conservant 6, 8, 10 et 12 variables. Les variables identifiées comme pertinentes ont ensuite servi à entraîner un modèle de classification SVM : 8 modèles ont donc été développés (2 groupes de dates \times 4 groupes de variables). Pour évaluer et comparer ces classificateurs, des superpixels supplémentaires ont été annotés : 50 par classe de végétation, soit 200 et 350 SP respectivement pour les dates pré- et post-floraison. Ces SP ont été classés par chaque modèle SVM et une matrice de confusion a été calculée. Deux classificateurs ont été conservés, soit un par groupe de dates. Le critère de sélection s'est basé sur leur capacité à différencier le froment des adventices, même si plus d'erreurs entre espèces d'adventices étaient commises. En effet, l'objectif principal est d'étudier la pression totale infligée par toutes les adventices sur la culture, il était donc plus intéressant de simplifier les matrices de confusion et de rassembler les différentes espèces d'adventices en une seule classe.

Une fois le meilleur modèle identifié pour les dates pré- et post-floraison, la différenciation culture / adventices sur toutes les images des quadrats a pu être réalisée. Celles-ci ont été segmentées grâce à l'algorithme SLIC en fixant les mêmes paramètres que pour les images d'entraînement. Les caractéristiques extraites de chaque quadrat étaient celles conservées à l'étape précédente et chaque superpixel a été classé par le modèle SVM sélectionné. La figure 14 illustre un exemple d'image RVB (figure 14a) et de l'identification du froment et des adventices après classification (figure 14b).




FIGURE 14 – Différenciation froment / adventices. (a) Image RVB. (b) Classification des plantes obtenue par SVM.

2.2.5 Calcul de la pression adventice

Pour chaque image, la fraction de couvert végétal (FCV) a alors pu être calculée pour le froment et pour chaque espèce d'adventice. La FCV d'une espèce était égale au pourcentage de pixels appartenant à cette classe sur l'image. Les FCV ont ensuite été regroupés en deux indices : $FCV_{culture}$ (équation 9) et $FCV_{adventice}$ (équation 10) :

$$FCV_{culture} = FCV_{froment} \quad (9)$$

$$FCV_{adventice} = FCV_{chardon} + FCV_{camomille} + FCV_{coquelicot} + FCV_{moutarde} \quad (10)$$

Enfin, la pression adventice (PA) dans chaque quadrat a été calculée comme le rapport de ces deux indices (équation 11) :

$$PA_{image} = \frac{FCV_{adventice}}{FCV_{culture}} \quad (11)$$

2.2.6 Comparaison aux données de terrain

Avant d'évaluer la dynamique de compétition froment / adventices tout au long de la saison, les indicateurs calculés dans la section précédente ont été comparés aux mesures de terrain réalisées par Nina Leclef. Ce relevé a été effectué le lendemain de la dernière acquisition d'images, ce sont donc ces dernières qui ont été confrontées aux mesures réalisées.

D'abord, une régression linéaire entre la biomasse de chaque espèce végétale et la FCV correspondante dans chaque quadrat a été réalisée et le score R^2 a été calculé. Les biomasses et FCV ont été normalisées afin de simplifier la comparaison lors de la lecture des graphiques.

Pour la pression, la PA_{image} a été comparée à la $PA_{biomasse}$, cette dernière étant égale au rapport entre la biomasse totale des adventices et la biomasse du froment (équation 12), également à l'aide d'une régression linéaire et du score R^2 .

$$PA_{biomasse} = \frac{Biomasse_{adventice}}{Biomasse_{culture}} \quad (12)$$

2.2.7 Caractérisation de la dynamique de compétition froment / adventices

Finalement, la dynamique de compétition entre le froment d'hiver et les différentes adventices suivies et présentes sur les parcelles a pu être étudiée. Cela a été réalisé en évaluant l'évolution des FCV de la culture et des adventices ainsi que de la PA extraite des images terrestres.

Pour ce faire, ces trois indicateurs ont été calculés pour chaque quadrat et pour chaque date. Ils ont ensuite été mis en graphique afin de mieux visualiser leur évolution.

2.3 Images aériennes

2.3.1 Acquisition

Les images aériennes ont été acquises à l'aide d'une caméra multispectrale RedEdge-M (MicaSense, Seattle, États-Unis), munie de cinq capteurs de 1,2 MP (1280 × 960 px). Ils ont permis d'enregistrer des images dans cinq bandes spectrales : bleu (475 nm), vert (560 nm), rouge (668 nm), red-edge (717 nm) et proche infrarouge (840 nm). La caméra était embarquée sur un drone Matrice 100 (DJI, Shenzhen, Chine) utilisé pour survoler les parcelles d'intérêt. Le dessin du plan de vol a été limité par le cimetière situé directement à côté du champ, mais les images des quadrats suivis pour ce travail ont correctement été acquises. Onze cibles de contrôle géolocalisées ont été réparties autour (9) et sur (2) les parcelles afin de pouvoir corriger la position des images par la suite. Les vols ont été faits à une hauteur de 50 mètres, avec un recouvrement latéral de 90% et à une vitesse de 3,2 m/s. Le plan de vol, les quadrats et les cibles sont localisés sur la figure 15 ci-dessous.




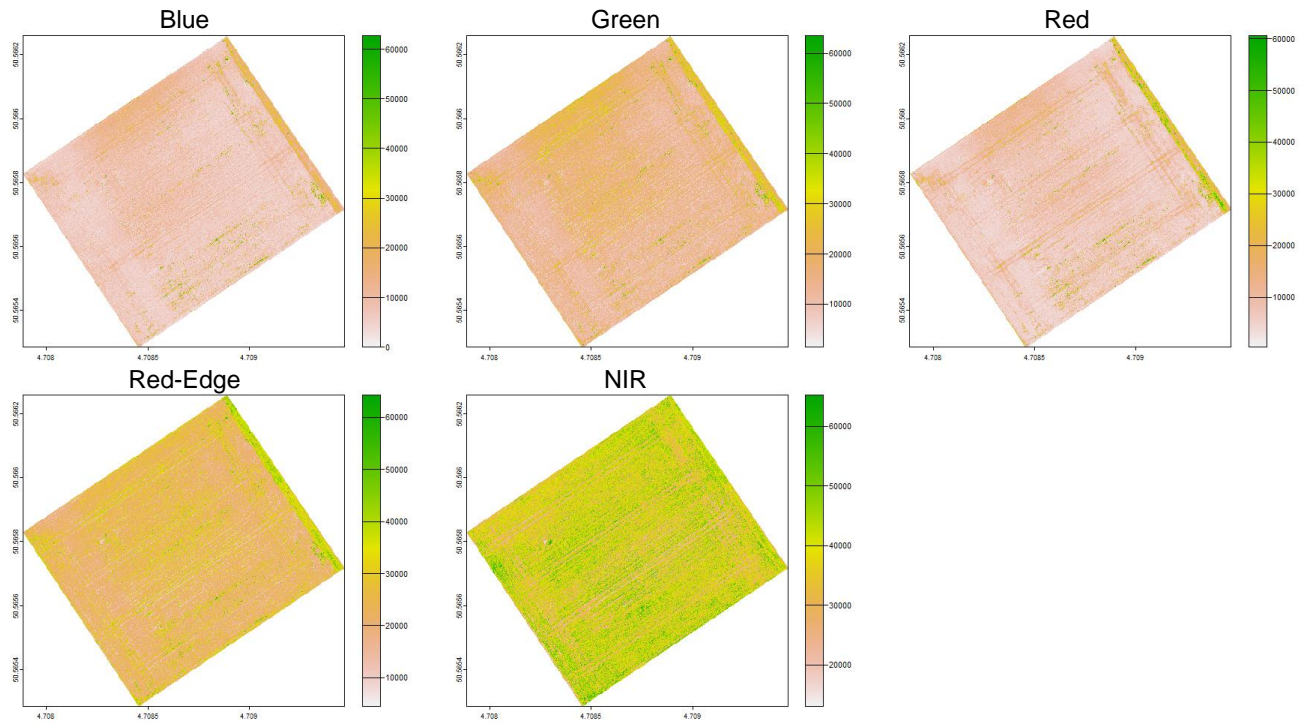
FIGURE 15 – Dessin du plan de vol et localisation des quadrats et des cibles de contrôle.

2.3.2 Génération des orthomosaïques


Une fois acquises, les images ont été importées dans le logiciel Agisoft Metashape Professional (version 1.5.5). Plusieurs étapes se sont ensuite succédées afin de reconstruire des orthomosaïques :

1. Alignement des images ;
2. Localisation des cibles de contrôle sur toutes les images ;
3. Optimisation des positions des images ;
4. Construction d'un nuage de points dense ;
5. Construction d'un modèle numérique d'élévation ;
6. Construction d'une orthomosaïque ;
7. Calibration des réflectances.

Les orthomosaïques ainsi obtenues avaient toutes une résolution au sol comprise entre 2,5 et 3,5 cm/px. La figure 16 illustre un exemple d'orthomosaïque reconstruite et rognée selon le contour des parcelles étudiées. Comme le montre la figure 16a, la réflectance de chaque bande était enregistrée en 16 bits et prenait donc pour chaque pixel une valeur comprise entre 0 et 65.535.



(a)



(b)

FIGURE 16 – Exemple d'orthomosaïque reconstruite et rognée selon les contours des parcelles étudiées. (a) Réflectance mesurée dans les 5 bandes. (b) Fausses couleurs RVB.

2.3.3 Extraction des données dans les quadrats

Comme expliqué précédemment, les positions des centres des quadrats ont été géolocalisées en début d'expérimentation et enregistrées dans une couche vectorielle. Cette couche a été lue avec la fonction *st_read* de la librairie R *sf* (version 1.0-14). Une zone carrée de 50×50 cm a pu donc être créée autour de ces centres à l'aide de la fonction *buffer* de la librairie R *terra* (version 1.7-55). Ces tampons ont été alignés selon la direction des lignes de culture, comme le montre la figure 17.

Grâce à ces tampons, la valeur moyenne de réflectance mesurée dans chaque quadrat a pu être extraite dans chaque bande. Ceci a été fait à l'aide de la fonction *extract* de la librairie *terra*, après avoir importé le raster multibande grâce à la fonction *rast*. L'opération a été répétée avec des tampons de 1×1 m, pour des raisons discutées au point 4.1, et les deux jeux de données ont été comparés à l'aide d'une analyse de la variance (ANOVA) et utilisés pour les analyses suivantes.

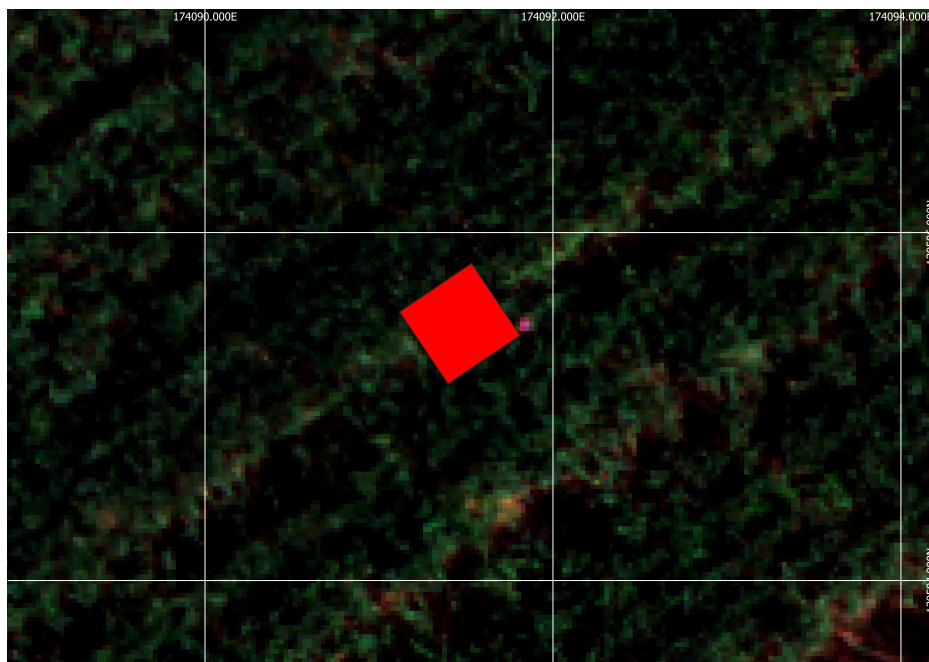


FIGURE 17 – Exemple de tampon de 50×50 cm centré sur le quadrat et utilisé pour extraire les données des images aériennes. Le repère en plastique rose, introduit au point 2.1, est identifiable à droite du quadrat.

2.3.4 Comparaison aux images terrestres

Afin d'avoir une première idée des différences entre les données acquises au sol et celles acquises par drone, les canaux RVB des deux méthodes ont été comparés. Pour ce faire, la valeur moyenne de chaque canal a été calculée pour chaque quadrat sur base des images terrestres et aériennes. Étant donné que les premières étaient enregistrées en 8 bits et les secondes en 16 bits, les valeurs extraites des images par drone ont subi une transformation racine carrée. Au total, ce sont 120 paires (6 dates \times 20 quadrats) de valeurs moyennes qui ont été comparées pour chaque canal RVB.

2.3.5 Calcul des indices de végétation

Une fois les valeurs de réflectance des cinq bandes extraites, plusieurs indices de végétation (IV), dont les formules sont reprises ci-dessous, ont été calculés. De la même manière que pour les réflectances, la valeur moyenne de l'indice dans le quadrat a été extraite à l'aide de la fonction *extract*.

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (13)$$

$$GNDVI = \frac{NIR - GREEN}{NIR + GREEN} \quad (14)$$

$$RVI = \frac{RED}{NIR} \quad (15)$$

$$DVI = NIR - RED \quad (16)$$

$$VDVI = \frac{2 \times GREEN - RED - BLUE}{2 \times GREEN + RED + BLUE} \quad (17)$$

avec *BLUE*, *GREEN*, *RED* et *NIR* les valeurs de réflectance dans les bandes bleue, verte, rouge et proche infrarouge respectivement ;

et avec *NDVI* = normalized difference vegetation index, *GNDVI* = green normalized difference vegetation index, *RVI* = ratio vegetation index, *DVI* = difference vegetation index et *VDVI* = visible difference vegetation index.

Pour chaque date et chaque quadrat, les valeurs des différents indices ont été comparées aux valeurs de pression adventice calculées sur les images terrestres. Pour ce faire, des régressions linéaires ont été réalisées et les scores R^2 ont été calculés.

2.3.6 Prédiction de la pression adventice

Une autre méthode de prédiction de la PA calculée au sol à partir des images aériennes a été utilisée. Pour chaque date, un modèle de régression linéaire multiple (RLM) a été créé, en utilisant les cinq canaux des images multibandes comme variables explicatives et la PA_{image} comme variable à expliquer. Les dates ont été séparées afin de prendre en compte les potentielles différences de conditions d'illumination et météorologiques.

3 Résultats

3.1 Images terrestres

3.1.1 Segmentation sol / végétation

Les tables 2 à 7 correspondent aux matrices de confusion obtenues par validation de chaque modèle de segmentation sol / végétation. Au vu des valeurs d'exactitude obtenues, tous les modèles ont été jugés comme aptes à correctement différencier les superpixels de sol et ceux de végétation afin de créer le masque binaire de végétation de chaque image de quadrat.

TABLE 2 – Matrice de confusion pour le jeu de validation de la segmentation sol / végétation pour le 08/05/2024. Exactitude = 99,10%

		Classe prédite	
		Sol	Végétation
Classe réelle	Sol	30,33%	0,18%
	Végétation	0,72%	68,77%

TABLE 3 – Matrice de confusion pour le jeu de validation de la segmentation sol / végétation pour le 14/05/2024. Exactitude = 99,00%

		Classe prédite	
		Sol	Végétation
Classe réelle	Sol	17,89%	0,35%
	Végétation	0,64%	81,11%

TABLE 4 – Matrice de confusion pour le jeu de validation de la segmentation sol / végétation pour le 23/05/2024. Exactitude = 99,04%

		Classe prédite	
		Sol	Végétation
Classe réelle	Sol	25,51%	0,34%
	Végétation	0,62%	73,53%

TABLE 5 – Matrice de confusion pour le jeu de validation de la segmentation sol / végétation pour le 30/05/2024. Exactitude = 99,40%

		Classe prédite	
		Sol	Végétation
Classe réelle	Sol	23,34%	0,24%
	Végétation	0,36%	76,06%

TABLE 6 – Matrice de confusion pour le jeu de validation de la segmentation sol / végétation pour le 06/06/2024. Exactitude = 99,43%

		Classe prédite	
		Sol	Végétation
Classe réelle	Sol	20,70%	0,53%
	Végétation	0,03%	78,73%

TABLE 7 – Matrice de confusion pour le jeu de validation de la segmentation sol / végétation pour le 13/06/2024. Exactitude = 98,79%

		Classe prédite	
		Sol	Végétation
Classe réelle	Sol	23,10%	0,43%
	Végétation	0,78%	75,69%

3.1.2 Différenciation culture / adventices

Les tables 8 à 11 et 12 à 15 correspondent aux matrices de confusion obtenues par validation des différents modèles testés pour la pré- et la post-floraison, respectivement. Pour chacun de ces deux groupes de modèles, le modèle à 8 variables a été conservé, présentant une exactitude de 50,50% pour le modèle pré-floraison (table 9) et de 72,29% pour celui post-floraison (table 13). Dans les deux cas, ce sont les variables suivantes qui ont été sélectionnées par la RFE : moyennes des canaux RVB et TSV, homogénéité et énergie.

TABLE 8 – Matrices de confusion pour le jeu de validation de la différenciation culture / adventices pour le modèle pré-floraison avec les 6 variables sélectionnées par RFE : R, B, T, S, V, Homogénéité.

		Classe prédite			
		TRZAX	CIRAR	MATCH (a)	SINAR (a)
Classe réelle	TRZAX	49	0	1	0
	CIRAR	46	0	4	0
	MATCH (a)	3	0	47	0
	SINAR (a)	50	0	0	0

TP + TN = 100			
		Classe prédite	
		Culture	Adventice
Classe réelle	Culture	49	1
	Adventice	99	51

TABLE 9 – Matrices de confusion pour le jeu de validation de la différenciation culture / adventices pour le modèle pré-floraison avec les 8 variables sélectionnées par RFE : R, V, B, T, S, V, Homogénéité, Énergie.

		Classe prédite			
		TRZAX	CIRAR	MATCH (a)	SINAR (a)
Classe réelle	TRZAX	50	0	0	0
	CIRAR	45	0	5	0
	MATCH (a)	4	0	46	0
	SINAR (a)	50	0	0	0

TP + TN = 101			
		Classe prédite	
		Culture	Adventice
Classe réelle	Culture	50	0
	Adventice	99	51

TABLE 10 – Matrices de confusion pour le jeu de validation de la différenciation culture / adventices pour le modèle pré-floraison avec les 10 variables sélectionnées par RFE : R, V, B, T, S, V, Homogénéité, Énergie, Corrélation, ASM.

		Classe prédite			
		TRZAX	CIRAR	MATCH (a)	SINAR (a)
Classe réelle	TRZAX	49	0	1	0
	CIRAR	46	0	4	0
	MATCH (a)	4	0	46	0
	SINAR (a)	50	0	0	0

TP + TN = 99			
		Classe prédite	
		Culture	Adventice
Classe réelle	Culture	49	1
	Adventice	100	50

TABLE 11 – Matrices de confusion pour le jeu de validation de la différenciation culture / adventices pour le modèle pré-floraison avec les 12 variables : R, V, B, T, S, V, Homogénéité, Énergie, Corrélation, ASM, Dissimilarité, Contraste.

		Classe prédite			
		TRZAX	CIRAR	MATCH (a)	SINAR (a)
Classe réelle	TRZAX	50	0	0	0
	CIRAR	50	0	0	0
	MATCH (a)	46	0	4	0
	SINAR (a)	50	0	0	0

		TP + TN = 54	
		Classe prédite	
		Culture	Adventice
Classe réelle	Culture	50	0
	Adventice	146	4

3 RÉSULTATS

TABLE 12 – Matrices de confusion pour le jeu de validation de la différenciation culture / adventices pour le modèle post-floraison avec les 6 variables sélectionnées par RFE : R, V, T, S, V, Homogénéité.

		Classe prédite						
		TRZAX	CIRAR	MATCH (a)	MATCH (b)	PAPRH	SINAR (a)	SINAR (b)
Classe réelle	TRZAX	46	3	1	0	0	0	0
	CIRAR	43	7	0	0	0	0	0
	MATCH (a)	2	5	43	0	0	0	0
	MATCH (b)	4	0	0	42	0	0	4
	PAPRH	0	0	0	0	50	0	0
	SINAR (a)	35	11	4	0	0	0	0
	SINAR (b)	11	3	3	13	0	0	20

		TP + TN = 251	
		Classe prédite	
		Culture	Adventice
Classe réelle	Culture	46	4
	Adventice	95	205

TABLE 13 – Matrices de confusion pour le jeu de validation de la différenciation culture / adventices pour le modèle post-floraison avec les 8 variables sélectionnées par RFE : R, V, B, T, S, V, Homogénéité, Énergie.

		Classe prédite						
		TRZAX	CIRAR	MATCH (a)	MATCH (b)	PAPRH	SINAR (a)	SINAR (b)
Classe réelle	TRZAX	46	2	2	0	0	0	0
	CIRAR	43	7	0	0	0	0	0
	MATCH (a)	2	4	44	0	0	0	0
	MATCH (b)	0	1	0	45	0	0	4
	PAPRH	0	1	0	0	49	0	0
	SINAR (a)	34	13	3	0	0	0	0
	SINAR (b)	14	2	3	10	0	0	21

		TP + TN = 253	
		Classe prédite	
		Culture	Adventice
Classe réelle	Culture	46	4
	Adventice	93	207

TABLE 14 – Matrices de confusion pour le jeu de validation de la différenciation culture / adventices pour le modèle post-floraison avec les 10 variables sélectionnées par RFE : R, V, B, T, S, V, Homogénéité, Énergie, Corrélation, ASM.

		Classe prédite						
		TRZAX	CIRAR	MATCH (a)	MATCH (b)	PAPRH	SINAR (a)	SINAR (b)
Classe réelle	TRZAX	47	2	1	0	0	0	0
	CIRAR	43	7	0	0	0	0	0
	MATCH (a)	2	4	44	0	0	0	0
	MATCH (b)	2	1	0	42	0	0	5
	PAPRH	0	1	1	0	47	0	1
	SINAR (a)	34	13	3	0	0	0	0
	SINAR (b)	15	5	3	6	0	0	21

		TP + TN = 251	
		Classe prédite	
		Culture	Adventice
Classe réelle	Culture	47	3
	Adventice	96	204

TABLE 15 – Matrices de confusion pour le jeu de validation de la différenciation culture / adventices pour le modèle post-floraison avec les 12 variables sélectionnées par RFE : R, V, B, T, S, V, Homogénéité, Énergie, Corrélation, ASM, Dissimilarité, Contraste.

		Classe prédite						
		TRZAX	CIRAR	MATCH (a)	MATCH (b)	PAPRH	SINAR (a)	SINAR (b)
Classe réelle	TRZAX	50	0	0	0	0	0	0
	CIRAR	49	0	1	0	0	0	0
	MATCH (a)	35	0	15	0	0	0	0
	MATCH (b)	49	0	1	0	0	0	0
	PAPRH	48	0	2	0	0	0	0
	SINAR (a)	44	0	6	0	0	0	0
	SINAR (b)	46	0	4	0	0	0	0

		TP + TN = 79	
		Classe prédite	
		Culture	Adventice
Classe réelle	Culture	50	0
	Adventice	271	29

3.1.3 Comparaison aux données terrain

La figure 18 illustre les résultats des comparaisons entre la biomasse sèche mesurée en fin d'expérimentation et la fraction de couvert végétale extraite des images du 13/06/2024, ce pour chaque espèce. Les coefficients de détermination R^2 de calibration de chaque régression linéaire sont indiqués en légende.

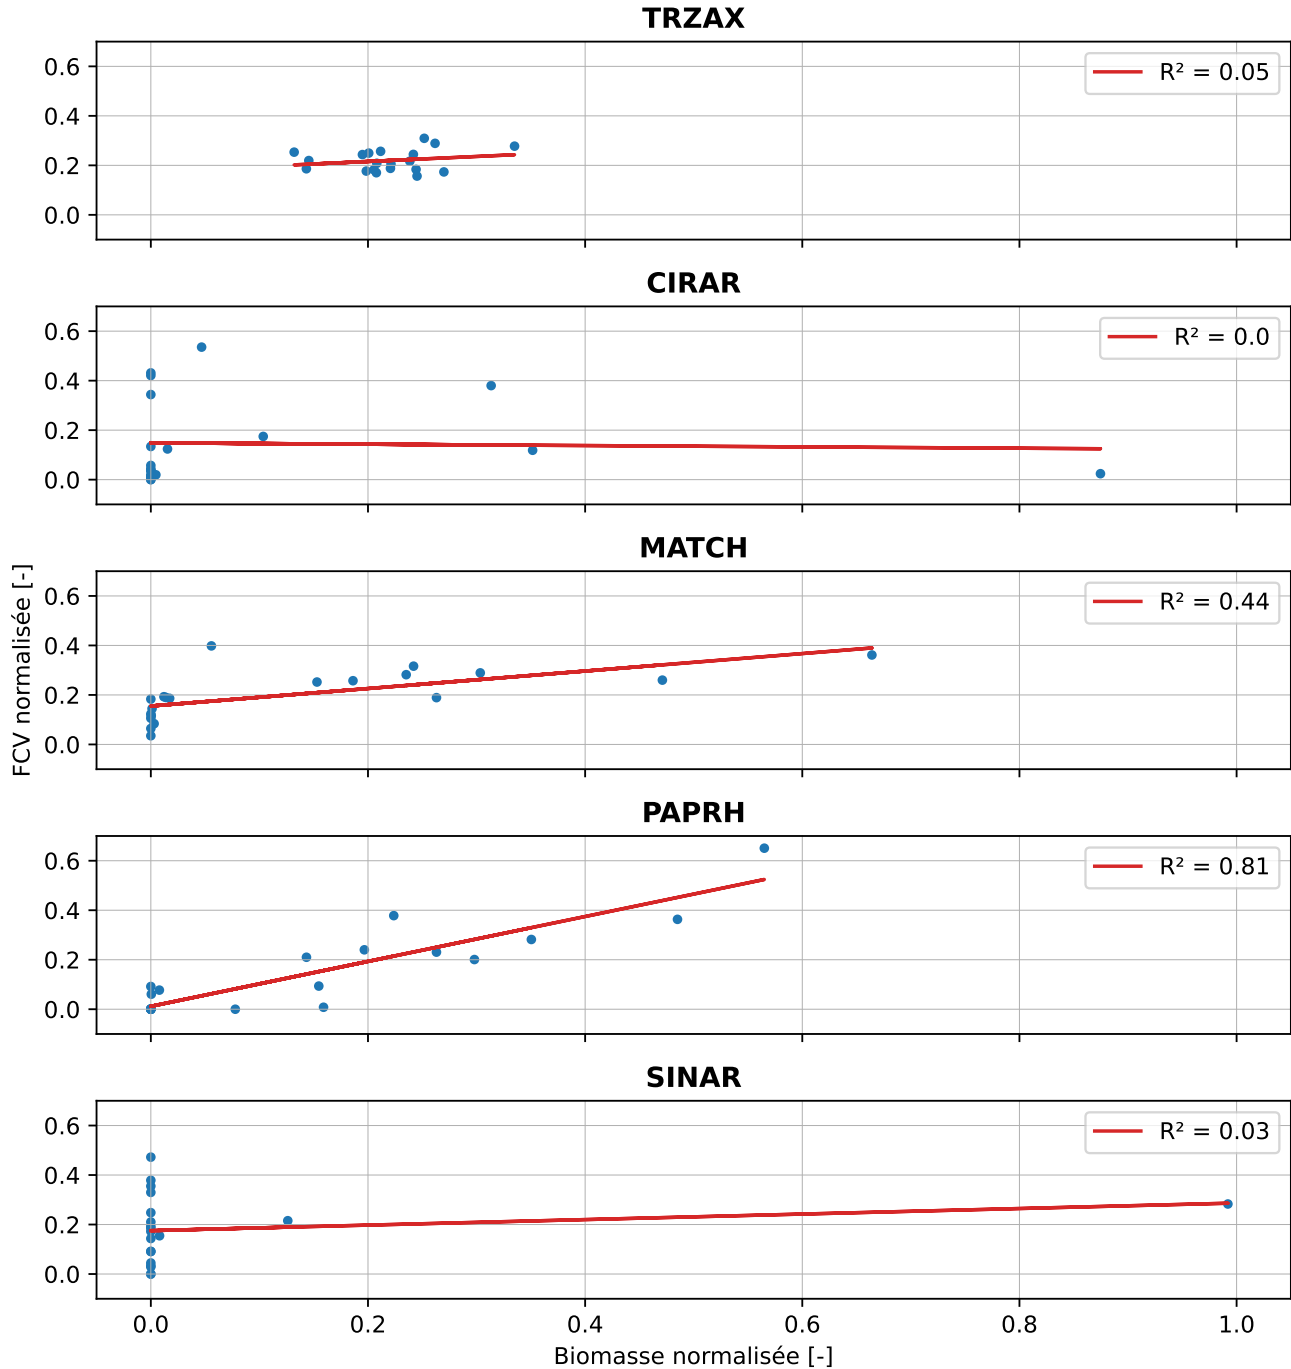


FIGURE 18 – Résultats des régressions linéaires réalisées pour comparer la biomasse de chaque espèce dans chaque quadrat à sa FCV correspondante.

La figure 19 illustre le résultat de la comparaison entre le rapport des biomasses des adventices et du froment ($PA_{biomasse}$) et celui de leurs FCV respectives (PA_{image}). Comme pour la figure précédente, la PA_{image} présentée ici correspond à celle mesurée sur les images du 13/06/2024 des 20 quadrats suivis. Le coefficient de détermination R^2 de calibration de la régression linéaire est indiqué en légende.




FIGURE 19 – Résultat de la régression linéaire réalisée pour comparer la PA_{image} et la $PA_{biomasse}$.

3.1.4 Caractérisation de la dynamique de compétition froment / adventices

Les figures 20 à 23 présentent les évolutions temporelles des FCV du froment et des adventices ainsi que l'évolution de la pression adventice dans chaque quadrat. Les résultats sont présentés en parallèle afin de mieux comprendre comment varie la PA.

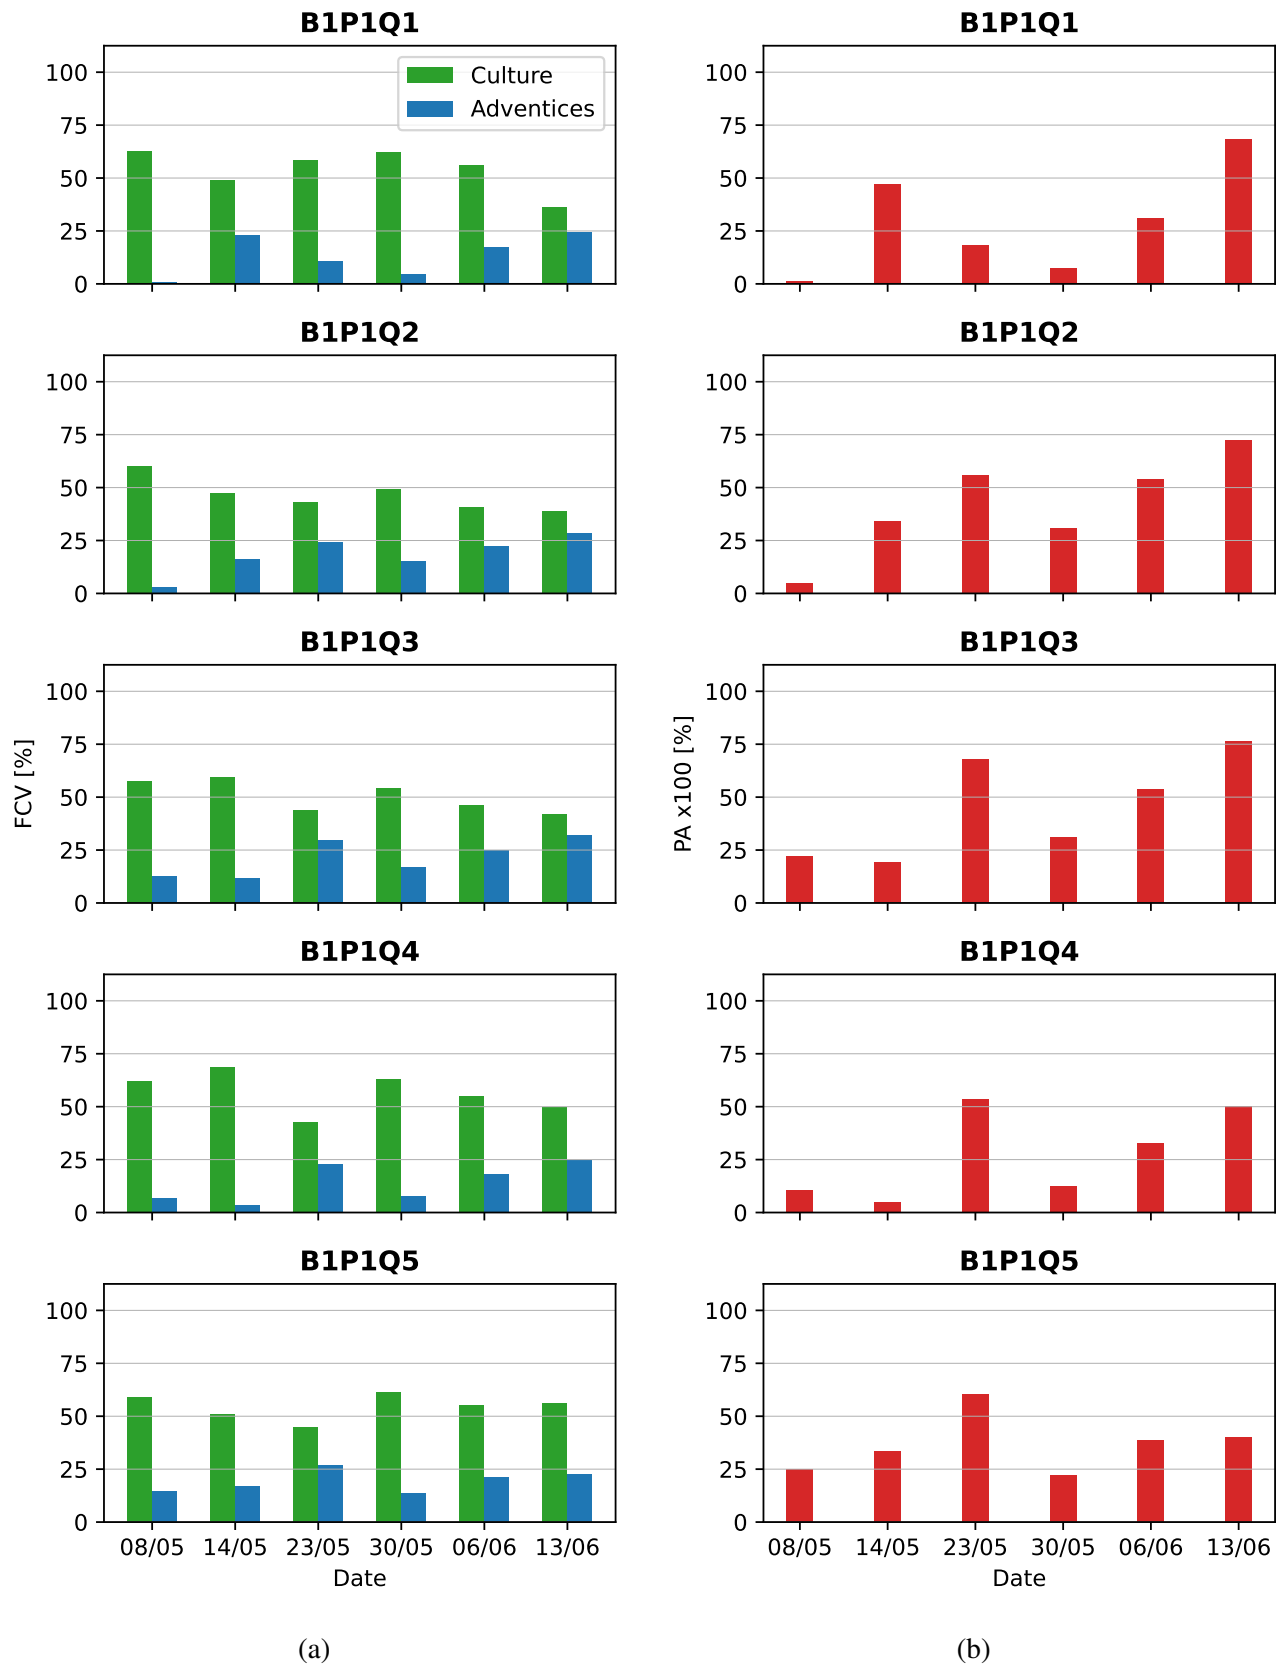


FIGURE 20 – Évolution des FCV du froment et des adventices (a) et de la pression adventice (b) sur les quadrats de la parcelle 1 au cours de la saison.




FIGURE 21 – Évolution des FCV du froment et des adventices (a) et de la pression adventice (b) sur les quadrats de la parcelle 2 au cours de la saison.

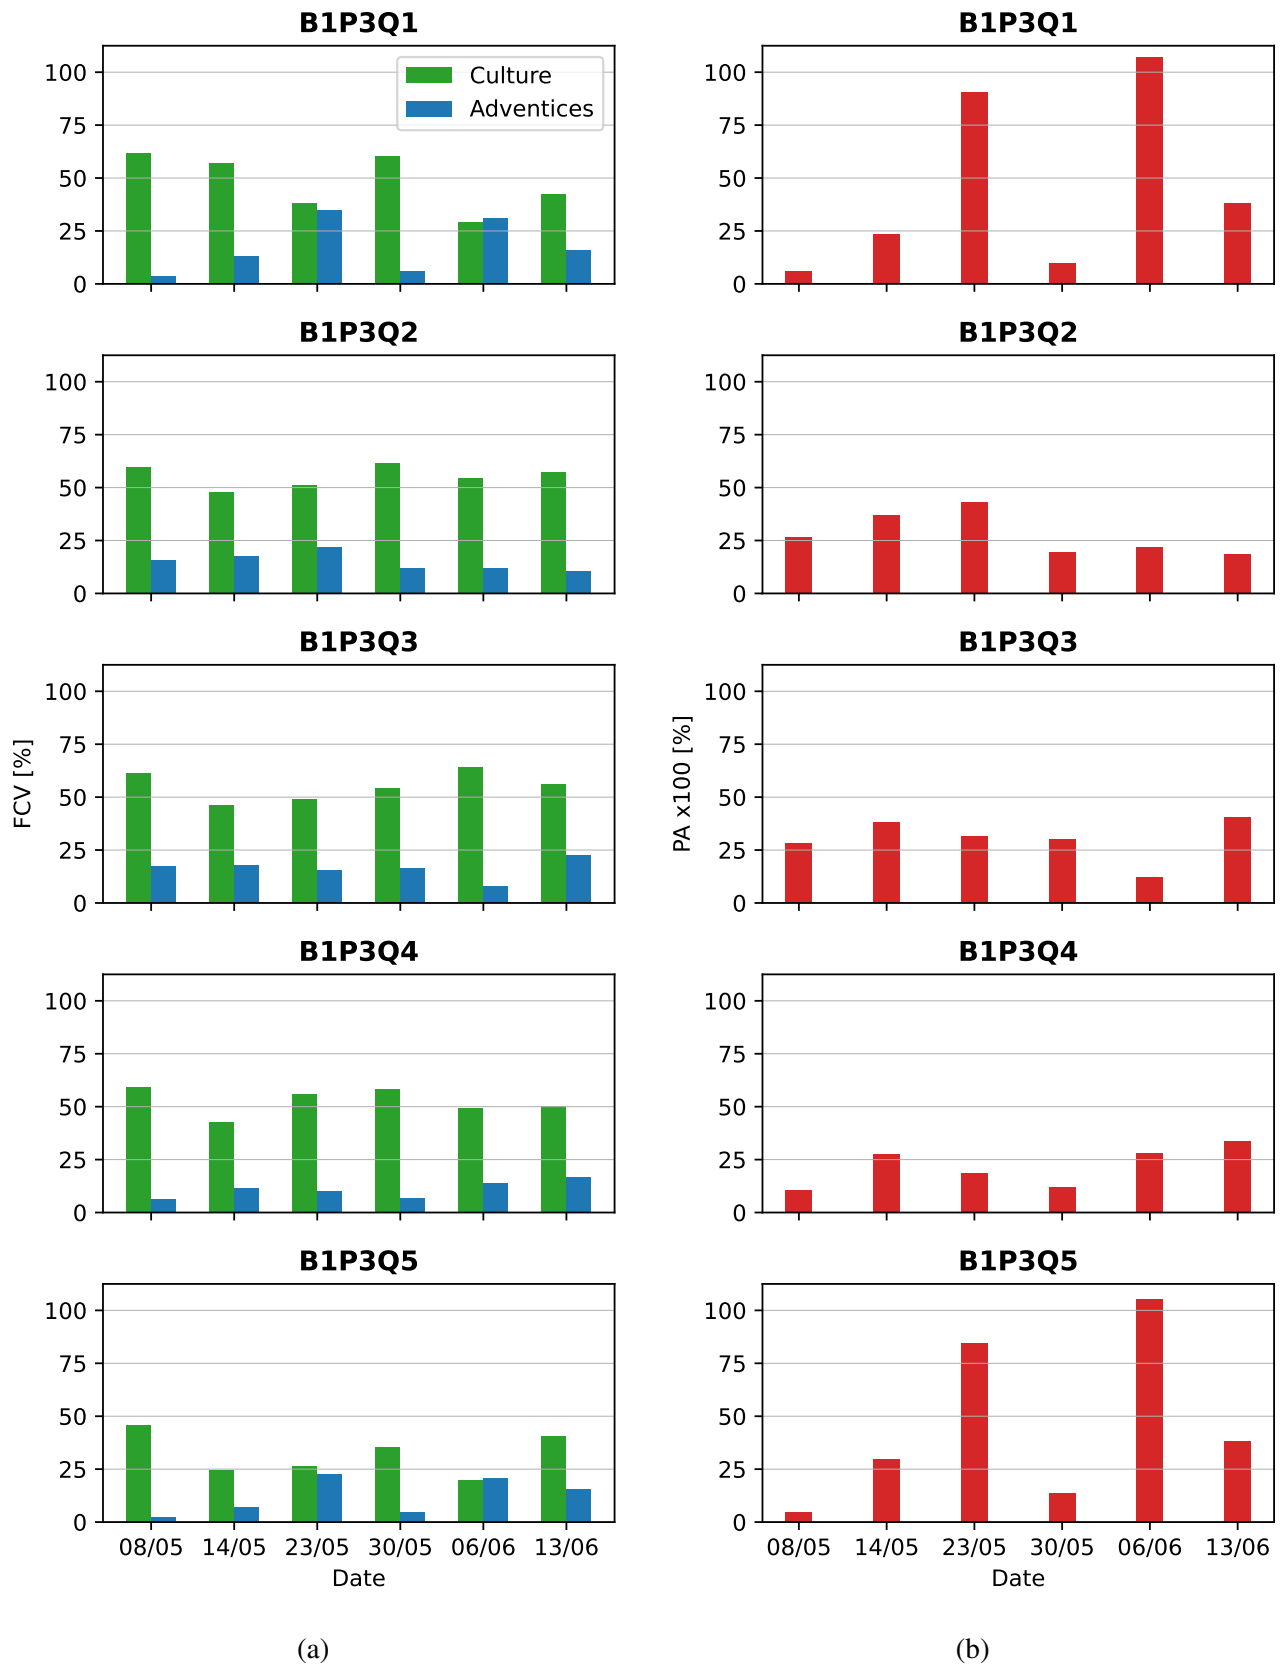


FIGURE 22 – Évolution des FCV du froment et des adventices (a) et de la pression adventice (b) sur les quadrats de la parcelle 3 au cours de la saison.

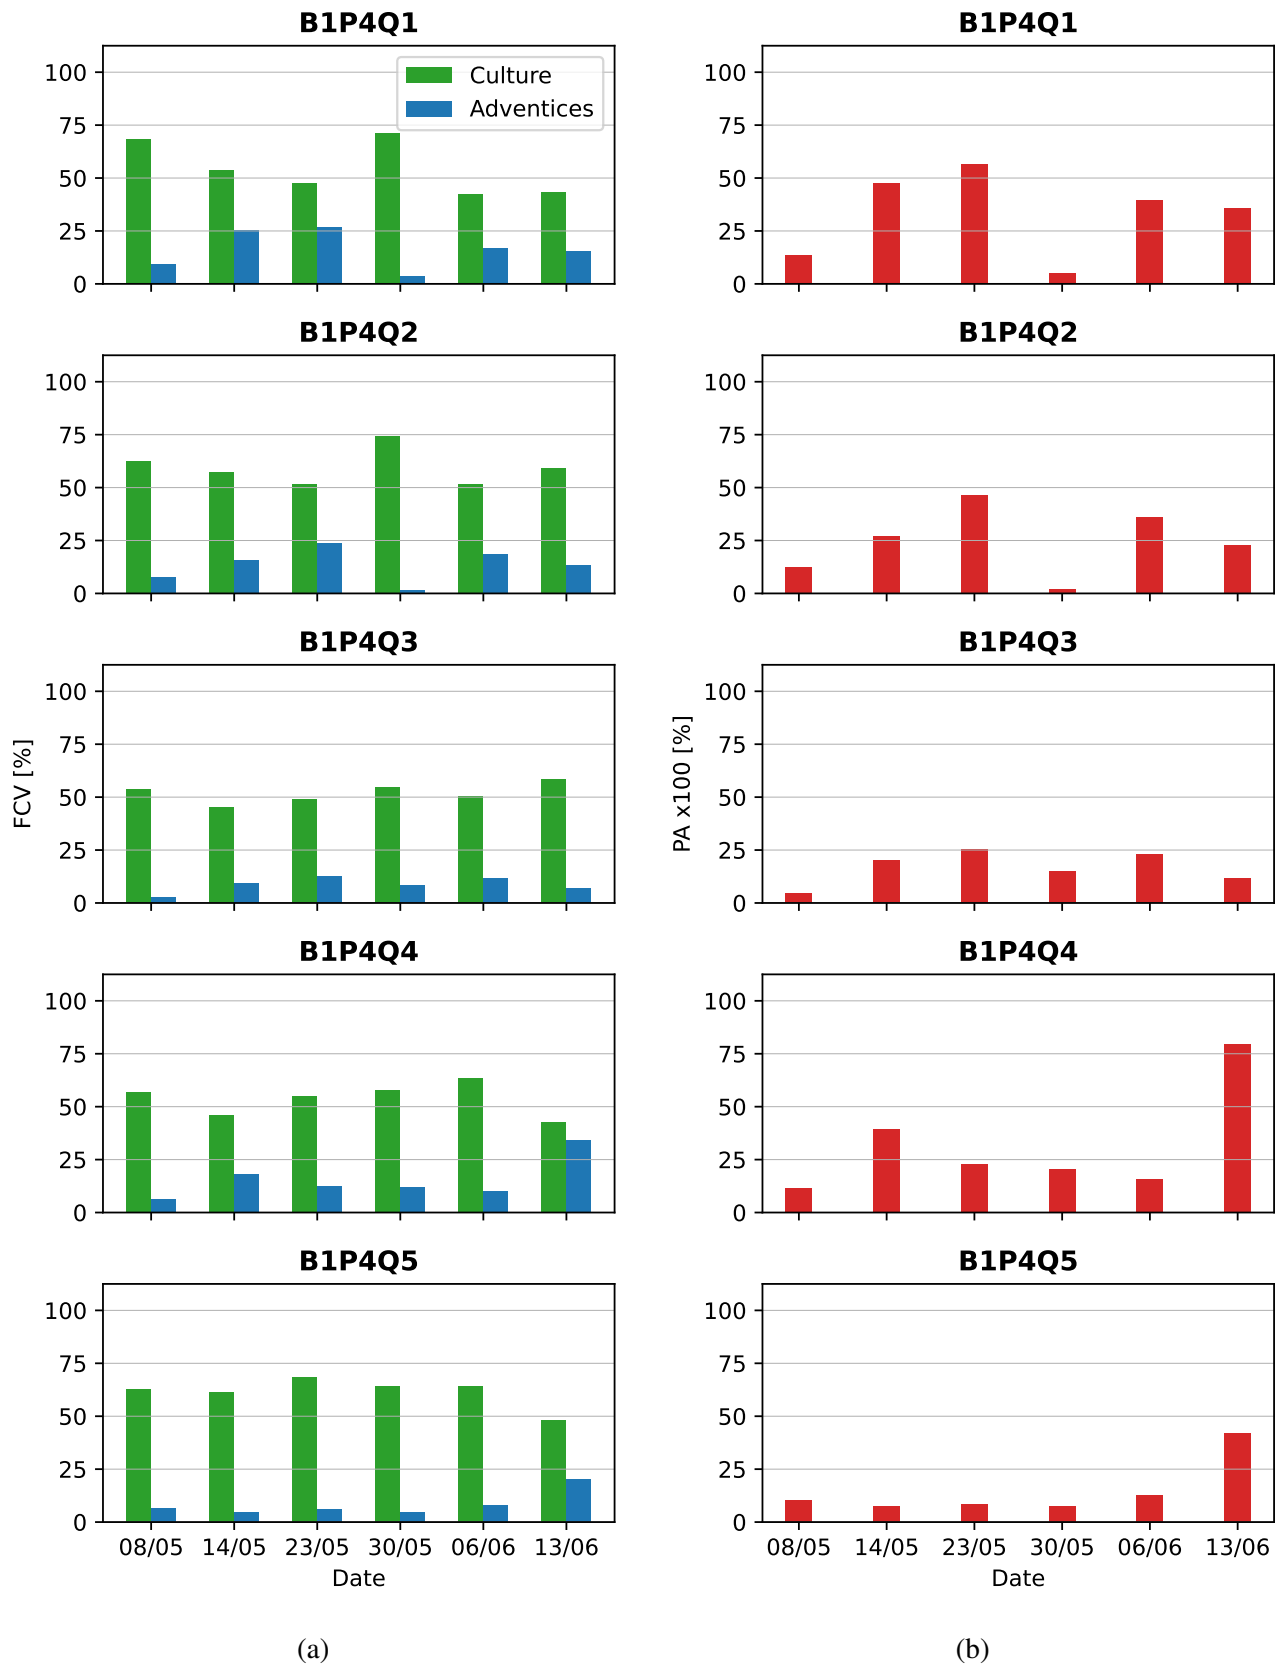


FIGURE 23 – Évolution des FCV du froment et des adventices (a) et de la pression adventice (b) sur les quadrats de la parcelle 4 au cours de la saison.

3.2 Images aériennes

3.2.1 Comparaison des tailles des quadrats extraits

La figure 24 compare les données extraites des quadrats selon la taille de ces derniers. La droite $y = x$ est tracée comme référence. Les valeurs des coefficients de détermination R^2 sont indiquées en légende pour chaque bande. La table 16 montre que les moyennes des deux extractions des rasters sont égales pour chaque bande selon l'ANOVA, avec des p-valeurs supérieures à 0,05. Néanmoins, les analyses suivantes ont tout de même été réalisées avec les deux tailles de quadrats étant donné que le proche infrarouge (NIR) est utilisé dans quatre des IV calculés et qu'il s'agit de la bande avec le plus petit R^2 .





FIGURE 24 – Comparaison des réflectances moyennes extraites pour chaque bande des quadrats de 50×50 cm avec celles extraites des quadrats de 100×100 cm.

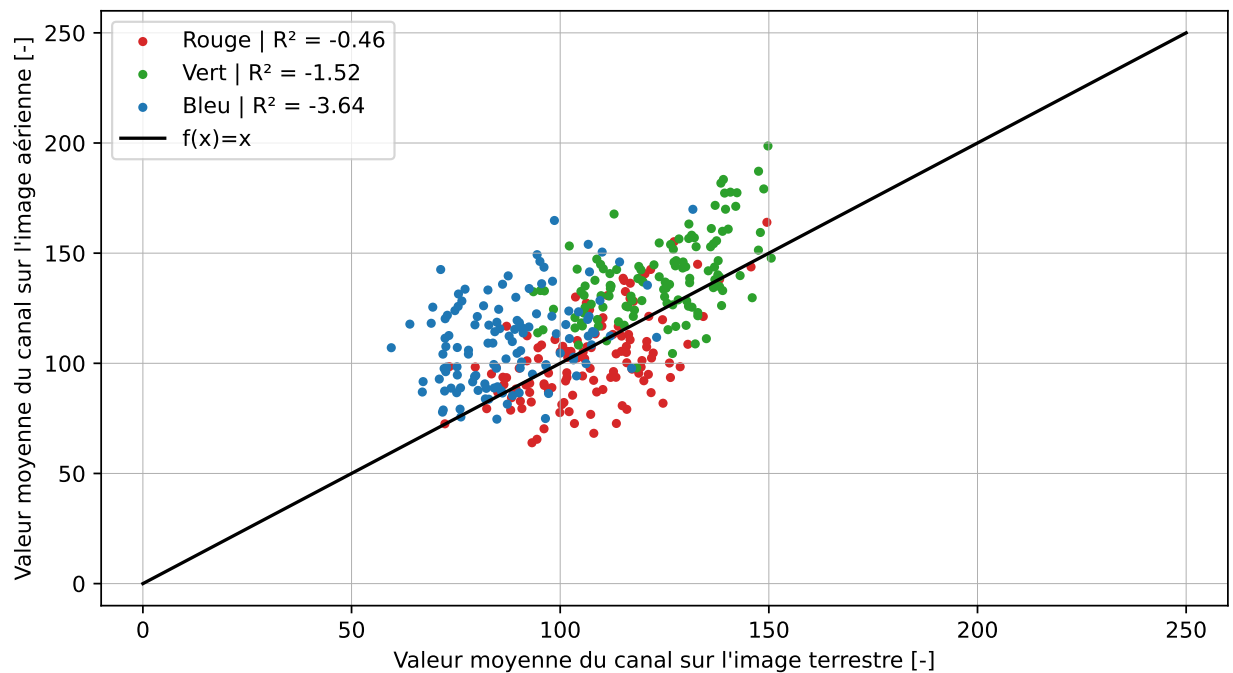
TABLE 16 – Résultats des ANOVA réalisées pour comparer les valeurs moyennes extraites pour chaque canal des deux tailles de quadrats.

	F statistic	p-value
Bleu	0,211183	0,646261
Vert	0,310818	0,577703
Rouge	0,336875	0,562188
Red-edge	0,673126	0,412785
Proche infrarouge	0,596756	0,440585

3.2.2 Comparaison aux images terrestres



(a)



(b)

FIGURE 25 – Comparaison des valeurs de réflectances mesurées sur les images au sol avec celles mesurées sur les images aériennes (mises sous racine carrée) pour les canaux RVB. (a) : Quadrats de 50×50 cm. (b) : Quadrats de 100×100 cm.

Les figures 25a et 25b comparent les valeurs moyennes des canaux RVB mesurées sur les quadrats à partir des images terrestres d'une part et aériennes de l'autre. Comme expliqué au point 2.3.4, les valeurs de réflectance pour les canaux RVB extraites des orthomosaïques ont été mises sous racine carrée. En effet, alors que les images aériennes étaient enregistrées en 16 bits, les terrestres ne l'étaient qu'en 8 bits. Cette transformation a permis une comparaison plus visuelle. Une analyse rapide permet de voir que dans les deux cas, les valeurs dans le bleu et le vert ont tendance à être plus élevées sur les images aériennes, tandis que les valeurs dans le rouge sont plus faibles. Les deux jeux de données sont mieux corrélés avec les données extraites des quadrats de 100 cm de côté, comme le montrent les R^2 en légende.

3.2.3 Calcul des indices de végétation

Les figures 26 à 30 présentent les résultats des régressions linéaires réalisées entre la PA_{image} mesurée sur les images terrestres et les valeurs moyennes des indices de végétation extraits des quadrats de 50×50 cm sur les orthomosaïques. Les figures 31 à 35 présentent ces mêmes résultats mais pour les quadrats de 100×100 cm. Les coefficients de détermination R^2 de calibration sont à chaque fois indiqués en légende. Les valeurs pour les 6 dates sont différenciées par différentes couleurs, mais les régressions ont été réalisées sur l'ensemble des données.

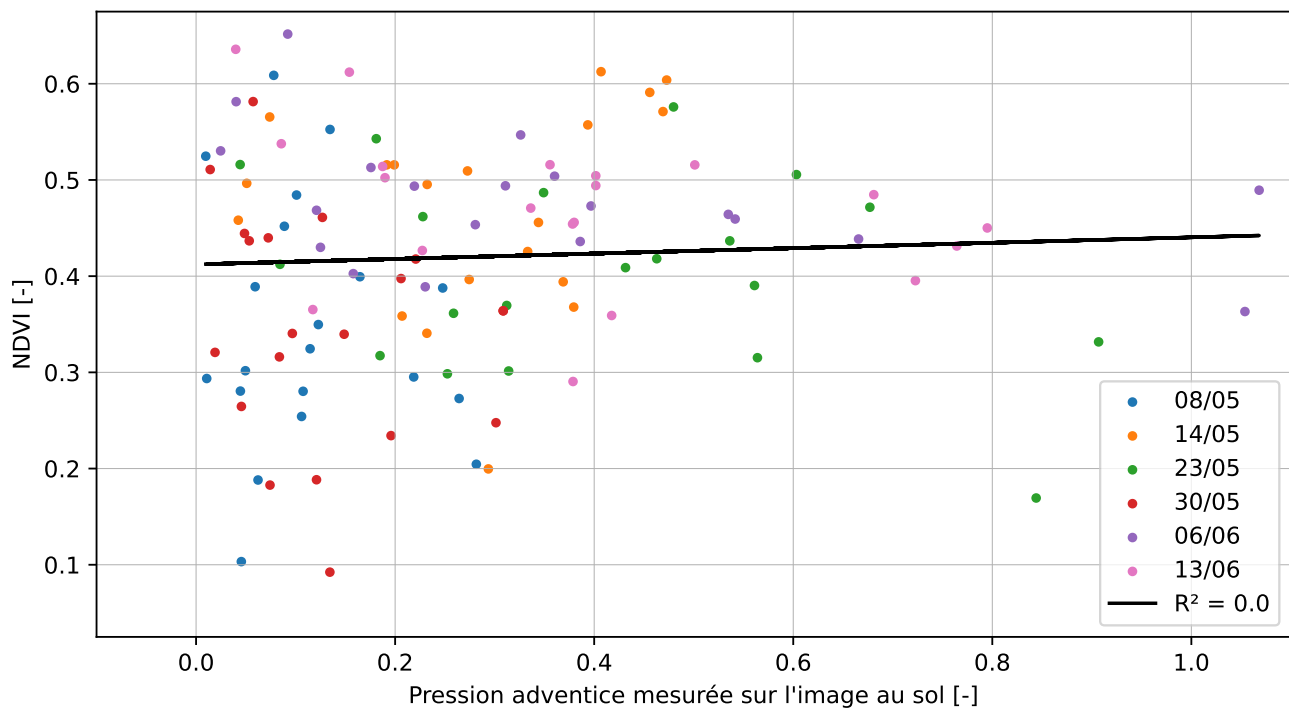


FIGURE 26 – Résultat de la régression linéaire réalisée pour comparer la PA_{image} au NDVI extrait des quadrats de 50×50 cm.




FIGURE 27 – Résultat de la régression linéaire réalisée pour comparer la PA_{image} au GNDVI extrait des quadrats de 50×50 cm.

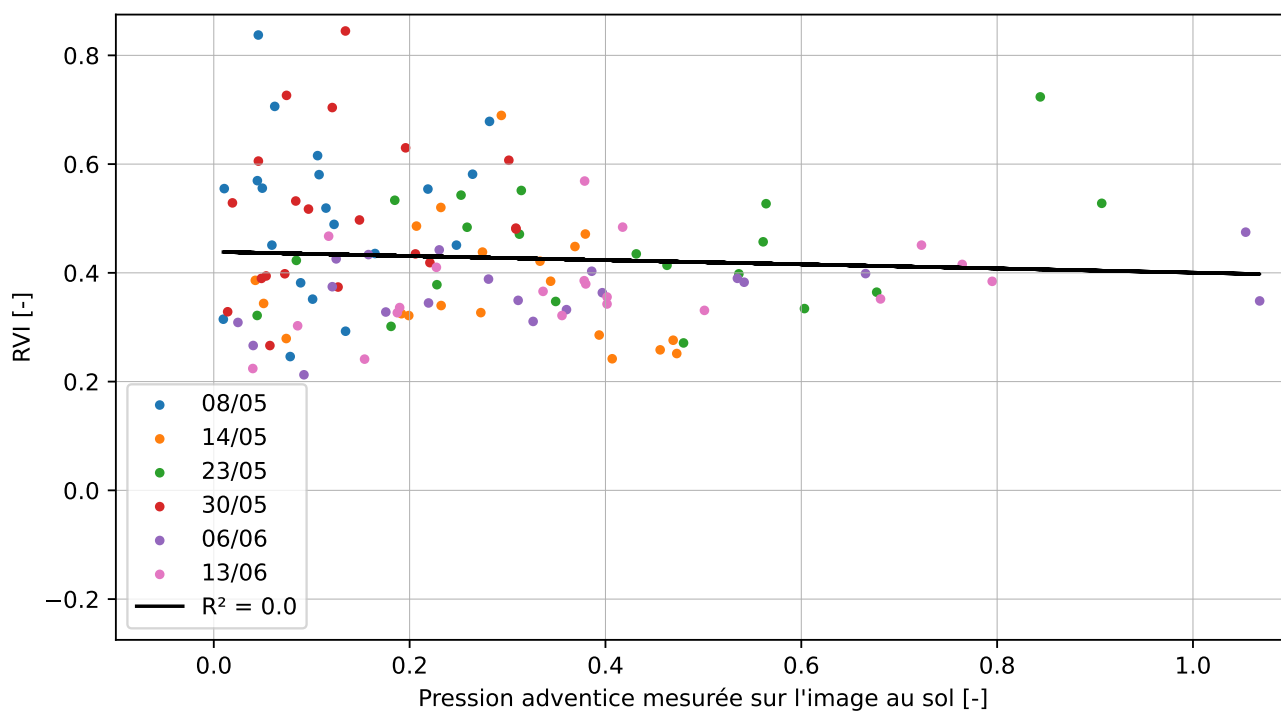


FIGURE 28 – Résultat de la régression linéaire réalisée pour comparer la PA_{image} au RVI extrait des quadrats de 50×50 cm.

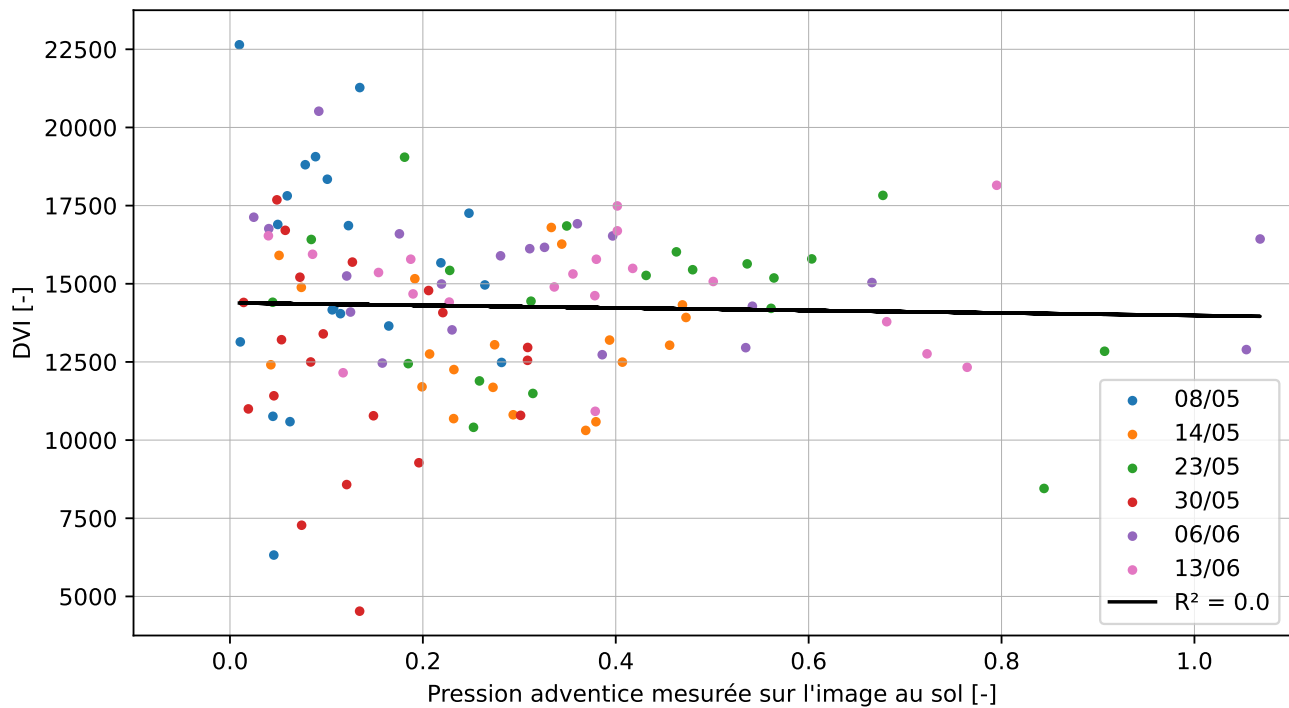


FIGURE 29 – Résultat de la régression linéaire réalisée pour comparer la PA_{image} au DVI extrait des quadrats de 50×50 cm.




FIGURE 30 – Résultat de la régression linéaire réalisée pour comparer la PA_{image} au VDVI extrait des quadrats de 50×50 cm.

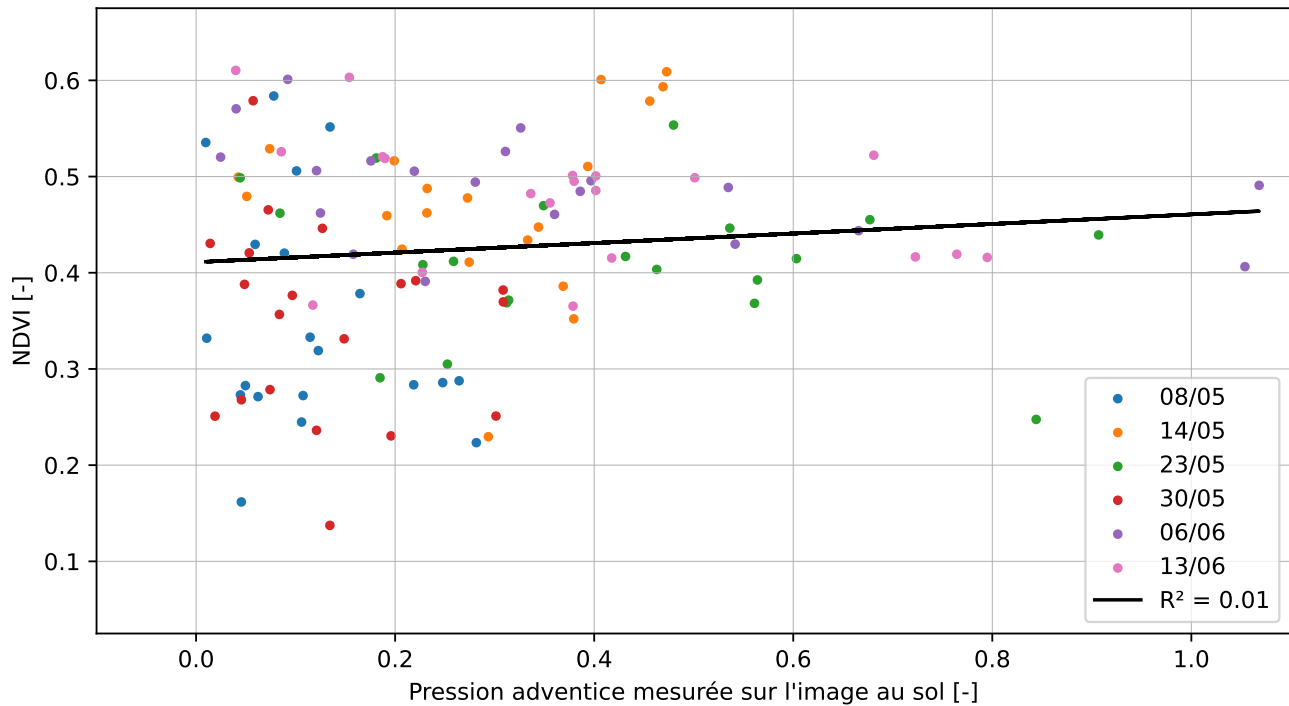


FIGURE 31 – Résultat de la régression linéaire réalisée pour comparer la PA_{image} au NDVI extrait des quadrats de 100×100 cm.




FIGURE 32 – Résultat de la régression linéaire réalisée pour comparer la PA_{image} au GNDVI extrait des quadrats de 100×100 cm.




FIGURE 33 – Résultat de la régression linéaire réalisée pour comparer la PA_{image} au RVI extrait des quadrats de 100×100 cm.




FIGURE 34 – Résultat de la régression linéaire réalisée pour comparer la PA_{image} au DVI extrait des quadrats de 100×100 cm.

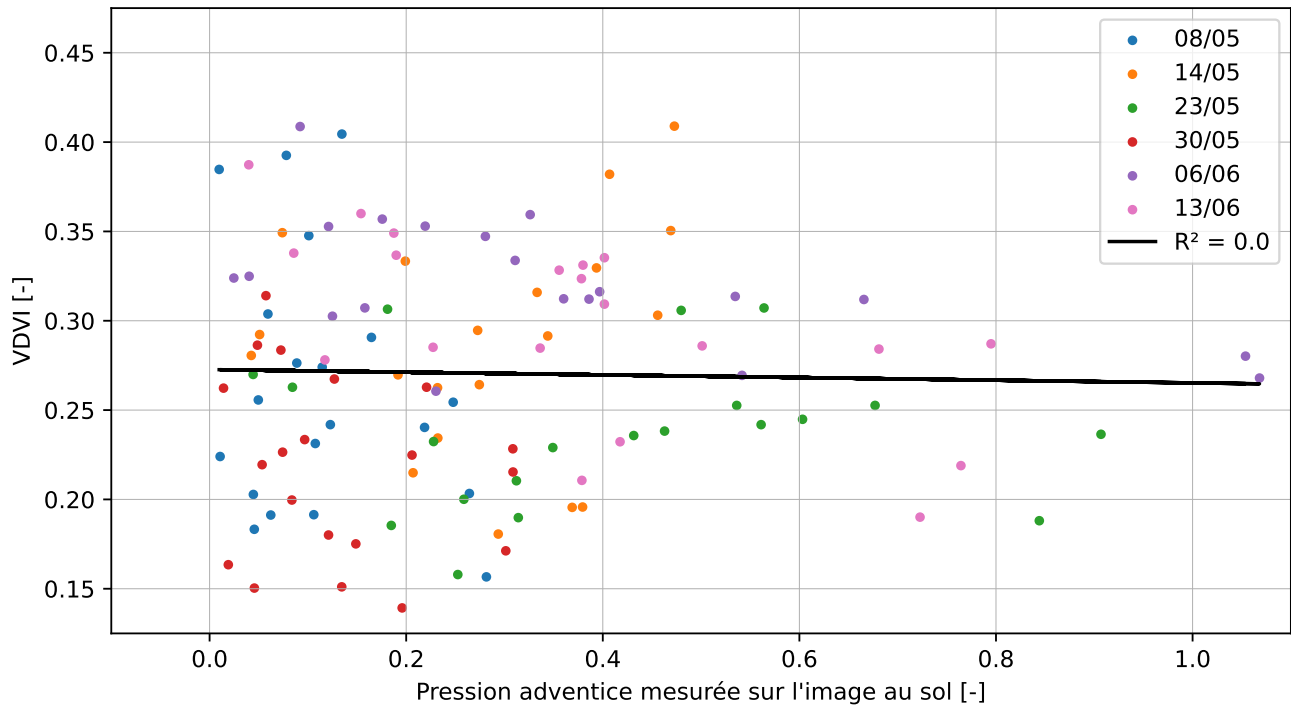


FIGURE 35 – Résultat de la régression linéaire réalisée pour comparer la PA_{image} au VDMI extrait des quadrats de 100×100 cm.

3.2.4 Prédiction de la pression adventice

La table 17 présente les résultats des RLM réalisées pour prédire la PA_{image} dans chaque quadrat, à partir des données extraites des rasters multibandes. Pour chaque date, les coefficients de la régression sont renseignés, ainsi que le R^2 de calibration. Ils sont indiqués pour les données extraites des quadrats de 50×50 cm sur les rasters ainsi que pour celles extraites des quadrats de 100×100 cm.

TABLE 17 – Résultat des RLM réalisées pour prédire la PA_{image} dans chaque quadrat à partir des données extraites des rasters multibandes.

		Quadrats de 50×50 cm						
		f(x=0)	xR	xG	xB	xFR	xNR	R ²
Date	08-05-24	-3,76E-01	8,45E-06	-8,54E-06	8,63E-07	2,05E-06	1,40E-05	0,1993
	14-05-24	9,90E-02	5,07E-05	-7,23E-07	-4,48E-05	-1,48E-05	1,76E-05	0,3446
	23-05-24	2,19E-02	5,56E-05	-1,12E-05	-3,15E-05	1,30E-05	2,58E-06	0,3064
	30-05-24	1,93E-01	8,83E-06	-3,02E-05	7,77E-06	2,32E-05	-6,95E-06	0,2014
	06-06-24	-1,26E+00	7,85E-05	-3,91E-05	5,06E-05	5,36E+05	-4,58E-06	0,2349
	13-06-24	-1,52E+00	1,88E-04	8,41E-06	-1,57E-04	-1,84E-05	4,86E-05	0,4562
		Quadrats de 100×100 cm						
		f(x=0)	xR	xG	xB	xFR	xNR	R ²
Date	08-05-24	-3,05E-01	1,59E-05	-7,84E-06	-4,44E-06	1,55E-06	1,13E-05	0,133
	14-05-24	-6,06E-01	7,34E-05	-3,35E-05	-4,59E-05	7,63E-06	3,63E-05	0,5123
	23-05-24	1,53E+00	5,04E-05	9,64E-06	-4,09E-05	-1,44E-05	-2,40E-05	0,2744
	30-05-24	-2,49E-01	1,49E-05	-4,07E-05	1,36E-05	3,37E-05	-1,30E-07	0,2458
	06-06-24	2,85E+00	2,16E-05	-1,00E-04	1,04E-04	-1,30E-05	-4,59E-05	0,4989
	13-06-24	-6,75E-01	1,58E-04	-5,47E-05	-4,82E-05	-8,09E-06	2,93E-05	0,5205

4 Discussion

4.1 Limites de l'étude

Avant de discuter des résultats en eux-mêmes, il est important de décrire les limites de cette étude qui pourraient être à l'origine d'erreurs et donc influencer la qualité des résultats obtenus. Les points suivants détaillent ces potentielles sources d'erreurs. Les problèmes rencontrés et les changements apportés au protocole d'origine sont également expliqués.

4.1.1 Acquisition des images

Images terrestres

Comme expliqué au point 2.1, les quadrats suivis dans cette étude ont été géolocalisés en début d'expérimentation afin de pouvoir les retrouver tout au long de la saison. Durant les sorties d'acquisition d'images, une station GNSS Reach RS+ était utilisée pour les retrouver, avec l'aide supplémentaire des piquets en plastique (figure 4) et des tuteurs placés en mi-saison (figure 5). Malgré cela, il est difficile d'affirmer avec certitude que les images acquises à chaque sortie représentaient les quadrats de manière identique et ce, pour plusieurs raisons.

Tout d'abord, les piquets en plastique marquant les quadrats placés en début de saison l'ont été à l'aide d'un cadre carré en bois de 50 cm de côté (figure 4). Seulement, afin d'éviter qu'ils ne soient arrachés lors du désherbage mécanique, ces piquets étaient légèrement déplacés afin d'intégrer les lignes de culture. Les zones ainsi créées ne correspondaient donc pas exactement à un quadrat de 50 × 50 cm. Pour les deux relevés effectués par Nina Leclef, cela ne posait pas de problème car le cadre en bois pouvait être replacé pour assurer l'identification et le comptage des plantes présentes dans la bonne zone. Mais pour les acquisitions d'images avec la perche en aluminium (figure 6), il était impossible de replacer ce cadre pour chaque photo. La perche était donc placée le plus correctement possible pour que la caméra soit positionnée au-dessus du centre du quadrat, mais de légères erreurs de placement ont probablement dû être commises. De plus, une fois le froment arrivé à un certain stade, il gênait le positionnement du pied de la perche, obligeant ce dernier à être inséré entre les lignes de culture.

Ensuite, pour des raisons d'organisation, il était presque impossible d'effectuer l'acquisition des images terrestres à la même heure pour chaque date. Les sorties pouvaient donc se faire au matin ou dans l'après-midi, ce qui a eu un impact sur le placement de la perche par rapport au quadrat. En effet, l'heure de l'acquisition des images changeait la projection de l'ombre de la perche. Il fallait donc la placer dans un sens ou dans l'autre en fonction des conditions pour éviter que l'ombre ne se retrouve sur l'image. Cela a sûrement contribué à une certaine inhomogénéité de la prise de vue de chaque quadrat au cours de la saison.

Un autre problème source d'erreurs est le placement de la caméra à une hauteur d'un mètre au-dessus de la canopée. Pour des raisons logistiques, il n'était pas possible d'adapter la hauteur du porte-à-faux fixant la caméra à chaque quadrat. En effet, cela aurait pris bien trop de temps, surtout pour les sorties effectuées seul lors desquelles il aurait alors fallu abandonner le PC et poser la perche dans le champ pour l'adapter. Une hauteur moyenne était donc calculée, entraînant des erreurs lors de la récupération de la zone d'intérêt : si le haut de la canopée d'un quadrat était significativement plus bas que les autres, la zone extraite au point 2.2.2 couvrait une surface plus grande que 50 × 50 cm, comme le montre la figure 36b.

Enfin, les zones de végétation moins denses pouvaient révéler des éléments censés ne pas apparaître sur les images. Parmi eux sont comptés les piquets en plastique, les bouts en mousse des tuteurs et le pied de la perche en aluminium, tous observables sur la figure 36. Un point plus bas dans la discussion explique la conséquence de ces objets visibles qui ne devraient pas l'être.




FIGURE 36 – Comparaison de la hauteur de végétation de deux quadrats à la même date. (a) Végétation dense et à bonne hauteur. (b) Végétation peu dense et trop basse.

Images aériennes

La principale limitation des drones est liée à leurs batteries qui ne permettent pas d'effectuer de très longs vols. Pour conserver un taux de recouvrement important, il faut donc que la hauteur de vol soit assez élevée. La conséquence directe est alors une diminution de la résolution au sol. Si cela est moins gênant en fin de saison, quand les plantes sont bien développées, il reste difficile d'acquérir de l'information sur les premiers stades des plantules. Les premiers vols de test ont été réalisés à 25 m de hauteur avec un recouvrement latéral de 70%, mais les résultats n'étaient pas satisfaisants. C'est pour cette raison que les vols effectifs ont été faits à 50 m de haut avec 90% de recouvrement.

Ensuite, même si la réflectance a été calibrée pour chaque sortie à l'aide du panneau fourni par MicaSense, il était difficile de conserver des conditions d'illumination homogènes durant toute la durée des vols. Il se peut donc que certains quadrats aient été couverts par un nuage durant leur acquisition, créant une inhomogénéité dans les données. Le caractère capricieux de la météo de la saison n'a pas contribué à rendre la tâche plus simple.

Enfin, malgré les onze cibles de contrôle géolocalisées servant à la correction des positions des images, des décalages de plusieurs centimètres persistaient sur les orthomosaiques reconstruites. Or, les quadrats ne faisaient que 50 cm de côté, ce qui ne laisse qu'une faible marge d'erreur. C'est pour combler ce décalage que les données ont été extraites sur une zone de 50 × 50 cm et aussi de 100 × 100 cm. En agrandissant la zone, la probabilité qu'elle contienne le vrai quadrat étudié augmentait, mais elle captait forcément plus d'information autour. La figure 37 illustre un exemple de décalage entre une image terrestre (figure 37a) et une image aérienne (figure 37b).




FIGURE 37 – Illustration du décalage possible entre les images terrestres et aériennes. (a) Image terrestre, le carré rouge représente la zone du quadrat extraite, dans laquelle se trouvent 3 coquelicots. (b) Image aérienne extraite du raster multibande correspondant au quadrat, dans lequel un seul coquelicot est observable.

4.1.2 Quantité de données

Couverture temporelle

Dans le protocole établi en début d'expérimentation, il était prévu que les acquisitions d'images soient réalisées entre le 13 mars et le 19 juin, à raison d'une sortie toutes les deux semaines. Cela aurait permis de suivre l'évolution du froment et des adventices des premiers stades jusqu'à la floraison du froment. Seulement, la prise en main du matériel a pris un certain temps, c'est pourquoi la première sortie effective a dû être décalée au 8 mai et que les sorties n'ont été espacées que d'une semaine. D'abord, la caméra utilisée pour les images terrestres a été changée car la première était bien trop lourde que pour être manipulée par une seule personne au champ. Ce choix a été fait après la première sortie le 13 mars. Ensuite, les paramètres des vols de drone ont dû être ajustés, ce qui a également pris un certain temps avant d'obtenir des images aériennes exploitables.

Pour la confrontation de la différenciation culture / adventices aux données de terrain, seules les données de biomasses du second relevé ont pu être utilisées. Les images acquises le 13 juin sont donc les seules à avoir pu être comparées pour l'analyse du point **2.2.6**, ce qui laisse un questionnement sur la qualité du modèle pour les dates ultérieures, et notamment pour le modèle pré-floraison.

Couverture spatiale

Dans le même registre, il n'était à la base pas prévu de ne suivre qu'un seul bloc d'expérimentation. En effet, les 4 blocs du projet EcoFoodSystem auraient dû être étudiés, montant ainsi le nombre de quadrats suivis de 20 à 80. Mais plusieurs limitations ont été rencontrées. D'abord, comme expliqué précédemment, les vols du drone étaient limités par ses batteries, il était donc difficile de couvrir correctement les 4 blocs en une sortie terrain. De plus, les blocs 1 et 2 étant éloignés des 3 et 4, il se passait un certain temps entre les vols, temps allongé par le manque de cibles de contrôle qui devaient alors toutes être enlevées d'un bloc et replacées sur le suivant. Plusieurs heures pouvaient ainsi séparer les vols, et avec les conditions météorologiques fortement changeantes cette année, le dernier vol devait parfois être réalisé dans des conditions d'illumination très peu favorables à la bonne acquisition d'images. Les blocs 3 et 4 ont donc été enlevés du protocole.

Ensuite, l'acquisition des images terrestres était énergivore et chronophage, surtout effectuée seul. Après observation, les quadrats du bloc 2 contenaient beaucoup moins d'adventices que ceux du bloc 1. Finalement, seules les parcelles sur le bloc 1 ont été conservées afin d'être capable de prendre correctement les images des quadrats tout en gardant des conditions d'illumination homogènes.

Couverture spectrale

Comme expliqué dans un paragraphe précédent, la caméra au sol a été changée en cours d'étude car la première choisie était trop encombrante que pour être maniée aisément sur le terrain. Cette caméra était le boîtier Multicam-1 développé par le plateau mécatronique, qui permettait d'acquérir des images à 6 longueurs d'onde différentes en plus des images RVB. La caméra OAK finalement utilisée couvrait donc moins d'information spectrale, étant donné qu'il s'agissait d'une caméra RVB.

Cela a également entraîné une différence dans les techniques de vision employées aux deux échelles. Au sol, les images étaient acquises en RVB, tandis que par drone, elles l'étaient en multispectral. Cette distinction peut expliquer une partie des différences entre les images terrestres et aériennes.

4.1.3 Modèles de classification

Objets non végétaux

Le point 4.1.1 expliquait que le pied de la perche en aluminium, les piquets en plastique délimitant les quadrats et les bouts en mousse des tuteurs servant de repères pouvaient être visibles sur les images terrestres. À cause de leurs couleurs différentes du sol et de leur brillance importante, ces objets pouvaient être considérés comme de la végétation lors de la segmentation sol /végétation. Ils étaient par la suite classés dans une espèce de végétation. La plupart du temps, le pied de la perche et les piquets étaient identifiés comme du froment, alors que le tuteur en mousse, de couleur rose, était identifié comme du coquelicot. Les FCV de ces deux espèces ont donc sûrement été surestimées par la suite.

Adventices non étudiées

Pour la différenciation culture / adventices, les 4 espèces d'adventices les plus fréquentes et visibles en image ont été étudiées. Seulement, le relevé de terrain dans les quadrats a montré que de nombreuses autres espèces y étaient présentes : laiteron épineux (SONAS), stellaire intermédiaire (STEME), pensée des champs (VIOAR), petite cigüe (AETCY), pâturin annuel (POAAN), renouée des oiseaux (POLAV), véronique à feuilles de lierre (VERHE), agrostide jouet du vent (APESV), laiteron maraîcher (SONOL), arroche étalée (ATXPA), épilobe à quatre angles (EPIAD), pomme de terre (SOLTU), achillée millefeuille (ACHMI), jonc des crapauds (IUNBU) et ray-grass anglais (LOLPE).

Malgré cette grande diversité, les quatre espèces identifiées sur les images représentent à elles seules 68,44% de la biomasse sèche des adventices mesurée en fin d'expérimentation dans les quadrats suivis, soit 206,81 grammes. Les trois adventices non suivies les plus présentes (en biomasse sèche) sont l'agrostide jouet du vent, la renouée des oiseaux et la pomme de terre avec respectivement 54,03 g (17,88%), 28,14 g (9,31%) et 10,95 g (3,62%). L'agrostide est très difficile à identifier sur les images étant donné qu'il s'agit d'une graminée se confondant avec le froment. Pour les deux autres, elles sont beaucoup moins hautes que le froment et sont donc cachées par celui-ci sur les images en prise de vue zénithale.

4.2 Discussion des résultats

Maintenant que les limites de l'étude ont été définies, les résultats obtenus peuvent être discutés. Pour ce faire, ils sont analysés, interprétés et comparés à la littérature scientifique dans les points suivants.

4.2.1 Différenciation culture / adventices

Modèles pré-floraison

Les tables 8 à 11 présentent les matrices de confusion obtenues par validation des 4 différents modèles testés pour la classification pré-floraison. Si ces 4 modèles parviennent à très bien identifier les superpixels de froment, ce n'est pas vraiment le cas pour les adventices.

En effet, même si la camomille est bien classée pour les modèles à 6, 8 et 10 variables, la totalité des superpixels représentant le chardon ou la moutarde sont reconnus comme du froment. Ces erreurs sont certainement dues au manque d'information acquise par la caméra RVB : lors des premiers stades, les feuilles de froment, chardon et moutarde présentaient pratiquement la même couleur et cette ressemblance ne pouvait pas être comblée par les indicateurs de texture. Les superpixels de chardon et de moutarde sont identifiés comme du froment et non l'inverse, ce qui est sûrement dû au plus grand nombre de SP de froment utilisés pour l'entraînement des modèles SVM. La camomille est quant à elle bien classée car ses tiges étaient plus sombres que les feuilles des autres espèces et présentaient une texture différente.

Le modèle à 12 variables classe quant à lui pratiquement tous les superpixels comme du froment, même ceux de camomille. Cette erreur est due à un oubli, repéré malheureusement trop tard que pour être corrigé. En effet, alors que toutes les autres variables ont été standardisées, le contraste et la dissimilarité ne l'ont pas été. Cela a ainsi entraîné de grosses erreurs de classifications par le SVM. Cependant, les modèles avec 6, 8 et 10 variables présentent des résultats similaires, il est donc fort probable que le modèle à 12 variables standardisées n'aurait pas énormément amélioré la qualité de la classification.

Modèles post-floraison

Les tables 12 à 15 présentent les matrices de confusion obtenues par validation des 4 différents modèles testés pour la classification post-floraison. À l'instar des modèles pré-floraison, ils parviennent à bien identifier les superpixels de froment. La situation est plus contrastée pour les adventices.

Comme pour la pré-floraison, tous les superpixels de feuilles de moutarde sont mal classés par les 4 modèles, la plupart mis en froment ou en chardon. La situation est similaire pour ce dernier, la plupart des SP sont identifiés comme du froment, même si quelques-uns sont correctement classés. Les fleurs de moutarde sont quant à elles un peu mieux identifiées et les confusions se font principalement avec le froment ou les fleurs de camomille. Dans le premier cas, cela peut s'expliquer par la saturation fréquente des fleurs qui sont alors blanches sur l'image, tout comme le sont les feuilles ou les épis du froment. Dans le second cas, les fleurs jaunes de la moutarde sont confondues avec les centres jaunes des fleurs de camomille. La confusion inverse peut d'ailleurs être observée dans les tables, mêmes si les fleurs de camomille sont mieux identifiées, tout comme les tiges. Les coquelicots sont quant à eux très bien classés. Ces observations sont valables pour les modèles à 6, 8 et 10 variables.

Pour les mêmes raisons que la classification pré-floraison, le modèle à 12 variables classe quasiment l'entièreté des superpixels en froment.

Comparaison à la littérature

En utilisant des vignettes annotées et un modèle SVM, Gée & Denimal (2020) ont obtenu une exactitude de 93% en validation de leur classification culture / adventices. Ce résultat est loin d'avoir été atteint dans ce travail, avec 50,50% pour la pré-floraison et 72,29% pour la post-floraison. Cependant, plusieurs facteurs peuvent expliquer cette différence de qualité de classification. Tout d'abord, les vignettes annotées utilisées pour leur classificateur SVM ne contenaient qu'un type de végétation, soit culture ou froment. Or cela n'est possible que si la culture et les adventices ne se recouvrent pas sur l'image, ce qui n'arrive qu'en début de saison. En effet, dans ce travail, la végétation est arrivée à floraison, ce qui signifie un développement important et donc forcément un contact sur les images. Ensuite, de ces vignettes annotées ont été extraites 500 variables à l'aide de la méthode du Bag of Visual Words (Csurka et al., 2002), alors que seulement 12 variables l'ont été des superpixels dans ce travail, ce qui réduit la quantité d'information et donc potentiellement la qualité des modèles.

4.2.2 Comparaison aux données terrain

Comparaison biomasse / fraction de couvert végétal

La figure 18 montre que, dans le cas de cette étude, la fraction de couvert végétal des différentes espèces ne permet pas de correctement estimer leur biomasse sèche. En effet, les R^2 des régressions linéaires réalisées pour le froment, le chardon et la moutarde sont tous inférieurs à 0,1. Différentes hypothèses peuvent être posées pour expliquer ces faibles valeurs. Pour le froment, les FCV et les biomasses mesurées ne montrent pas beaucoup de variabilité, ce qui peut être à l'origine du mauvais résultat de la régression. Pour le chardon et la camomille, l'erreur est principalement due aux points pour lesquels la biomasse est nulle alors que la FCV ne l'est pas, ce qui suggère une surestimation du nombre de superpixels classés en chardon et en moutarde. La faible quantité de données expliquée au point 4.1.2 peut également engendrer de mauvais résultats à cause d'une faible variabilité.

La situation est légèrement meilleure pour la camomille avec un R^2 égal à 0,44 et le coquelicot avec 0,81. Dans les deux cas, une partie de l'erreur peut également être expliquée par les points dont la biomasse est nulle mais pas la FCV. Les régressions sont sûrement meilleures aussi grâce au nombre plus élevé des quadrats pour lesquels des camomilles ou des coquelicots ont été relevés sur le terrain. En effet, cela réduit le nombre de points à biomasse nulle et donc l'erreur commise.

Gée & Denimal (2020) ont pourtant montré que la fraction de couvert végétal était une bonne approximation de la biomasse sèche, avec un R^2 de 0,93 pour le froment et de 0,70 pour les adventices. Cependant, il ne faut pas négliger le fait que leurs régressions ont été faites pour des stades jeunes en début de saison, alors que celles de ce travail ont été réalisées sur les données à la floraison de la culture. Or, en début de croissance, les plantes sont beaucoup moins hautes, ce qui permet sûrement une meilleure approximation de la biomasse à partir des informations 2D des images. Pour améliorer les régressions faites pour des stades plus tardifs, une option est envisagée dans les perspectives au point 4.3.2.

Comparaison biomasse / pression adventice

En ce qui concerne la régression linéaire entre la $PA_{biomasse}$ et la PA_{image} , le résultat n'est pas très concluant avec un R^2 de 0,12. Cela était attendu vu qu'il a été montré ci-dessus que les FCV ne permettaient pas de correctement estimer la biomasse. Pour ce travail, il ne peut donc pas être conclu que la pression adventice liée au rapport des biomasses peut être approximée à l'aide d'images RVB. Cela ne veut cependant pas dire que l'indicateur PA_{image} est entièrement à jeter.

4.2.3 Caractérisation de la dynamique de compétition froment / adventices

En analysant les figures 20b, 21b, 22b et 23b, qui illustrent l'évolution de la pression adventice dans tous les quadrats calculée sur les images, une tendance générale peut être observée. En effet, dans de nombreux quadrats, la PA présente deux phases similaires, d'abord du 08/05 au 23/05 (avant la floraison des adventices) et ensuite du 30/05 au 13/06 (après la floraison des adventices). Ces deux phases indiquent une augmentation de la pression au cours du temps, avec une diminution importante entre les deux.

Pour expliquer cette évolution de la PA, il faut s'intéresser à l'évolution des FCV du froment et des adventices, représentée sur les figures 20a, 21a, 22a et 23a. La figure 38 fait office d'exemple pour illustrer l'explication. Au début (08/05), les adventices ne sont pas très développées alors que les feuilles de froment prennent déjà une place importante sur l'image. Les deux semaines suivantes, elles s'étendent sur le plan horizontal (14/05) mais aussi en hauteur (23/05). Cela entraîne simultanément une baisse de la FCV du froment et une hausse de celle des adventices. La résultante en est donc une augmentation de la PA. Ensuite, bien que les fleurs des adventices étaient désormais présentes (30/05), le froment a continué à se développer pour masquer les feuilles et tiges des adventices, diminuant la PA_{image} . Mais ces fleurs ont continué d'apparaître et de se développer au fil de la saison (06/06 et 13/06), ce qui a entraîné une augmentation de la PA.




FIGURE 38 – Illustration de l'évolution des FCV du froment et des adventices au cours de la saison. Pour chaque date, l'image RVB ainsi que la différenciation culture / adventices réalisée par SVM est visible.

L'analyse précédente a permis d'expliquer l'évolution de la pression adventice pour les quadrats suivants : les cinq quadrats de la première parcelle (P1), les quadrats 1, 2 et 4 de la deuxième parcelle (P2), les quadrats 2 et 4 de la troisième parcelle (P3) et les quadrats 1, 2, 4 et 5 de la quatrième parcelle (P4). Il reste donc à l'expliquer pour les six autres quadrats.

Les quadrats B1P2Q3, B1P3Q1 et B1P3Q5 présentent une évolution de la PA assez similaire, avec une pression très importante le 06/06, dépassant même les 100% pour les deux derniers. Après observation des images RVB et de la classification froment / adventices, cette pression élevée peut s'expliquer par une surestimation du nombre de SP classés comme adventices par le SVM. En effet, le 06 juillet les images ont été acquises sous des conditions de lumière assez intense, ce qui a entraîné la surexposition du froment sur certaines images, et donc une confusion avec les fleurs des adventices. Pour les trois quadrats restants, le rapport des FCV du froment et des adventices reste simplement assez constant.

4.2.4 Comparaison des tailles des quadrats extraits

Les valeurs de R^2 dans la légende de la figure 24 ainsi que les résultats de l'ANOVA dans la table 16 indiquent que les valeurs moyennes de réflectance extraites des quadrats de 50 cm de côté et de 100 cm de côté sont très similaires, ce pour chacune des 5 bandes. Cependant, le R^2 le moins élevé est celui pour le proche infrarouge, avec une valeur de 0,75. Or, le NIR est important pour le calcul de nombreux indices de végétation. C'est pour cette raison que les analyses ont tout de même été réalisées avec les données extraites des deux tailles de quadrat sur les rasters.

Plusieurs hypothèses peuvent être à l'origine de cette différence plus importante dans le NIR que dans les autres bandes spectrales. Tout d'abord, il est possible qu'un effet de bord soit plus prononcé avec les quadrats d'un mètre de côté, entraînant une différence entre les deux tailles. Les bords ont peut-être des propriétés plus variantes dans le NIR. Ensuite, la caméra multispectrale peut être plus sensible aux variations de réflectance dans le proche infrarouge que dans les autres bandes. D'autres raisons peuvent être à l'origine des différences, mais il reste cependant difficile d'affirmer lesquelles en sont vraiment responsables.

4.2.5 Comparaison aux images terrestres

La figure 25 montre que des différences apparaissent entre les réflectances mesurées au sol et par drone, ce dans les trois bandes RVB. Trois hypothèses peuvent les expliquer. D'abord, des différences dans les bandes spectrales mesurées par les deux caméras peuvent exister. En effet, alors que la caméra embarquée sur drone mesure les réflectances dans le RVB à respectivement 668 ± 5 nm, 560 ± 10 nm et 475 ± 10 nm, il se peut que les bandes acquises pour ces trois canaux par la caméra terrestre ne soient pas exactement les mêmes. Malheureusement, ces informations n'ont pas été trouvées dans les spécifications de l'OAK-D S2. Ensuite, alors que les images terrestres sont acquises à 1 m au-dessus du couvert végétal, celles aériennes le sont à 50 m de haut. Or, Kedzierski et al. (2019) ont montré que l'atmosphère ainsi que les conditions météorologiques avaient un impact sur la qualité radiométrique des images acquises par drone. Enfin, les valeurs extraites et comparées sont les moyennes des réflectances dans les trois bandes RVB sur les quadrats. Or, il a été montré précédemment qu'un décalage de la position de ceux-ci sur les rasters pouvait exister, entraînant possiblement une différence dans les mesures. La logique est la même pour les quadrats d'un mètre de côté, qui représentent une zone plus grande que les images terrestres et donc forcément différente.

4.2.6 Calcul des indices de végétation

Les figures 26 à 35 illustrent les régressions linéaires réalisées entre la pression adventice et les indices de végétation extraits des quadrats des deux tailles. Au vu des R^2 obtenus, tous inférieurs à 10%, aucun des cinq IV calculés ne permet de correctement estimer la PA. Les couleurs sur les graphiques, qui servent à distinguer les 6 dates, suggèrent que même en réalisant une régression par date, les indices ne seraient pas très efficaces pour prédire la pression au sol. Ces mauvais résultats viennent peut-être du fait que les indices n'utilisent pas toute l'information spectrale disponible. En effet, quatre d'entre-eux ne se basent que sur les valeurs de réflectance dans deux bandes, et le dernier (*VDVI*), bien qu'il utilise trois bandes, n'inclut aucune information dans le proche infrarouge.

4.2.7 Prédiction de la pression adventice

C'est justement pour utiliser toute l'information spectrale extraite des quadrats que les régressions linéaires multiples ont été réalisées. Dans ce cas, les dates ont été séparées pour prendre en compte les possibles différences de conditions météorologiques. Au vu des coefficients de détermination R^2 présentés dans la table 17, cette méthode semble plus efficace que les indices de végétation pour prédire la pression adventice. Cependant, il faut garder à l'esprit qu'il s'agit des R^2 en calibration, au vu du peu de données disponibles. Aucune des deux tailles des quadrats extraits des rasters ne semble fortement se démarquer, même si les modèles avec les quadrats d'1 m² sont meilleurs pour quatre des six dates.

4.3 Perspectives

4.3.1 Acquisition des images

Images terrestres

Comme expliqué au point 4.1.1, même si les quadrats étaient géolocalisés, il était difficile de placer la perche de manière identique à chaque sortie. Afin de limiter la variabilité entre les différentes prises de vue au cours de la saison, il pourrait être envisagé d'employer une plateforme de phénotypage mobile. En effet, le plateau mécatronique de l'axe BioDyne possède déjà une telle plateforme, développée et utilisée notamment pour la thèse de Sébastien Dandrifosse (2022). Cet outil permettrait de circuler de quadrat en quadrat à l'aide d'une stations GPS et donc de mieux se positionner pour l'acquisition des images. De plus, cela réduirait grandement la charge de travail, étant donné que tous les capteurs nécessaires pourraient être embarqués et non portés sur le dos ou à la main.

Images aériennes

Afin d'améliorer la précision des positions des quadrats sur les rasters reconstruits, plusieurs solutions pourraient être mises en place. Tout d'abord, plus de cibles de contrôle pourraient être placées au sol, notamment au milieu du champ. Cela permettrait d'obtenir plus d'images contenant une cible et donc de mieux les localiser. Dans le même registre, le plan de vol pourrait être un peu plus étendu, surtout du côté du cimetière. En effet, comme le montre la figure 15, quatre cibles étaient placées très au bord de la zone couverte par le drone. Elles étaient donc très peu présentes sur les images acquises, ce qui pouvait entraîner des erreurs très marquées comme sur la figure 39. Après analyse, l'inclusion ou non de ces quatre cibles ne changeait pratiquement pas l'erreur sur les positions des quadrats, mais cela reste un point auquel il faut être attentif. Enfin, le suivi de quadrats plus étendus serait également une solution. Au plus la surface extraite est grande, au moins l'impact d'un décalage de plusieurs centimètres sera important.




FIGURE 39 – Illustration d’une erreur possible due aux cibles placées trop au bord du plan de vol.

4.3.2 Quantité de données

Couverture temporelle

Pour mieux évaluer la dynamique de compétition entre la culture et les adventices dans son entièreté, il serait évidemment intéressant de l’étudier dès le début de la saison. Cela demande donc une préparation et une prise en main du matériel bien à l’avance, ce qui n’a malheureusement pas pu être le cas pour ce travail.

Concernant les données de terrain utilisées pour évaluer l’indice PA_{image} , plusieurs quadrats pourraient être identifiés afin de recueillir des données de biomasse durant toute la saison. Une autre option, mise en place par Gée et al. (2021), est l’utilisation d’un modèle de croissance du froment alimenté par des mesures non destructives. Ce modèle fournit ainsi des estimations de la biomasse et permet donc de mieux évaluer l’impact de la pression adventice à tout moment de la saison.

Couverture spatiale

L’idée d’une plateforme mobile citée plus haut serait également utile afin de pouvoir étudier plus de quadrats. En effet, si la charge de travail est moins conséquente par quadrat, il est possible de prendre plus d’images lors d’une même sortie. Cela permettrait de couvrir une surface plus importante et donc de mieux représenter la variabilité des adventices sur le champ. Les images aériennes seraient également mieux exploitées car une plus grande proportion des informations en serait extraite.

Couverture spectrale

Pour améliorer la différenciation entre la culture et les adventices, surtout pour les premiers stades de développement, l’utilisation de capteurs hyperspectraux s’avèrerait sûrement très utile, tant pour les images terrestres qu’aériennes. De plus, l’emploi d’une même technique de vision aux deux échelles permettrait de mieux comprendre l’impact de l’atmosphère sur les différentes bandes spectrales. Pour un prix beaucoup plus abordable, les capteurs 3D seraient également des outils utiles à l’identification des différentes espèces végétales, en plus d’améliorer l’estimation de leur biomasse.

4.3.3 Modèles de classification

Modèles sur les images terrestres

Les modèles de classification utilisés dans ce travail, tant pour la segmentation sol / végétation que pour la différenciation culture / adventices, étaient des séparateurs à vastes marges. Ces modèles requièrent deux paramètres principaux : le terme de pénalité d'erreur C et le facteur de généralisation σ . Ces deux valeurs ont été laissées par défaut dans la fonction *svm.SVC*, or il est possible de les optimiser au jeu de données afin d'améliorer la classification. Il serait donc intéressant d'évaluer à quel point la qualité des modèles augmenterait en adaptant C et σ .

Les raisons du choix du SVM ont été expliquées plus tôt dans ce rapport. Mais dans la littérature, d'autres modèles ont déjà été utilisés pour identifier différentes espèces végétales comme les réseaux neuronaux ou les forêts aléatoires. Avec un jeu de données plus conséquent, la comparaison de ces différentes techniques d'apprentissage automatique pourrait également améliorer l'identification des adventices.

Modèles sur les images aériennes

Dans le cadre de ce travail, les données extraites des images aériennes ont simplement été comparées à celles issues des images terrestres, dont la pression adventice calculée. Pour aller plus loin, il serait intéressant de développer un modèle d'identification des adventices directement à partir des données des rasters. Il serait sûrement difficile d'obtenir des résultats satisfaisants en début de saison alors que les plantules sont encore très petites. Cependant, pour les stades plus avancés, les adventices seraient certainement distinguables de la culture, comme le suggère la figure 40 ainsi qu'Anderegg et al. (2023).

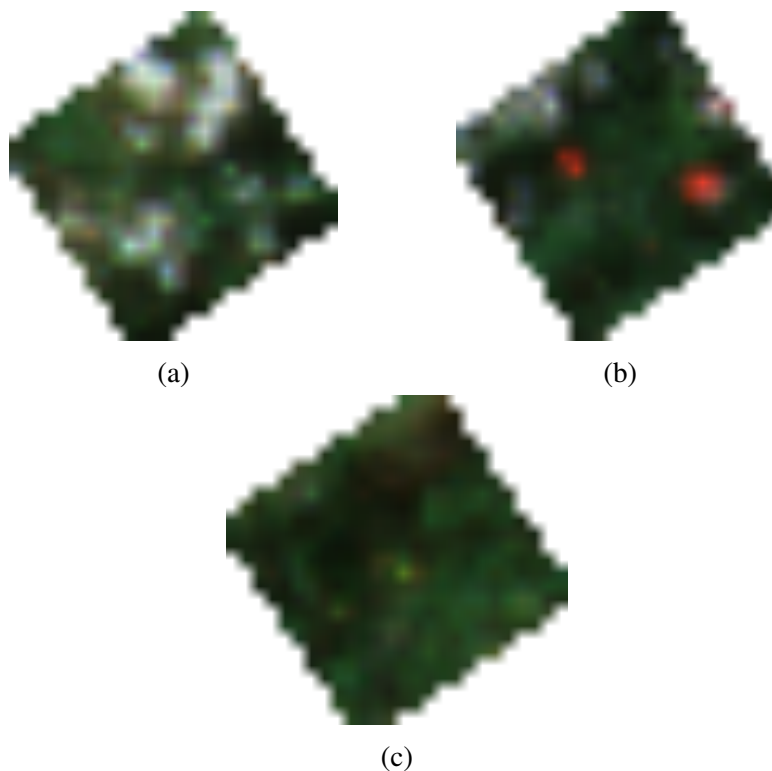


FIGURE 40 – Identification de différentes adventices sur les orthomosaiques. (a) Camomille. (b) Coquelicot. (c) Moutarde.

5 Conclusions

Dans le cadre de ce travail, deux modèles de classification permettant de différencier la culture des adventices sur base d'images terrestres ont été développés : un pour la période pré-floraison des adventices et l'autre pour la période post-floraison. Pour alimenter ces modèles, qui étaient des séparateurs à vastes marges, 12 variables ont été extraites de superpixels calculés sur les images rouge-vert-bleu à l'aide d'un algorithme par groupement itératif linéaire simple. Une sélection des meilleurs traits a été effectuée à l'aide d'une élimination récursive des variables. Un indicateur de pression adventice, calculé comme le rapport des fractions de couvert végétal des adventices et du froment, a ainsi pu être extrait des images et comparé à des données prises sur le terrain. Finalement, 20 quadrats de 50 cm de côté ont pu être suivis et l'évolution de cette pression adventice a pu être caractérisée.

La validation des deux modèles a montré que la classification avant la floraison des adventices n'était pas évidente, avec une exactitude de 50,50%. Le résultat était plus encourageant pour le modèle post-floraison, avec une exactitude de 72,29%. Cette différence était très certainement due à l'information de couleur supplémentaire qu'apportaient les fleurs des adventices. La comparaison aux données de biomasses mesurées en fin d'expérimentation a suggéré que, pour des stades avancés des plantes, il était difficile d'approximer leur biomasse à partir d'images 2D. L'ajout d'une information de hauteur améliorerait sans doute cette estimation. Enfin, l'analyse des évolutions des fractions de couvert végétal des adventices et du froment a permis de comprendre comment la pression adventice variait au fil de la saison. Les adventices semblaient d'abord se développer sur le plan horizontal mais aussi en hauteur, avant de se faire recouvrir par le froment. Ensuite, elles reprenaient de plus en plus d'espace, principalement grâce à leurs fleurs qui se développaient.

Des images aériennes des quadrats ont également été acquises à l'aide d'une caméra multispectrale embarquée sur drone. Différents indices de végétation ont ainsi pu être calculés sur chaque quadrat et comparés à la pression adventice extraite des images terrestres à l'aide de régressions linéaires. Une régression linéaire multiple a également été développée afin d'estimer cette pression à partir des valeurs de réflectance dans les cinq bandes spectrales acquises par la caméra multispectrale. Ces analyses ont été effectuées sur deux tailles de quadrat différentes, 50 cm et 100 cm de côté, afin de combler les éventuels décalages entre les positions des images aériennes et celles des quadrats au sol.

Les coefficients de détermination obtenus pour les régressions linéaires entre la pression adventice et les indices de végétation ont suggéré que ces derniers n'était pas efficaces pour estimer cette pression. Cependant, l'utilisation des valeurs de réflectances des cinq bandes spectrales pour la prédire a montré des résultats prometteurs, même si les conditions météorologiques semblaient avoir un impact sur la qualité des modèles. Enfin, les quadrats d'un mètre de côté ont montré de meilleurs résultats, suggérant une meilleure représentation de la réalité au sol.

Pour conclure, les résultats obtenus dans ce travail ont montré que la caractérisation de la dynamique de compétition entre le froment d'hiver et les adventices pouvait être réalisée à l'aide d'indicateurs issus des images terrestres et aériennes. Cependant, de nombreuses pistes d'amélioration devront encore être mises en place afin d'obtenir des résultats vraiment satisfaisants. La principale perspective étant l'ajout d'information à l'aide de capteurs 3D et hyperspectraux, ce aux deux échelles.

6 Bibliographie

- Abbas, T., Zahir, Z. A., Naveed, M., & Kremer, R. J. (2018). Chapter Five - Limitations of Existing Weed Control Practices Necessitate Development of Alternative Techniques Based on Biological Approaches. In D. L. Sparks (Éd.), *Advances in Agronomy* (Vol. 147, p. 239-280). Academic Press. <https://doi.org/10.1016/bs.agron.2017.10.005>
- Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P., & Süsstrunk, S. (2012). SLIC Superpixels Compared to State-of-the-Art Superpixel Methods. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 34(11), 2274-2282. <https://doi.org/10.1109/TPAMI.2012.120>
- Ahlgren, S. (2004). *Environmental impact of chemical and mechanical weed control in agriculture a comparing study using Life Cycle Assessment (LCA) methodology*. Göteborg SIK 2004.
- Ahmed, M., & Wardle, D. A. (1994). Allelopathic potential of vegetative and flowering ragwort (*Senecio jacobaea* L.) plants against associated pasture species. *Plant and Soil*, 164(1), 61-68. <https://doi.org/10.1007/BF00010111>
- Anderegg, J., Tschurr, F., Kirchgessner, N., Treier, S., Schmucki, M., Streit, B., & Walter, A. (2023). On-farm evaluation of UAV-based aerial imagery for season-long weed monitoring under contrasting management and pedoclimatic conditions in wheat. *Computers and Electronics in Agriculture*, 204, 107558. <https://doi.org/10.1016/j.compag.2022.107558>
- Atkinson, J. T., Ismail, R., & Robertson, M. (2014). Mapping Bugweed (*Solanum mauritianum*) Infestations in *Pinus patula* Plantations Using Hyperspectral Imagery and Support Vector Machines. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(1), 17-28. <https://doi.org/10.1109/JSTARS.2013.2257988>
- Badhan, S., Desai, K., Dsilva, M., Sonkusare, R., & Weakey, S. (2021). Real-Time Weed Detection using Machine Learning and Stereo-Vision. *2021 6th International Conference for Convergence in Technology (I2CT)*, 1-5. <https://doi.org/10.1109/I2CT51068.2021.9417989>
- Bakhshipour, A., Jafari, A., Nassiri, S. M., & Zare, D. (2017). Weed segmentation using texture features extracted from wavelet sub-images. *Biosystems Engineering*, 157, 1-12. <https://doi.org/10.1016/j.biosystemseng.2017.02.002>
- Bauer, M., & Cipra, J. (1973). Identification of Agricultural Crops by Computer Processing of ERTS MSS Data. *LARS Technical Reports*. <https://docs.lib.purdue.edu/larstech/20>
- Behmann, J., Mahlein, A.-K., Rumpf, T., Römer, C., & Plümer, L. (2015). A review of advanced machine learning methods for the detection of biotic stress in precision crop protection. *Precision Agriculture*, 16(3), 239-260. <https://doi.org/10.1007/s11119-014-9372-7>

- Beltran, D., & Basañez, L. (2014). A Comparison between Active and Passive 3D Vision Sensors: BumblebeeXB3 and Microsoft Kinect. In M. A. Armada, A. Sanfeliu, & M. Ferre (Éds.), *ROBOT2013: First Iberian Robotics Conference: Advances in Robotics, Vol. 1* (p. 725-734). Springer International Publishing.
https://doi.org/10.1007/978-3-319-03413-3_54
- Berti, A., Zanin, G., Baldoni, G., Grignani, C., Mazzoncini, M., Montemurro, P., Tei, F., Vazzana, C., & Viggiani, P. (1992). Frequency distribution of weed counts and applicability of a sequential sampling method to integrated weed management. *Weed Research*, 32(1), 39-44.
<https://doi.org/10.1111/j.1365-3180.1992.tb01860.x>
- Bi, K., Niu, Z., Xiao, S., Bai, J., Sun, G., Wang, J., Han, Z., & Gao, S. (2021). Non-Destructive Monitoring of Maize Nitrogen Concentration Using a Hyperspectral LiDAR: An Evaluation from Leaf-Level to Plant-Level. *Remote Sensing*, 13(24), 5025.
<https://doi.org/10.3390/rs13245025>
- Buhler, D. D. (2005). WEED MANAGEMENT. In D. Hillel (Éd.), *Encyclopedia of Soils in the Environment* (p. 323-328). Elsevier.
<https://doi.org/10.1016/B0-12-348530-4/00311-8>
- Campbell, J. B. (1987). *Introduction to Remote Sensing*. The Guilford Press.
- Capinera, J. L. (2005). Relationships between insect pests and weeds: an evolutionary perspective. *Weed Science*, 53(6), 892-901.
<https://doi.org/10.1614/WS-04-049R.1>
- Caussanel, J. P. (1989). Nuisibilité et seuils de nuisibilité des mauvaises herbes dans une culture annuelle : situation de concurrence bispécifique. *Agronomie*, 9(3), 219-240.
<https://doi.org/10.1051/agro:19890301>
- Chauvel, B., Darmency, H., Munier-Jolain, N., & Rodriguez, A. (coord.). (2018). *Gestion durable de la flore adventice des cultures*. Editions Quae.
- Chhokar, R. S., Sharma, R. K., & Sharma, I. (2012). Weed management strategies in wheat-A review. *Journal of Wheat Research*.
<https://epubs.icar.org.in/index.php/JWR/article/view/35326>
- Couturier, C., & Doublet, S. (2022). Le blé - Limiter la dépendance aux importations. Solagro.
https://solagro.org/medias/publications/f118_2022_04_note_ble_solagro.pdf
- Csurka, G., Dance, C., Fan, L., Willamowski, J., & Bray, C. (2002). *Visual categorization with bags of keypoints*. European Conference on Computer Vision.
- Culliney, T. W. (2005). Benefits of Classical Biological Control for Managing Invasive Plants. *Critical Reviews in Plant Sciences*, 24(2), 131-150.
<https://doi.org/10.1080/07352680590961649>

- Dammer, K., Intress, J., Beuche, H., Selbeck, J., & Dworak, V. (2013). Discrimination of *Ambrosia artemisiifolia* and *Artemisia vulgaris* by hyperspectral image analysis during the growing season. *Weed Research*, 53(2), 146-156.
<https://doi.org/10.1111/wre.12006>
- Dandrifosse, S. (2022). *Dynamics of wheat organs by close-range multimodal machine vision*.
<https://orbi.uliege.be/handle/2268/294161>
- Dobbs, A. M., Ginn, D., Skovsen, S. K., Bagavathiannan, M. V., Mirsky, S. B., Reberg-Horton, C. S., & Leon, R. G. (2022). New directions in weed management and research using 3D imaging. *Weed Science*, 70(6), 641-647.
<https://doi.org/10.1017/wsc.2022.56>
- Doraiswamy, P. C., Moulin, S., Cook, P. W., & Stern, A. (2003). Crop Yield Assessment from Remote Sensing. *Photogrammetric Engineering & Remote Sensing*, 69(6), 665-674.
<https://doi.org/10.14358/PERS.69.6.665>
- Esposito, M., Crimaldi, M., Cirillo, V., Sarghini, F., & Maggio, A. (2021). Drone and sensor technology for sustainable weed management: a review. *Chemical and Biological Technologies in Agriculture*, 8(1), 18.
<https://doi.org/10.1186/s40538-021-00217-8>
- FAO (Éd.). (2017). *The future of food and agriculture – Trends and challenges*. Food and Agriculture Organization of the United Nations.
- FAO. (2024, février 2). *WorldFoodSituation*. FAO Cereal Supply and Demand Brief | Food and Agriculture Organization of the United Nations.
<https://www.fao.org/worldfoodsituation/csdb/en> (consulté le 07/02/2024)
- Feldman. (2001). The origin of cultivated wheat. In A Bonjean, W Angus, eds, *The World Wheat Book: A History of Wheat Breeding* (p. 3-56). Lavoisier Tech & Doc.
- García Torres, L., Peña-Barragán, J. M., López-Granados, F., Jurado-Expósito, M., & Fernández-Escobar, R. (2008). Automatic assessment of agro-environmental indicators from remotely sensed images of tree orchards and its evaluation using olive plantations. *Computers and Electronics in Agriculture*, 61(2), 179-191.
<https://doi.org/10.1016/j.compag.2007.11.004>
- Gée, C., & Denimal, E. (2020). RGB Image-Derived Indicators for Spatial Assessment of the Impact of Broadleaf Weeds on Wheat Biomass. *Remote Sensing*, 12(18), 2982.
<https://doi.org/10.3390/rs12182982>
- Gée, C., Denimal, E., Merienne, J., & Larmure, A. (2021). Evaluation of weed impact on wheat biomass by combining visible imagery with a plant growth model : towards new non-destructive indicators for weed competition. *Precision Agriculture*, 22(2), 550-568.
<https://doi.org/10.1007/s11119-020-09776-6>

- Gerhards, R., & Oebel, H. (2006). Practical experiences with a system for site-specific weed control in arable crops using real-time image analysis and GPS-controlled patch spraying. *Weed Research*, 46(3), 185-193.
<https://doi.org/10.1111/j.1365-3180.2006.00504.x>
- Gholami, R., & Fakhari, N. (2017). Chapter 27 - Support Vector Machine: Principles, Parameters, and Applications. In P. Samui, S. Sekhar, & V. E. Balas (Éds.), *Handbook of Neural Computation* (p. 515-535). Academic Press.
<https://doi.org/10.1016/B978-0-12-811318-9.00027-2>
- Hall-Beyer, M. (2017). *GLCM Texture: A Tutorial v. 3.0 March 2017*.
<https://doi.org/10.11575/PRISM/33280>
- Hanke, I., Wittmer, I., Bischofberger, S., Stamm, C., & Singer, H. (2010). Relevance of urban glyphosate use for surface water quality. *Chemosphere*, 81(3), 422-429.
<https://doi.org/10.1016/j.chemosphere.2010.06.067>
- Harandi, N., Vandenberghe, B., Vankerschaver, J., Depuydt, S., & Van Messem, A. (2018). *How to make sense of 3D representations for plant phenotyping: a compendium of processing and analysis techniques*.
- Harker, K. N., & O'Donovan, J. T. (2013). Recent Weed Control, Weed Management, and Integrated Weed Management. *Weed Technology*, 27(1), 1-11.
<https://doi.org/10.1614/WT-D-12-00109.1>
- Harvey, R. G., & Wagner, C. R. (1994). Using Estimates of Weed Pressure to Establish Crop Yield Loss Equations. *Weed Technology*, 8(1), 114-118.
<https://www.jstor.org/stable/3988275>
- Hasan, A. S. M. M., Soheli, F., Diepeveen, D., Laga, H., & Jones, M. G. K. (2021). A survey of deep learning techniques for weed detection from images. *Computers and Electronics in Agriculture*, 184, 106067.
<https://doi.org/10.1016/j.compag.2021.106067>
- Hussain, M., Farooq, S., Merfield, C., & Jabran, K. (2018). Chapter 8 - Mechanical Weed Control. In K. Jabran & B. S. Chauhan (Éds.), *Non-Chemical Weed Control* (p. 133-155). Academic Press.
<https://doi.org/10.1016/B978-0-12-809881-3.00008-5>
- Islam, N., Rashid, M. M., Wibowo, S., Wasimi, S., Morshed, A., Xu, C., & Moore, S. (2021). Machine Learning Based Approach for Weed Detection in Chilli Field Using RGB Images. In H. Meng, T. Lei, M. Li, K. Li, N. Xiong, & L. Wang (Éds.), *Advances in Natural Computation, Fuzzy Systems and Knowledge Discovery* (p. 1097-1105). Springer International Publishing.
https://doi.org/10.1007/978-3-030-70665-4_119

- Jabran, K., Mahmood, K., Melander, B., Bajwa, A. A., & Kudsk, P. (2017). Chapter Three - Weed Dynamics and Management in Wheat. In D. L. Sparks (Éd.), *Advances in Agronomy* (Vol. 145, p. 97-166). Academic Press.
<https://doi.org/10.1016/bs.agron.2017.05.002>
- Keddy, P. A., & Cahill, J. (2012). Competition in Plant Communities. In P. A. Keddy & J. Cahill, *Ecology*. Oxford University Press.
<https://doi.org/10.1093/obo/9780199830060-0009>
- Kedzierski, M., Wierzbicki, D., Sekrecka, A., Fryskowska, A., Walczykowski, P., & Siewert, J. (2019). Influence of Lower Atmosphere on the Radiometric Quality of Unmanned Aerial Vehicle Imagery. *Remote Sensing*, *11*(10), 1214.
<https://doi.org/10.3390/rs11101214>
- Korres, N. E. (2018). Chapter 6 - Agronomic Weed Control: A Trustworthy Approach for Sustainable Weed Management. In K. Jabran & B. S. Chauhan (Éds.), *Non-Chemical Weed Control* (p. 97-114). Academic Press.
<https://doi.org/10.1016/B978-0-12-809881-3.00006-1>
- Kuester, A., Conner, J. K., Culley, T., & Baucom, R. S. (2014). How weeds emerge: a taxonomic and trait-based examination using United States data. *The New Phytologist*, *202*(3), 1055-1068.
<https://doi.org/10.1111/nph.12698>
- Kumar, A., Sabharwal, Y., & Sen, S. (2004). A simple linear time $(1 + \epsilon)$ -approximation algorithm for k-means clustering in any dimensions. *45th Annual IEEE Symposium on Foundations of Computer Science*, 454-462.
<https://doi.org/10.1109/FOCS.2004.7>
- Kumar, S., Bhowmick, M. K., & Ray, P. (2021). Weeds as alternate and alternative hosts of crop pests. *INDIAN JOURNAL OF WEED SCIENCE*, *53*(1), 14-29.
<https://doi.org/10.5958/0974-8164.2021.00002.2>
- Li, L., Zhang, Q., & Huang, D. (2014). A Review of Imaging Techniques for Plant Phenotyping. *Sensors*, *14*(11), 20078-20111.
<https://doi.org/10.3390/s141120078>
- Li, Z., Guo, R., Li, M., Chen, Y., & Li, G. (2020). A review of computer vision technologies for plant phenotyping. *Computers and Electronics in Agriculture*, *176*, 105672.
<https://doi.org/10.1016/j.compag.2020.105672>
- Lin, M.-Y., Lynch, V., Ma, D., Maki, H., Jin, J., & Tuinstra, M. (2022). Multi-Species Prediction of Physiological Traits with Hyperspectral Modeling. *Plants*, *11*(5), 676.
<https://doi.org/10.3390/plants11050676>
- Lou, Z., Quan, L., Sun, D., Li, H., & Xia, F. (2022). Hyperspectral remote sensing to assess weed competitiveness in maize farmland ecosystems. *Science of The Total Environment*, *844*, 157071.
<https://doi.org/10.1016/j.scitotenv.2022.157071>

- Marin-Morales, M. A., Ventura-Camargo, B. de C., & Hoshina, M. M. (2013). Toxicity of Herbicides: Impact on Aquatic and Soil Biota and Human Health. In *Herbicides - Current Research and Case Studies in Use*. IntechOpen.
<https://doi.org/10.5772/55851>
- Marino, S. (2023). Understanding the spatio-temporal behavior of crop yield, yield components and weed pressure using time series Sentinel-2-data in an organic farming system. *European Journal of Agronomy*, *145*, 126785.
<https://doi.org/10.1016/j.eja.2023.126785>
- Merfield, C. N. (2023). Chapter 2 - Integrated weed management in organic farming. In Sarathchandran, U. M.r., S. Thomas, & D. K. Meena (Éds.), *Organic Farming (Second Edition)* (p. 31-109). Woodhead Publishing.
<https://doi.org/10.1016/B978-0-323-99145-2.00004-5>
- Moazzam, S. I., Khan, U. S., Qureshi, W. S., Nawaz, T., & Kunwar, F. (2023). Towards automated weed detection through two-stage semantic segmentation of tobacco and weed pixels in aerial Imagery. *Smart Agricultural Technology*, *4*, 100142.
<https://doi.org/10.1016/j.atech.2022.100142>
- Moran, M. S., Inoue, Y., & Barnes, E. M. (1997). Opportunities and limitations for image-based remote sensing in precision crop management. *Remote Sensing of Environment*, *61*(3), 319-346.
[https://doi.org/10.1016/S0034-4257\(97\)00045-X](https://doi.org/10.1016/S0034-4257(97)00045-X)
- Mulla, D. J. (1997). Geostatistics, remote sensing and precision farming. *Ciba Foundation Symposium*, *210*, 100-115; discussion 115-119, 134-140.
<https://doi.org/10.1002/9780470515419.ch7>
- Mulla, D. J. (2013). Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosystems Engineering*, *114*(4), 358-371.
<https://doi.org/10.1016/j.biosystemseng.2012.08.009>
- Murphy, C. E., & Lemerle, D. (2006). Continuous cropping systems and weed selection. *Euphytica*, *148*(1), 61-73.
<https://doi.org/10.1007/s10681-006-5941-9>
- Oerke, E.-C. (2006). Crop losses to pests. *The Journal of Agricultural Science*, *144*(1), 31-43.
<https://doi.org/10.1017/S0021859605005708>
- Olson, D., & Anderson, J. (2021). Review on unmanned aerial vehicles, remote sensors, imagery processing, and their applications in agriculture. *Agronomy Journal*, *113*(2), 971-992.
<https://doi.org/10.1002/agj2.20595>
- Paturkar, A., Gupta, G. S., & Bailey, D. (2020). Non-destructive and cost-effective 3D plant growth monitoring system in outdoor conditions. *Multimedia Tools and Applications*, *79*(47), 34955-34971.
<https://doi.org/10.1007/s11042-020-08854-1>

- Peteinatos, G. G., Weis, M., Andújar, D., Rueda Ayala, V., & Gerhards, R. (2014). Potential use of ground-based sensor technologies for weed detection: Ground-based sensor technologies for weed detection. *Pest Management Science*, 70(2), 190-199.
<https://doi.org/10.1002/ps.3677>
- Qasem, J. R., & Foy, C. L. (2001). Weed Allelopathy, Its Ecological Impacts and Future Prospects: A Review. *Journal of Crop Production*, 4(2), 43-119.
https://doi.org/10.1300/J144v04n02_02
- Rahman, A., Lu, Y., & Wang, H. (2023). Performance evaluation of deep learning object detectors for weed detection for cotton. *Smart Agricultural Technology*, 3, 100126.
<https://doi.org/10.1016/j.atech.2022.100126>
- Ram, B. G., Oduor, P., Igathinathane, C., Howatt, K., & Sun, X. (2024). A systematic review of hyperspectral imaging in precision agriculture: Analysis of its current state and future prospects. *Computers and Electronics in Agriculture*, 222, 109037.
<https://doi.org/10.1016/j.compag.2024.109037>
- Rew, L. J., & Cousens, R. D. (2001). Spatial distribution of weeds in arable crops: are current sampling and analytical methods appropriate? *Weed Research*, 41(1), 1-18.
<https://doi.org/10.1046/j.1365-3180.2001.00215.x>
- Ribeiro, A., Fernandez-Quintanilla, C., Barroso, J., & Garcia-Alegre, M. C. (2005). Development of an image analysis system for estimation of weed pressure. In *Precision Agriculture '05* (p. 169-174). Wageningen Academic.
https://doi.org/10.3920/9789086865499_021
- Rice, E. L. (1984). *Allelopathy*. Elsevier Science.
- Rose, M. T., Cavagnaro, T. R., Scanlan, C. A., Rose, T. J., Vancov, T., Kimber, S., Kennedy, I. R., Kookana, R. S., & Van Zwieten, L. (2016). Impact of Herbicides on Soil Biology and Function. In D. L. Sparks (Éd.), *Advances in Agronomy* (Vol. 136, p. 133-220). Academic Press.
<https://doi.org/10.1016/bs.agron.2015.11.005>
- Rouse, J. W. (1974). *Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation*.
<https://ntrs.nasa.gov/citations/19740022555>
- Sahin, H. M., Miftahshudur, T., Grieve, B., & Yin, H. (2023). Segmentation of weeds and crops using multispectral imaging and CRF-enhanced U-Net. *Computers and Electronics in Agriculture*, 211, 107956.
<https://doi.org/10.1016/j.compag.2023.107956>
- Sattin, M., & Berti, A. (2003). Parameters for weed-crop competition. In *Weed Management for Developing Countries. 1: Addendum*. Food and Agriculture Organization of the United Nations.

- Schepers, J. S., Francis, D. D., Vigil, M., & Below, F. E. (1992). Comparison of corn leaf nitrogen concentration and chlorophyll meter readings. *Communications in Soil Science and Plant Analysis*, 23(17-20), 2173-2187.
<https://doi.org/10.1080/00103629209368733>
- Seelan, S. K., Laguette, S., Casady, G. M., & Seielstad, G. A. (2003). Remote sensing applications for precision agriculture: A learning community approach. *Remote Sensing of Environment*, 88(1), 157-169.
<https://doi.org/10.1016/j.rse.2003.04.007>
- Shahbazi, N., Ashworth, M. B., Callow, J. N., Mian, A., Beckie, H. J., Speidel, S., Nicholls, E., & Flower, K. C. (2021). Assessing the Capability and Potential of LiDAR for Weed Detection. *Sensors*, 21(7), 2328.
<https://doi.org/10.3390/s21072328>
- Sharma, G., Barney, J. N., Westwood, J. H., & Haak, D. C. (2021). Into the weeds: new insights in plant stress. *Trends in Plant Science*, 26(10), 1050-1060.
<https://doi.org/10.1016/j.tplants.2021.06.003>
- Shewry, P. R. (2021, novembre 20). *The Contribution of Wheat to Human Nutrition and Health*. Year On The Field.
<https://www.yearonthefield.net/post/the-contribution-of-wheat-to-human-nutrition-and-health> (consulté le 07/07/2024)
- Shewry, P. R., & Hey, S. J. (2015). The contribution of wheat to human diet and health. *Food and Energy Security*, 4(3), 178-202.
<https://doi.org/10.1002/fes3.64>
- Shotton, J., Winn, J., Rother, C., & Criminisi, A. (2009). TextonBoost for Image Understanding: Multi-Class Object Recognition and Segmentation by Jointly Modeling Texture, Layout and Context. *International Journal of Computer Vision*, 81(1), 2-23.
<https://doi.org/10.1007/s11263-007-0109-1>
- Singh, V., Rana, A., Bishop, M., Filippi, A. M., Cope, D., Rajan, N., & Bagavathiannan, M. (2020). Chapter Three - Unmanned aircraft systems for precision weed detection and management : Prospects and challenges. In D. L. Sparks (Éd.), *Advances in Agronomy* (Vol. 159, p. 93-134). Academic Press.
<https://doi.org/10.1016/bs.agron.2019.08.004>
- Siudak, M., & Rokita, P. (2014). A Survey of Passive 3D Reconstruction Methods on the Basis of More than One Image. *Machine Graphics and Vision*, 23(3/4), 57-117.
<https://doi.org/10.22630/MGV.2014.23.3.5>
- Smith, L. N., Zhang, W., Hansen, M. F., Hales, I. J., & Smith, M. L. (2018). Innovative 3D and 2D machine vision methods for analysis of plants and crops in the field. *Computers in Industry*, 97, 122-131.
<https://doi.org/10.1016/j.compind.2018.02.002>

- Sonka, M., Hlavac, V., & Boyle, R. (1993). *Image Processing, Analysis and Machine Vision*. Springer US.
<https://doi.org/10.1007/978-1-4899-3216-7>
- Sonka, M., Hlavac, V., & Boyle, R. (2015). *Image processing, analysis, and machine vision* (Fourth edition). Cengage Learning.
- Stone, M. L., Solie, J. B., Raun, W. R., Whitney, R. W., Taylor, S. L., & Ringer, J. D. (1996). Use of Spectral Radiance for Correcting In-season Fertilizer Nitrogen Deficiencies in Winter Wheat. *Transactions of the ASAE*, 39(5), 1623-1631.
<https://doi.org/10.13031/2013.27678>
- Strothmann, W., Ruckelshausen, A., Hertzberg, J., Scholz, C., & Langsenkamp, F. (2017). Plant classification with In-Field-Labeling for crop/weed discrimination using spectral features and 3D surface features from a multi-wavelength laser line profile system. *Computers and Electronics in Agriculture*, 134, 79-93.
<https://doi.org/10.1016/j.compag.2017.01.003>
- Walter, A., Liebisch, F., & Hund, A. (2015). Plant phenotyping: from bean weighing to image analysis. *Plant Methods*, 11(1), 14.
<https://doi.org/10.1186/s13007-015-0056-8>
- Wang, H., Lin, Y., Wang, Z., Yao, Y., Zhang, Y., & Wu, L. (2017). Validation of a low-cost 2D laser scanner in development of a more-affordable mobile terrestrial proximal sensing system for 3D plant structure phenotyping in indoor environment. *Computers and Electronics in Agriculture*, 140, 180-189.
<https://doi.org/10.1016/j.compag.2017.06.002>
- Wang, A., Zhang, W., & Wei, X. (2019). A review on weed detection using ground-based machine vision and image processing techniques. *Computers and Electronics in Agriculture*, 158, 226-240.
<https://doi.org/10.1016/j.compag.2019.02.005>
- Weiss, M., Jacob, F., & Duveiller, G. (2020). Remote sensing for agricultural applications : A meta-review. *Remote Sensing of Environment*, 236, 111402.
<https://doi.org/10.1016/j.rse.2019.111402>
- Wendel, A., & Underwood, J. (2016). Self-supervised weed detection in vegetable crops using ground based hyperspectral imaging. *2016 IEEE International Conference on Robotics and Automation (ICRA)*, 5128-5135.
<https://doi.org/10.1109/ICRA.2016.7487717>
- Weston, L. A., & Duke, S. O. (2003). Weed and Crop Allelopathy. *Critical Reviews in Plant Sciences*, 22(3-4), 367-389.
<https://doi.org/10.1080/713610861>

- Westwood, J. H., Charudattan, R., Duke, S. O., Fennimore, S. A., Marrone, P., Slaughter, D. C., Swanton, C., & Zollinger, R. (2018). Weed Management in 2050: Perspectives on the Future of Weed Science. *Weed Science*, 66(3), 275-285.
<https://doi.org/10.1017/wsc.2017.78>
- Wisler, G. C., & Norris, R. F. (2005). Interactions between Weeds and Cultivated Plants as Related to Management of Plant Pathogens. *Weed Science*, 53(6), 914-917.
<https://www.jstor.org/stable/4046994>
- World Health Organization. (1990). *Public health impact of pesticides used in agriculture*.
<https://iris.paho.org/handle/10665.2/44667>
- Wu, X., Aravecchia, S., Lottes, P., Stachniss, C., & Pradalier, C. (2020). Robotic weed control using automated weed and crop classification. *Journal of Field Robotics*, 37(2), 322-340.
<https://doi.org/10.1002/rob.21938>
- Zimdahl, R. L. (Éd.). (2004). Definition of Plant Competition. In *Weed-Crop Competition* (1re éd., p. 6-8). Wiley.
<https://doi.org/10.1002/9780470290224.ch2>
- Zimdahl, R. L. (2018). *Fundamentals of Weed Science*. Academic Press.