

Université de Montréal

**Contribution de l'imagerie dronique pour la
caractérisation des paramètres biophysiques des cultures
agricoles**

par Kosal Khun

Département de Géographie
Faculté des arts et des sciences

Thèse présentée
en vue de l'obtention du grade de Philosophiæ Doctor (Ph. D.)
en Géographie

Mai 2020

© Kosal Khun, 2020

Cette thèse intitulée

**Contribution de l'imagerie dronique pour la caractérisation des paramètres
biophysiques des cultures agricoles**

Présentée par
Kosal Khun

A été évaluée par un jury composé des personnes suivantes

François Girard
Président-rapporteur

François Cavayas
Directeur de recherche

Claude Codjia
Codirecteur

Nicolas Tremblay
Membre du jury

Jérôme Théau
Examineur externe

Résumé

Grâce aux technologies de l'information et aux systèmes de positionnement par satellites (GNSS), l'agriculture de précision raffine l'échelle d'observation et d'intervention, du champ à la plante individuelle. La télédétection, notamment à travers les images satellitaires, a également permis de surveiller l'évolution de la culture, avec une fréquence temporelle et une résolution spatiale accrues.

La vigueur de la culture est un paramètre crucial de la fertilisation, permettant d'optimiser l'apport en intrants et de générer des retombées économiques et environnementales. Plusieurs manières d'estimer la vigueur sont possibles. Pour une culture en rangs comme le maïs (*Zea Mays L.*), nous avons privilégié la biomasse qui servira de proxy à la vigueur.

Notre étude s'appuie sur l'hypothèse que l'avènement des drones agricoles ouvrira la voie à une meilleure estimation de la vigueur. Nous supposons que la flexibilité de la plateforme combinée avec la très haute résolution spatiale (THRS) des images droniques permettra un suivi plus précis de l'évolution de la vigueur, tant dans l'espace que dans le temps – conditions critiques pour le déploiement de l'agriculture de précision.

Les recherches des 15 dernières années s'appuient sur le drone pour collecter des images THRS, dont le traitement fait appel principalement à la méthode des indices de végétation, tel le NDVI. Plusieurs questions se posent :

- Le recours au NDVI est-il la manière la plus efficiente d'exploiter la THRS des images droniques ? Si non, comment exploiter autrement et mieux cette imagerie ?
- Attendu les contraintes de temps, la quantité de données et les impératifs logistiques, la méthode de traitement adoptée sera-t-elle suffisamment robuste ? Les concepts utilisés seront-ils simples et compréhensibles pour obtenir l'adhésion des utilisateurs finaux, c'est-à-dire les agriculteurs ?
- Les capteurs à bord des drones pouvant être orientés assez librement, quels sont les effets des angles de visée sur les résultats ?

D'abord, nous avons évalué la pertinence de l'approche classique, consistant à utiliser l'indice NDVI pour déterminer les paramètres de la culture. Pour cela, la plateforme dronique est comparée avec le capteur de proximité GreenSeeker. Il en découle que le drone se montre moins performant que le GreenSeeker pour l'estimation de la biomasse du maïs.

Nous avons ainsi délaissé l'approche classique et opté pour un indicateur de surface apparente, extrait à l'aide des techniques de vision par ordinateur appliquées à des images RGB. Cette méthode tire profit de la THRS offerte par l'imagerie dronique et produit un proxy robuste de la biomasse, au niveau surfacique (par mètre carré) et linéaire (par rang).

Nous avons aussi constaté que les résultats n'étaient pas affectés par les angles d'acquisition des images (au nadir et obliques). Partant, cette recherche ouvre la perspective à des applications de la dronautique en agriculture de précision, pour l'estimation de la vigueur et d'autres paramètres fondamentaux entrant dans les algorithmes d'optimisation des intrants. Elle offre également la possibilité d'imaginer des plateformes non-droniques pour l'acquisition des images THRS dans le contexte de la fertilisation.

Mots-clés : Agriculture de précision, Télédétection, Drone, UAV, Vigueur, Biomasse, Maïs, Fertilisation

Abstract

Thanks to information technologies and GNSS (Global Navigation Satellite System), precision agriculture is refining the scale of observation and intervention, from the field to the individual plant. Remote sensing, in particular through satellite imagery, has also made it possible to monitor the crop dynamics, with increasing time frequency and spatial resolution.

Crop vigor is a crucial parameter allowing the optimization of inputs, and consequently economic and environmental benefits. Several ways to estimate crop vigor are possible. For a row crop such as corn (*Zea Mays* L.), aboveground biomass has been favored and will serve as a proxy for vigor.

Our study is based on the hypothesis that the recent advent of agricultural UAVs (Unmanned Aerial Vehicles) will pave the way for a better estimation of crop vigor. We assume that the flexibility of the UAV combined with the very high spatial resolution of their images will allow a more accurate monitoring of crop vigor, both in space and time – conditions which are critical for the deployment of precision agriculture.

Research over the past 15 years has relied on the UAV to collect images of very high spatial resolution. However, the processing of those images is mainly based on vegetation indices, especially the NDVI. Several questions arise from the above observations:

- Is the use of NDVI the most efficient way to exploit the spatial resolution of UAV images? If not, is there a better way to exploit this imagery?
- How to respond to time and logistical constraints in the image processing so that it is ultimately adopted by farmers?
- Since UAV-borne sensors can be oriented quite freely, what are the effects of the acquisition angles on the results?

First, we assessed the relevance of the traditional approach which uses the NDVI index to determine crop parameters. To do that, we compared the UAV platform with the GreenSeeker proximal sensor. The results showed that the UAV is less efficient than the GreenSeeker in estimating corn biomass.

We thus moved away from the traditional approach and opted for a method extracting the apparent leaf area, through computer vision techniques applied to RGB images. This method took advantage of the very high spatial resolution offered by UAV images and produced a robust proxy for corn biomass, at the surface (per square meter) and row levels.

We also found that the results were not affected by the acquisition angles of the images (nadir and oblique). Therefore, this research opens the perspective to UAV applications in precision agriculture, for the estimation of vigor and other fundamental parameters used in input optimization algorithms. It also offers the possibility to imagine non-UAV based platforms for the acquisition of very high resolution images in the context of fertilization.

Keywords : Precision agriculture, Remote sensing, UAV, Crop vigor, Biomass, Corn, Fertilization

Table des matières

Résumé.....	iii
Abstract.....	v
Liste des tableaux.....	xii
Liste des figures.....	xiv
Liste des sigles et abréviations.....	xx
Remerciements.....	xxiii
Avant-propos.....	xxiv
Chapitre 1. Introduction.....	1
1.1. Contexte général.....	1
1.2. La télédétection dronique pour évaluer la vigueur des cultures agricoles : problématique.....	3
1.3. Objectifs et hypothèses de recherche.....	4
1.4. Contributions de la recherche à l’avancement des connaissances.....	5
1.5. Organisation de la thèse.....	6
PARTIE I : LA TÉLÉDÉTECTION DRONIQUE.....	7
Chapitre 2. Télédétection dronique appliquée en agriculture de précision : état de l’art.....	8
2.1. Les drones : définitions.....	8
2.2. Typologie des drones.....	9
2.3. Capteurs embarqués dans les drones.....	10
2.3.1. Caméra RGB.....	11
2.3.2. Caméra RGB modifiée.....	12
2.3.3. Caméra multispectrale.....	14
2.3.4. Caméra hyperspectrale.....	15
2.3.5. Caméra thermique.....	16
2.3.6. Systèmes lidar et radar.....	16
Chapitre 3. Traitements et analyses des images droniques.....	18
3.1. Planification et acquisition d’images.....	18

3.1.1. Plan de vol.....	18
3.1.2. Échelle d'intervention.....	20
3.1.3. Échelle d'observation.....	22
3.2. Prétraitements	23
3.2.1. Corrections géométriques et orthomosaiquage.....	23
3.2.2. Corrections radiométriques.....	25
3.3. Extraction de l'information.....	26
3.3.1. Traits caractéristiques et vigueur	26
3.3.2. Information spectrale	28
3.3.3. Indices de végétation vs paramètres biophysiques	31
3.3.4. Information structurale.....	38
Chapitre 4. L'imagerie dronique comme alternative aux autres méthodes de calcul de la vigueur	
42	
4.1. Avantages et désavantages du drone comme plateforme de télédétection	42
4.1.1. Avantages.....	42
4.1.2. Inconvénients	42
4.2. Qualité d'estimation des paramètres biophysiques.....	44
4.2.1. Comparaison drone vs satellite ou avion	44
4.2.2. Comparaison drone vs capteur de proximité	46
Chapitre 5. Mesurer la vigueur du maïs : cadre général	49
5.1. Le maïs-grain	49
5.1.1. Importance de la culture du maïs	49
5.1.2. Principes de culture du maïs	50
5.1.3. Bien mesurer la vigueur pour mieux fertiliser	51
5.2. Les expériences menées.....	53
5.2.1. Sites à l'étude.....	53
5.2.2. Données et prétraitements.....	53
5.2.3. Choix du paramètre de référence : la biomasse	53
5.2.4. Validation des résultats et corrélation entre paramètres	54
PARTIE II : LA THRS ET LES INDICES DE VÉGÉTATION.....	56

Chapitre 6. Étude théorique : simulation avec le modèle PROSPECT.....	57
6.1. Introduction.....	57
6.2. Méthodologie.....	58
6.3. Résultats.....	60
6.3.1. Variation de la teneur en chlorophylle (Cab).....	60
6.3.2. Variation de la quantité de matière sèche (Cm).....	62
6.4. Discussion.....	64
6.5. Conclusion.....	66
Chapitre 7. Étude avec des images droniques : comparaison avec le GreenSeeker.....	68
7.1. Introduction.....	68
7.2. Méthodologie.....	69
7.2.1. Sites à l'étude.....	69
7.2.2. Images droniques et prétraitements.....	69
7.2.3. Données de GreenSeeker et traitements.....	73
7.2.4. Données de vérité terrain.....	76
7.3. Résultats et discussion.....	77
7.3.1. Comparaison des cartes de NDVI : GreenSeeker vs UAV.....	77
7.3.2. Comparaison entre NDVI (UAV et GS) et points de validation au sol.....	80
7.3.3. De la pertinence d'un indice de végétation.....	83
7.4. Conclusion.....	85
PARTIE III : DÉVELOPPEMENT D'UNE MÉTHODE POUR QUANTIFIER LA VIGUEUR DE LA VÉGÉTATION.....	86
Chapitre 8. Estimation de la vigueur individuelle : expérience en serre.....	87
8.1. Introduction.....	87
8.2. Méthodologie.....	89
8.2.1. Description du protocole.....	89
8.2.2. Mesures effectuées.....	90
8.2.3. Traitement des images.....	94
8.3. Résultats et discussion.....	96
8.3.1. Corrélations entre paramètres de la plante.....	96

8.3.2. Analyse de la surface apparente de la plante	98
8.3.3. Corrélations entre paramètres de la plante et sa surface apparente	101
8.4. Conclusion	105
Chapitre 9. Extraction de la vigueur zonale à travers la fraction du couvert végétal	107
9.1. Introduction.....	107
9.2. Méthodologie	108
9.2.1. Site à l'étude	108
9.2.2. Données de vérité terrain	108
9.2.3. Images droniques et prétraitements	108
9.2.4. Extraction d'information.....	110
9.3. Résultats et discussion	112
9.3.1. Comparaison entre les deux modes d'acquisition.....	112
9.3.2. Mesurer la vigueur dans l'espace.....	114
9.3.3. Mesurer la vigueur dans l'espace et dans le temps.....	117
9.1. Discussion.....	118
9.2. Conclusion	119
Chapitre 10. Mesure de la vigueur linéaire à travers l'imagerie nadir et oblique.....	120
10.1. Introduction.....	120
10.2. Méthodologie	121
10.2.1. Terrain à l'étude.....	121
10.2.2. Mesure de biomasse	121
10.2.3. Plateformes d'acquisition et prétraitement des images.....	121
10.2.4. Traitement des images	123
10.2.5. Traitement statistique.....	128
10.3. Résultats et discussion	129
10.3.1. Comparaison entre les plateformes d'acquisition.....	129
10.3.2. Comparaison entre l'imagerie nadir et oblique.....	132
10.4. Conclusion	134
Chapitre 11. Perspectives.....	135
11.1. Le drone en remplacement des plateformes classiques de télédétection	136
11.2. Complémentarité des plateformes.....	137

11.3. Surveillance continue.....	138
11.4. Solution à passage unique.....	139
Conclusion générale.....	141
Références bibliographiques.....	144
Annexe A. Calculer le NDVI moyen.....	156
Annexe B. Tableaux et figures.....	160

Liste des tableaux

Tableau 2.1 – Typologie des drones	10
Tableau 3.1 – Principaux paramètres biophysiques.....	27
Tableau 3.2 – Exemples d’indices de végétation utilisés avec les images droniques.....	32
Tableau 3.3 – Exemples des modèles statistiques d’estimation de la teneur en azote en fonction des paramètres spectraux (adapté de Tahir <i>et al.</i> (2013)).	34
Tableau 5.1 – Production mondiale et canadienne des principales céréales et graines oléagineuses, 2016 (source : FAO, mise à jour du 28 mai 2018).....	49
Tableau 5.2 – Superficies cultivées en maïs-grain par rapport aux terres en culture, en Montérégie, au Québec et au Canada, 2016 (source : Statistique Canada)	50
Tableau 6.1 – Valeurs nominales et plages de valeurs utilisées pour l’analyse de sensibilité du modèle PROSPECT (N : structure physique de la feuille, Cab : concentration en chlorophylle, Cm : teneur en matière sèche, Cw : teneur en eau).....	59
Tableau 7.1 – Dates d’acquisition des données pour l’expérience en 2015	70
Tableau 8.1 – Nombre de plants échantillonnés, pour l’expérience en serre (printemps 201). 90	
Tableau 8.2 – Caractéristiques des pixels d’une image, selon la position et l’angle de visée de la caméra Micasense RedEdge.	92
Tableau 8.3 – Nombre de plants photographiés et d’images traitées (expérience en serre, printemps 2017).	95
Tableau 8.4 – Moyennes, écarts-types et matrice de corrélation de Pearson pour les paramètres biophysiques mesurés. Taille de l’échantillon : N=36.....	97
Tableau 9.1 – Spécifications techniques de la caméra attachée au drone Phantom 3 Professional, pour l’acquisition des images, à L’Acadie, été 2016.	109
Tableau 9.2 – Coefficients de détermination R^2 obtenus par Tilly <i>et al.</i> (2015), selon le type de régression, entre la biomasse et la hauteur de la canopée (PH) d’un part ; et entre la biomasse et les indices de végétation d’autre part (adapté de Tilly <i>et al.</i> (2015)).	118
Tableau 10.1 – Spécifications techniques des caméras utilisées pour l’acquisition des images, à L’Acadie, été 2017.....	123

Tableau 10.2 – Paramètres de la régression linéaire, pour estimer la surface apparente normalisée *Sap* en fonction de la biomasse fraîche ou sèche ; *Sap* est extraite des images acquises par la caméra Canon à différents angles de visée (N=50)..... 132

Tableau B.1 – Mesures des plants échantillonnés lors de l’expérience en serre, printemps 2017.
..... 160

Liste des figures

Figure 2.1 – Matrice de Bayer (1976) : a) Exemple de matrice avec l’arrangement GBRG ; b) Configurations possibles du premier bloc de 4 pixels d’une matrice de Bayer.....	11
Figure 2.2 – Réponse spectrale de la caméra Canon S110 RGB (source : Sensefly).	12
Figure 2.3 – Réponse spectrale de la caméra modifiée Canon S110 NIR (source : Sensefly).	13
Figure 2.4 – Réponse spectrale de la caméra multispectrale Airinov Multispec 4C (source : Airinov).....	14
Figure 2.5 – Exemples de caméras multispectrales : à gauche, la Micasense RedEdge et, à droite, la Parrot Sequoia (sources : Micasense et Parrot).....	15
Figure 2.6 – Visualisation de l’effet de parallaxe en superposant les 3 bandes (rouge, vert, bleue) de la caméra Micasense RedEdge. Il est possible de voir que les bandes ne sont pas bien alignées.	15
Figure 3.1 – Étapes de traitement et d’analyse des images droniques.....	18
Figure 3.2 – Trois différents plans de vol : (A) lignes de vol parallèles; (B) lignes en quadrillage; (C) lignes de vol en boîte-mobile. Les lignes jaunes représentent les lignes de vol et les points verts les points de passage le long de la ligne de vol pour la navigation GNSS (Shi <i>et al.</i> , 2016).	19
Figure 3.3 – Exemples d’échelles de mesure de la vigueur et le mode de gestion correspondant.	21
Figure 3.4 – Schéma de traitement des images pour produire un nuage de points 3D avec la méthode SfM-MVS (Structure from motion – multi-view stereo). Source : Iglhaut <i>et al.</i> (2019)	24
Figure 3.5 – Approche d’analyse des images droniques.....	27
Figure 3.6 – Exemples de signature spectrale pour les deux principaux objets rencontrés dans un champ : la végétation et le sol. Les mesures ont été effectuées avec le spectroradiomètre ASD FieldSpec Handheld 2, dans un champ de maïs (été 2015).	28
Figure 3.7 – Coefficients d’absorption des différents composants d’une feuille verte, d’après le modèle PROSPECT-D (Jacquemoud et Baret, 1990). Les courbes représentent l’absorption relative de chaque composant par rapport à son absorption maximale.	29

Figure 3.8 – Réflectance et transmittance des feuilles de maïs pour 0, 90 et 180 kg N ha ⁻¹ (Daughtry <i>et al.</i> , 2000).....	30
Figure 3.9 – Réflectance des feuilles de maïs en fonction de la teneur en chlorophylle (Daughtry <i>et al.</i> , 2000).	37
Figure 4.1 – Système embarqué GreenSeeker (source : Trimble).....	47
Figure 4.2 – Capteur portatif GreenSeeker (source : Trimble).....	48
Figure 5.1 – Stades végétatifs du maïs. Source : MAAARO (2017).....	51
Figure 6.1 – Simulation PROSPECT en variant le paramètre Cab (teneur en chlorophylle, en $\mu\text{g}\cdot\text{cm}^{-2}$) : a) signatures spectrales selon les valeurs de Cab, b) courbes de réflectance en fonction de Cab dans les 5 bandes de la Micasense RedEdge, c) évolution du NDVI et du NGRDI en fonction de Cab. Les valeurs des autres paramètres du modèle ont été fixées comme suit : N = 1,518 ; Ccx = 12 $\mu\text{g}\cdot\text{cm}^{-2}$; Canth = 0 $\mu\text{g}\cdot\text{cm}^{-2}$; Cbp = 0 (unité arbitraire) ; Cm = 0,003662 $\mu\text{g}\cdot\text{cm}^{-2}$; Cw = 0,0131 $\mu\text{g}\cdot\text{cm}^{-2}$	61
Figure 6.2 – Évolution de l'indice NDRE en fonction de la teneur en chlorophylle.	62
Figure 6.3 – Simulation PROSPECT en variant le paramètre Cm (teneur en matière sèche, en $\mu\text{g}\cdot\text{cm}^{-2}$) : a) signatures spectrales selon les valeurs de Cm, b) courbes de réflectance en fonction de Cm dans les 5 bandes de la Micasense RedEdge, c) évolution du NDVI et du NGRDI en fonction de Cm. Les valeurs des autres paramètres du modèle ont été fixées comme suit : N = 1,518 ; Ccx = 12 $\mu\text{g}\cdot\text{cm}^{-2}$; Canth = 0 $\mu\text{g}\cdot\text{cm}^{-2}$; Cbp = 0 (unité arbitraire) ; Cab = 58 $\mu\text{g}\cdot\text{cm}^{-2}$; Cw = 0,0131 $\mu\text{g}\cdot\text{cm}^{-2}$	63
Figure 6.4 – Évolution de l'indice NDBI en fonction de la teneur en matière sèche.....	64
Figure 7.1 – Trajectoire de vol en quadrillage au-dessus du champ 1, le 13 juin 2015. La zone d'intérêt à survoler est identifiée par le rectangle rouge, dont les dimensions sont environ 570 m x 280 m (source : capture-écran du logiciel eMotion 2).....	70
Figure 7.2 – Trajectoire de vol en boîte mobile au-dessus du champ 2, le 17 juin 2015. La zone d'intérêt à survoler est identifiée par le rectangle rouge, dont les dimensions sont environ 1390 m x 125 m (source : capture-écran du logiciel eMotion 2).....	71
Figure 7.3 – Conversion des valeurs GreenSeeker enregistrées en empreintes réelles (NDVI_GS _{6x2m}), utilisées pour comparer avec les données UAV.....	75
Figure 7.4 – Validation croisée des valeurs de GreenSeeker krigées pour a) Champ 1, N=10 144 et b) Champ 2, N=55 951.....	76

Figure 7.5 – Extrait de la carte NDVI_GS_{1m} après krigeage, utilisée pour comparer avec les données terrain. Les points alignés représentent la position des valeurs NDVI enregistrées par chaque tête GreenSeeker lors du déplacement du tracteur. 76

Figure 7.6 – Comparaison entre les cartes de NDVI pour le champ 1, en date du 13 juin 2015 : a) carte obtenue par krigeage des mesures GreenSeeker, résolution : 1 m (NDVI_GS_{1m}), b) carte obtenue par photogrammétrie à partir des images droniques, résolution : 5 cm (NDVI_UAV_{5cm}). Les encadrés a1 et b1 montrent, avec plus de détails, une zone du champ sans mauvaises herbes ; tandis que les encadrés a2 et b2 montrent une zone fortement envahie par les mauvaises herbes. 78

Figure 7.7 – Relation entre NDVI_GS_{6x2m} et NDVI_UAV_{6x2m} pour les champs 1 (N=1216, à gauche) et 2 (N=6690). 79

Figure 7.8 – Carte résiduelle montrant la différence relative entre les données NDVI_UAV_{6x2m} mesurées et celles prédites à partir de NDVI_GS_{6x2m}, pour chaque empreinte GreenSeeker, exprimée en écart-type (é.t.). 79

Figure 7.9 – Relation entre la biomasse sèche du maïs et le NDVI (UAV et GS) pour le champ 1 (a, c), N=30 ; et pour le champ 2 (b, d), N=40. NDVI_UAV_{rows} a été calculé à partir des rangs *in situ*. 81

Figure 8.1 – Vue 3D d'une portion d'un champ de maïs, à la ferme de L'Acadie, été 2016. L'image a été produite à l'aide du logiciel Pix4Dmapper Pro à partir d'images droniques acquises avec le Phantom 3 Professional. 88

Figure 8.2 – Aperçu du dispositif en serre, CRD de Saint-Jean-sur-Richelieu, printemps 2017. 89

Figure 8.3 – Dispositif sur rails portant la caméra Micasense RedEdge. 91

Figure 8.4 – Différents angles d'observation d'un plant de maïs : a) angle azimutal = angle d'orientation du plant ; b) angle zénithal = angle de visée de la caméra. 91

Figure 8.5 – Position de la caméra par rapport au plant de maïs photographié (vue de profil). 92

Figure 8.6 – Schéma du dispositif d'acquisition d'images en salle de photographie. 93

Figure 8.7 – Planimètre LI-3100C pour mesurer la surface des feuilles de maïs (source : LICOR). 94

Figure 8.8 – Diagramme en radar représentant la surface apparente (en cm^2) en fonction de l'angle azimutal θ (en degrés), pour un angle de visée $\alpha = 0^\circ, 15^\circ, 30^\circ$. Chaque couleur représente une plante différente (N=36).	99
Figure 8.9 – Évolution de la surface apparente en fonction de l'angle de visée, l'angle azimutal est fixé à $\theta = 0^\circ$. Chaque couleur représente une plante différente (N=36).	100
Figure 8.10 – Relation entre surface apparente et surface foliaire totale, en fonction de l'angle zénithal α . Pour les 3 équations de régression, les ordonnées à l'origine ne sont pas significatives ($p > 0,1$) et les intervalles de confiance à 95 % des 3 pentes se chevauchent.	102
Figure 8.11 – Relation entre surface apparente et poids frais du plant de maïs, en fonction de l'angle zénithal α . Les ordonnées à l'origine ne sont pas significatives ($p > 0,1$). Les intervalles de confiance à 95 % des 3 pentes se chevauchent.	103
Figure 8.12 – Relation entre surface apparente et poids sec du plant de maïs, en fonction de l'angle zénithal α , régression linéaire (expérience en serre, printemps 2017).	104
Figure 8.13 – Relation entre surface apparente et poids sec du plant de maïs, en fonction de l'angle zénithal. La relation est linéaire entre les logarithmes des deux variables, avec une ordonnée à l'origine significativement non nulle, et une pente non significativement différente pour les angles zénithaux.	105
Figure 9.1 – Traitement d'un cliché RGB pour obtenir la fraction du couvert végétal. Les variables r, g, b sont les valeurs normalisées des bandes rouge (R), verte (G) et bleue (B) d'une image RGB, où chaque bande est divisée par la somme de toutes les bandes.	110
Figure 9.2 – Chaîne de traitements de l'imagerie dronique RGB pour extraire la fraction de couvert végétal.	111
Figure 9.3 – Relation entre la fraction de couvert végétal extraite des images droniques et la biomasse fraîche : en bleu, la FCV extraite des clichés pris à 3m et 5m AGL (N=96) ; en rouge, la FCV extraite de l'orthomosaique à 10m AGL (N=48). Tous les coefficients sont significatifs. Les intervalles de confiance à 95 % pour chacun des coefficients se chevauchent.	113
Figure 9.4 – Mosaique RGB (en haut) convertie en carte de FCV, du 4 août 2016 (stade V3).	114
Figure 9.5 – Mosaique RGB (en haut) convertie en carte de FCV, du 24 août 2016 (stades V6–V7).	115

Figure 9.6 – Évolution de la vigueur, exprimée à travers la FCV, dans l’espace et le temps (expérience à L’Acadie, été 2016). Les stades atteints par le maïs pour ces dates sont : V3 (4 août), V4 (10 août), V5–V6 (19 août) et V6–V7 (24 août). On constate la mauvaise qualité du mosaïquage pour la date du 19 août 2016..... 116

Figure 9.7 – Évolution de la fraction de couvert végétal (FCV) le long du rang 6, ferme expérimentale de L’Acadie, été 2016 ; das : *days after sowing* (nombre de jours après le semis). 117

Figure 10.1 – Caméra RGB accrochée à une tyrolienne (caméra Canon). 122

Figure 10.2 – Captures-écran extraites de l’interface utilisateur montrant un quadrat dans une image au nadir : (a) orthomosaïque clippée, produite à partir d’images acquises avec la caméra UAV et (b) cliché RGB acquis avec la caméra Canon, et leurs images segmentées superposées sur les photos originales (respectivement, c and d). Le point de contrôle (GCP) numéro 45 est visible dans cette scène, ce qui permet de localiser la zone d’échantillonnage. Les numéros P0 à P9 identifient les plants échantillonnés dans le rang, inclus dans le quadrat R10. 125

Figure 10.3 – Images obliques d’une zone d’échantillonnage photographiée avec la caméra Canon selon des angles de visée de (a) 30° et (b) 45° par rapport à la verticale. Les numéros P0 à P9 identifient les plants échantillonnés dans le rang, inclus à l’intérieur du rectangle R10. 126

Figure 10.4 – Relation entre les surfaces apparentes normalisées calculées à partir de la caméra Canon et celles calculées à partir de la caméra à bord du drone. Taille de l’échantillon : N=42. *Ordonnée à l’origine non significative. 130

Figure 10.5 – Relation entre la biomasse fraîche (respectivement sèche) du maïs et la surface apparente normalisée pour les caméras UAV (a, c) et Canon (b, d), à partir d’images acquises au nadir. Taille des échantillons : N=48 (caméra UAV) et N=50 (caméra Canon)..... 131

Figure 10.6 – Relation entre la biomasse fraîche (respectivement sèche) du maïs et la surface foliaire projetée extraite à partir de la caméra P, selon les angles de visée de 30° (a, c) et 45° (b, d). Taille de l’échantillon : N=50..... 133

Figure A.1 – Valeurs de NDVI en fonction des valeurs de réflectance dans le rouge (ρR) et dans le proche infrarouge (ρNIR), avec quelques exemples de cibles traditionnelles : maïs avec peu de chlorophylle (low Cab) et beaucoup de chlorophylle (high Cab) ; sol sec (dry soil) et sol mouillé (wet soil). 157

Figure A.2 – Comparaison des valeurs de NDVI moyen selon la façon de les calculer. NDVI_{ref} est calculé à partir des moyennes de réflectance dans chaque zone d'échantillonnage, tandis que NDVI_{mean} est la moyenne des valeurs de NDVI calculées à partir de la réflectance individuelle des pixels..... 158

Figure B.1 – Diagramme en radar représentant la surface foliaire apparente (coordonnée radiale, en cm²) en fonction de l'angle azimutal θ (coordonnée angulaire, en degrés), pour un angle de visée $\alpha=0^\circ$ (expérience en serre, printemps 2017). Chaque couleur représente une plante différente. 161

Figure B.2 – Diagramme en radar représentant la surface foliaire apparente (coordonnée radiale, en cm²) en fonction de l'angle azimutal θ (coordonnée angulaire, en degrés), pour un angle de visée $\alpha=15^\circ$ (expérience en serre, printemps 2017). Chaque couleur représente une plante différente. 162

Figure B.3 – Diagramme en radar représentant la surface foliaire apparente (coordonnée radiale, en cm²) en fonction de l'angle azimutal θ (coordonnée angulaire, en degrés), pour un angle de visée $\alpha=30^\circ$ (expérience en serre, printemps 2017). Chaque couleur représente une plante différente. 163

Figure B.4 – Relation entre surface apparente et poids sec du plant de maïs, en fonction de l'angle zénithal α . Seuls les plants dont le poids sec est inférieur à 30 g sont considérés (N=32). IC représente l'intervalle de confiance à 95% pour la pente. *Ordonnée à l'origine non significative. Pour les 3 équations de régression, les intervalles de confiance à 95% des 3 pentes se chevauchent. 164

Liste des sigles et abréviations

AAC : Agriculture et Agroalimentaire Canada

AGL : *Above ground level* (altitude au-dessus du sol)

BGNIR : *Blue Green Near-infrared* (caméra RGB modifiée : bleu, vert, proche infrarouge)

BRDF : *Bidirectional Reflectance Distribution Function*

CCD : *Charge Coupled Device*

CEa : Conductivité électrique apparente

CHM : *Canopy Height Model*

CMOS : *Complementary Metal Oxide Semiconductor*

COSINE : *Close-range spectral imaging of leaves*

CRD : Centre de recherche et de développement

CSM : *Crop Surface Model*

das : *days after sowing*

ERTS : *Earth Resources Technology Satellite* (devenu Landsat 1)

ExG : *Excess Green Index*

ExR : *Excess Red Index*

FAO : *Food and Agriculture Organization of the United Nations* (Organisation des Nations Unies pour l'alimentation et l'agriculture)

FCV : Fraction du couvert végétal

GCP : *Ground Control Point*

GNSS : *Global Navigation Satellite System* (Système de navigation par satellites)

GPS : *Global Positioning System*

IR : *Infrared* (Infrarouge)

ISPA : *International Society of Precision Agriculture*

LAI : *Leaf Area Index*

LED : *Light-Emitting Diode* (diode électroluminescente, DEL)

MAAARO : Ministère de l'Agriculture, de l'Alimentation et des Affaires Rurales de l'Ontario

MAPAQ : Ministère de l'Agriculture, des Pêcheries et de l'Alimentation du Québec

MNS : Modèle numérique de surface

MNT : Modèle numérique de terrain

MSS : *Multispectral Scanner System* (capteur embarqué sur les satellites Landsat 1 à 5)

NASA : *National Aeronautics and Space Administration* (Agence spatiale américaine)

NDVI : *Normalized Difference Vegetation Index*

NGRDI : *Normalized Green-Red Difference Index*

NSI : *Nitrogen Sufficiency Index*

OACI : Organisation de l'aviation civile internationale

OFAT : *One-factor-at-a-time* (méthode d'analyse de sensibilité)

OSAVI : *Optimized Soil Adjusted Vegetation Index*

PIR : Proche infrarouge (anglais, *NIR : Near-infrared*)

PVI : *Perpendicular Vegetation Index*

REIP : *Red-Edge Inflection Point*

RGB : *Red Green Blue* (caméra standard acquérant les 3 bandes du visible : rouge, vert, bleu)

RGNIR : *Red Green Near-infrared* (caméra RGB modifiée : rouge, vert, proche infrarouge)

RTK : *Real Time Kinematic*

SAIL : *Scattering by Arbitrarily Inclined Leaves*

SAVI : *Soil Adjusted Vegetation Index*

SCAN : *Soil, Crop, Atmosphere for N*

SfM : *Structure from Motion*

SPAD : *Soil Plant Analysis Development* (instrument permettant de mesurer la teneur en chlorophylle d'une feuille)

SWIR : *Short-Wave InfraRed* (Infrarouge ondes courtes)

TBA : Télédétection basse altitude

TGI : *Triangular Greenness Index*

THRS : Très haute résolution spatiale

TIC : Technologies de l'information et de la communication

TSAVI : *Transformed Soil Adjusted Vegetation Index*

UAV / UAS : *Unmanned Aerial Vehicle / Unmanned Aerial System*

UTM : Unité thermique maïs

UV : Ultraviolet

VI : *Vegetation Index*

À ma femme et à mes enfants.

Remerciements

Cette thèse n'aurait pu voir le jour sans l'implication et l'aide de plusieurs personnes. Il me serait difficile de les remercier toutes nommément, mais ma reconnaissance leur est toute due.

Tout d'abord, je voudrais exprimer mes sincères remerciements à mon directeur, M. François Cavayas, professeur à l'Université de Montréal, dont la bienveillance et l'expertise ont contribué à l'aboutissement de cette thèse. Je remercie aussi mon co-directeur, M. Claude Codjia, professeur à l'UQAM, qui fut un excellent soutien moral et académique. Tous deux ont su me guider à travers les nombreuses péripéties et me remettre sur orbite lorsque je faisais fausse route.

Je tiens également à remercier Dr Nicolas Tremblay, chercheur à Agriculture et Agroalimentaire Canada, qui a partagé avec générosité ses connaissances en agronomie et s'est toujours montré disponible pour fournir ses conseils éclairés. Il a également accepté de participer à mon jury de thèse. Qu'il en soit remercié.

J'exprime ma gratitude à M. Jérôme Théau, professeur à l'Université de Sherbrooke, et M. François Girard, professeur à l'Université de Montréal, qui me font l'honneur d'être examinateurs de ma thèse.

Un grand merci également à l'ensemble du personnel d'Agriculture et Agroalimentaire Canada, qui m'a accueilli avec gentillesse pendant plus de trois ans au sein de son Centre de recherche et de développement à Saint-Jean-sur-Richelieu. Philippe Vigneault, coordonnateur de l'équipe « Géomatique et Agriculture de précision », m'a pris sous ses ailes et, sans ménager sa peine, a mis à ma disposition toutes les ressources nécessaires pour mener à bien mes recherches. Enfin, j'adresse une pensée toute particulière à mes collègues de bureau qui m'ont accompagné pendant tout ce temps.

Avant-propos

Comme pour beaucoup de mes prédécesseurs, si le doctorat fut un voyage enrichissant, il fut également une aventure personnelle chaotique et parsemée d'embûches. Dans mon cas, l'aventure fut à l'image d'un vol de drone. Le choix de mon sujet de recherche fut tumultueux. Je dus multiplier les tentatives de décollage, avant de m'orienter finalement vers l'imagerie dronique en agriculture de précision. Ensuite, la montée en croisière fut relativement longue et délicate. Entre zones de turbulence, distractions, déroutements, maintes fois j'ai failli lâcher prise et abandonner le vaisseau.

Amorcée en 2013, ma thèse prenait littéralement la tangente jusqu'à une rencontre fortuite un jour de juin 2015 – plus exactement le samedi 13. Ce matin-là, sous un soleil montérégien brûlant, j'étais venu assister à un vol de drone au-dessus d'un champ de maïs. Je fis alors la connaissance de Philippe Vigneault. Après quelques collaborations durant l'été, ce dernier finit par me proposer d'effectuer mes recherches au sein du CRD de Saint-Jean-sur-Richelieu, sous l'égide de Nicolas Tremblay, agronome et chercheur à Agriculture et Agroalimentaire Canada.

Au fil de nos discussions, je compris que la télédétection peinait à frayer son chemin dans le domaine de l'agriculture. Faisant alors le *buzz* dans les médias, le drone semblait être la solution miracle dans toutes les industries. Son utilisation en agriculture de précision était inéluctable : flexible et collectant des images à haute résolution, le drone ne pouvait que révolutionner ce domaine également. Cependant, des défis restaient à être surmontés.

D'un côté, les pilotes de drones devaient jongler entre une concurrence de plus en plus rude (la démocratisation du drone et les logiciels de pilotage faisaient que n'importe qui pouvait se prétendre pilote), et une réglementation de plus en plus stricte ; celle-ci étant une conséquence de celle-là. Pis, ces pilotes manquaient cruellement de connaissances en télédétection et en photogrammétrie, et peinaient à extraire une information utile et utilisable par leurs clients finaux, les agriculteurs.

De l'autre côté, les producteurs agricoles devaient maîtriser la gestion de leur champ, malgré les paramètres impondérables et les aléas météorologiques, afin d'en tirer un profit économique. Entre savoirs empiriques et données mesurées à l'aide d'instruments modernes, les images

droniques ajoutaient une couche supplémentaire d'information que les agriculteurs n'avaient pas les moyens d'exploiter.

Partant de ce constat, nous nous interrogeâmes sur la meilleure façon d'exploiter l'imagerie dronique en agriculture de précision, et plus particulièrement dans le contexte de la fertilisation azotée pour la culture du maïs, domaines d'expertise de Dr Tremblay. La question était de savoir comment la haute résolution spatiale inhérente à l'imagerie dronique pouvait contribuer à mesurer plus précisément les variations de la vigueur à travers le champ.

Plusieurs approches étaient possibles. Celle que nous avons choisie possédait, à nos yeux, les avantages suivants :

- pour l'agriculteur, elle apportait une information concrète et utile, à savoir le suivi des variations de la biomasse à travers l'espace et le temps pour une meilleure gestion des engrais azotés ;
- pour le pilote de drone, elle permettait une flexibilité des missions droniques dans l'acquisition des images : les plans de vol en quadrillage, tout comme les échantillonnages ponctuels étaient possibles, et un drone commercial doté d'une caméra RGB suffisait ;
- pour le spécialiste en télédétection, elle offrait des outils simples pour traiter les images droniques et en extraire l'information voulue rapidement ;
- enfin, pour tous, elle facilitait la compréhension du lien entre les notions de vigueur, biomasse, surface apparente et fertilisation.

De la coupe aux lèvres, nos travaux furent fortement marqués par de nombreuses contraintes. Tout d'abord, le coût prohibitif de certains capteurs tels le lidar ou les caméras hyperspectrales nous laissait uniquement l'option des caméras RGB et multispectrales. Ensuite, la disponibilité des ressources matérielles et humaines était clairement limitée : pilotes, équipe de soutien, drones, caméras, fours de séchage et autres équipements étaient également sollicités pour d'autres projets de recherche au CRD ; ces ressources étant intensément disputées durant la courte saison estivale. D'autant plus que chacune de nos campagnes de terrain nécessitait énormément de temps pour l'acquisition des images et la mesure des paramètres de la plante. Enfin, certains impondérables pouvaient empêcher, à la dernière minute, la réalisation des

missions selon le plan prévu : frasques de la météo québécoise, crashes et avaries des appareils, autorisations de vol refusées, etc.

S'ajoutaient également les contraintes liées à d'autres activités académiques, telles la participation aux conférences et l'enseignement de cours, professionnelles (soutien dans les projets du CRD, travail autonome). Enfin, mes responsabilités familiales et parentales ont été intensifiées avec l'arrivée de deux enfants, nés durant la présente thèse.

Après moult acrobaties et loopings, c'est donc à bout de carburant que j'atterris et que je vous livre le compte-rendu de ce voyage ô combien exotique. Soyez témoin compréhensif et juge magnanime de ce récit qui, peut-être, vous semblera maladroit et parfois alambiqué. Faisant le pont entre deux domaines extrêmement différents – la télédétection et l'agronomie –, ce travail nécessitait l'éclaircissement de certaines notions qui paraîtront triviales pour les spécialistes du domaine, mais qui pourraient s'avérer obscures pour les personnes non expertes.

L'aventure s'approchant de sa fin, je tiens encore à m'adresser à tous les membres de l'équipage qui m'ont soutenu et supporté. Cette thèse n'aurait pu arriver à terme sans eux, je les en remercie de tout cœur. Désormais, il ne me reste plus qu'à prendre un nouvel envol. Je salue, d'avance, les gens qui seront là, sur mon parcours, pour m'encourager, me soutenir et, qui sait, m'accompagner. Bonne lecture et bon vent à tous !

Chapitre 1. Introduction

1.1. Contexte général

Le concept de l'agriculture de précision est né au milieu des années 1980, avec l'arrivée de nouvelles technologies telles que les récepteurs GPS (*Global Positioning System*) et les capteurs de rendement embarqués dans des véhicules terrestres. La société internationale de l'agriculture de précision (ISPA, Monticello, Illinois, <https://www.ispag.org>) a adopté récemment la définition suivante :

“Precision Agriculture is a management strategy that gathers, processes and analyzes temporal, spatial and individual data and combines it with other information to support management decisions according to estimated variability for improved resource use efficiency, productivity, quality, profitability and sustainability of agricultural production” (International Society of Precision Agriculture, 2019, paragr. 1)¹.

Cette définition souligne l'importance des données dans la stratégie de gestion et, donc, le rôle fondamental des technologies de l'information et de la communication (TIC) qui sont mises à contribution pour collecter, traiter et analyser des données multisources aux fins de gestion durable et profitable des parcelles agricoles. Ce sont notamment les capteurs embarqués, assistés des récepteurs GNSS (système de navigation par satellites), qui permettent de collecter des informations précieuses et précises. Celles-ci peuvent être ensuite traitées de façon quasi automatique par des outils statistiques et cartographiques. Cette gestion informatisée permet aux agriculteurs d'avoir une connaissance plus accrue de la variabilité de leurs exploitations et de moduler leurs interventions (Zwaenepoel et Le Bars, 1997).

¹ Cette définition est également fournie en français sur le site web de l'International Society of Precision Agriculture (ISPA) : « L'agriculture de précision est une stratégie de gestion qui rassemble, traite et analyse des données temporelles, spatiales et individuelles et les combine avec d'autres informations pour orienter les décisions de gestion en fonction de la variabilité des plantes ou des animaux en vue d'améliorer l'efficacité d'utilisation des ressources, la productivité, la qualité, la rentabilité et la durabilité de la production agricole. » (<https://www.ispag.org/about/definition>).

Il est ainsi possible d'affirmer que l'agriculture de précision devient indissociable de la notion de variabilité (Shannon *et al.*, 2018) : variation de la culture, du sol et des caractéristiques environnementales en fonction de la distance et de la profondeur (variabilité spatiale) et en fonction du temps (variabilité temporelle). Cette variabilité, tant spatiale que temporelle, peut s'observer au niveau de :

- la fertilité, la texture et l'humidité du sol ;
- la vigueur et le rendement des plantes ;
- la topographie, la diversité microbienne (microbiome) et les populations de nuisibles et de ravageurs.

En résumé, l'agriculture de précision peut se définir comme la gestion de la variabilité spatiale et temporelle dans les champs en utilisant les TIC. Pour cela, elle vise à adapter les intrants (engrais, insecticides, herbicides et autres pesticides) et les pratiques agricoles en fonction des conditions locales d'un champ afin de faire la bonne intervention, au bon endroit, au bon moment et de la bonne manière (Pierce et Sadler, 1995).

Selon Tremblay *et al.* (2003), un des plus grands défis de l'agriculture de précision est la gestion de la fertilisation avec des engrais azotés ; ceci autant pour des raisons économiques qu'environnementales. La fertilisation doit répondre aux besoins des plantes cultivées à travers une stratégie élaborée en fonction du type de plante, des réserves du sol, des apports de fertilisants et de l'observation de la réponse des plantes aux pratiques adoptées (Petit et Jobin, 2005). Pour estimer la quantité optimale d'azote à fournir, il est nécessaire de développer des systèmes informatiques accessibles aux producteurs agricoles capables d'intégrer divers types de données et générer des informations utiles et pertinentes sur les doses d'azote à appliquer à travers un champ. Les données pourraient inclure, entre autres, les conditions des sols, les conditions météorologiques (pluviométrie, ensoleillement) ainsi que les données sur la vigueur de la végétation.

De tels systèmes informatiques ont été proposés. Parmi eux, SCAN (acronyme de *Soil, Crop, Atmosphere for N*) conçu et développé au CRD de Saint-Jean-sur-Richelieu (Agriculture et agroalimentaire Canada), est l'un des plus performants (Tremblay *et al.*, 2012). SCAN est actuellement commercialisé par la compagnie Effigis, sous la forme du système d'aide à la

décision FieldApex² (Effigis Géo-Solutions, Montréal, Québec). C'est dans le contexte des travaux du CRD pour améliorer la performance de SCAN que notre recherche s'est effectuée. Plus particulièrement, nous avons voulu savoir si les images de très haute résolution spatiale (THRS) prises par drone avec les capteurs de télédétection embarqués (caméras RGB – de l'anglais *Red (R)*, *Green (G)*, *Blue (B)* ; caméras multispectrales, etc.) et leurs traitements numériques associés peuvent constituer une alternative valable aux approches actuelles fondées pour la plupart sur les indices de végétation, dits indices de vigueur, estimées à partir de l'imagerie satellitaire et aérienne, ou le plus souvent, par des capteurs embarqués dans des véhicules terrestres.

1.2. La télédétection dronique pour évaluer la vigueur des cultures agricoles : problématique

Le dictionnaire Larousse définit la « vigueur » comme l'aptitude des végétaux à se développer³. Au moment de la germination, le producteur veut s'assurer que le semis a été réalisé correctement et estimer le taux de levée qui aura un impact sur le rendement futur (Mondo *et al.*, 2013). Puis, dans les premiers stades de croissance, la vigueur correspondra à l'état de croissance de la culture, indicateur de stress potentiels, qui dictera une stratégie d'application des intrants (engrais, pesticides, etc.). Enfin, lorsque la culture est rendue à maturité, une estimation du rendement pourrait être effectuée à travers la vigueur, avant même la récolte. Il est évident qu'en agriculture de précision, la connaissance de la vigueur d'une culture permet au producteur de moduler ses interventions en termes de fertilisation, d'irrigation ou de lutte contre les ravageurs.

Dans bon nombre d'applications en agriculture de précision, la télédétection conventionnelle (par satellite ou par avion) opère par modélisation du signal provenant d'une culture agricole. Les modèles (physiques, statistiques, etc.) mettent en relation les réflectances dans une ou plusieurs bandes spectrales (sous formes d'indices de végétation, par exemple) et un paramètre

² <https://www.fieldapex.com/fr/>

³ Vigueur. (s. d.). Dans Dictionnaire Larousse en ligne. Repéré à <http://www.larousse.fr/dictionnaires/francais/vigueur/81973?q=vigueur#81006>

biophysique de la végétation qui exprime d'une manière ou d'une autre la vigueur d'une culture agricole. De tels paramètres sont notamment la biomasse, l'indice de surface foliaire (LAI) ou la teneur en chlorophylle.

Avec l'avènement des drones comme plateformes supportant divers types de capteurs, il est attendu que la télédétection prenne encore plus d'ampleur en agriculture de précision. Ces « véhicules aériens télépilotes » sont en effet capables d'acquérir des images à très haute résolution spatiale, de l'ordre du centimètre voire du millimètre, et au moment voulu. La majorité des études effectuées avec des images acquises par drone (dans la suite du texte, nous utiliserons le terme « images droniques⁴ ») suivent les mêmes approches que dans le cas des images aériennes ou spatiales. Cependant ces approches, fondées notamment sur des indices de végétation, n'ont pas abouti à des résultats probants (Hunt *et al.*, 2013) ou n'ont pas suffisamment exploité la THRS des images droniques, comme nous le verrons dans la revue de littérature au chapitre 4. Puisque les applications réelles de la télédétection par drone restent à démontrer, nous sommes en droit de nous questionner sur les méthodes qui peuvent mettre à profit l'imagerie de très haute résolution afin de cartographier la vigueur d'une culture agricole.

1.3. Objectifs et hypothèses de recherche

L'objectif principal de notre recherche est de développer une méthode d'estimation de la vigueur d'une culture agricole fondée sur des images droniques de très haute résolution. Nous visons à explorer la capacité de ces images à fournir une information pertinente sur les paramètres de croissance de la plante. Plus spécifiquement, notre recherche s'appuie sur l'imagerie dronique pour mesurer la vigueur d'une culture en rangs, le maïs (*Zea Mays* L.), dans le cadre de la fertilisation azotée. Nos travaux consistent principalement à identifier les meilleures conditions d'acquisition des images droniques et à développer des procédures visant à automatiser le traitement pour extraire de l'information pertinente afin de caractériser les paramètres biophysiques de la végétation considérés comme proxy de la vigueur.

⁴ L'adjectif *dronique* nous permet d'alléger le texte pour, notamment, qualifier les images acquises par drone. Ce terme paraît plus répandu (environ 7350 résultats retournés par Google, fin mars 2016 ; et 9970 en octobre 2019) que le nom *dronautique*.

Pour atteindre cet objectif, nous nous fixons les objectifs spécifiques suivants :

1. Évaluer l'apport du contenu spectral des images droniques à la cartographie de la vigueur d'un champ de maïs ;
2. Évaluer l'apport de paramètres géométriques d'une canopée comme la fraction du couvert végétal à la cartographie de la vigueur d'un champ de maïs ;
3. Développer une procédure qui va de l'acquisition des images droniques à l'extraction de l'information sur la vigueur d'une culture agricole.

En combinant la haute définition des caméras et la basse altitude des vols de drone, il en résulte une résolution spatiale de l'ordre du centimètre voire du millimètre ; ce qui permet de discerner des détails très fins au niveau de la végétation étudiée. Par conséquent, nous formulons l'hypothèse qu'il est désormais possible de mesurer des paramètres plus justes et plus précis qui se rapportent directement à la plante et qui reflètent mieux la variabilité spatiale de la vigueur, en nous basant principalement sur les informations apportées par la très haute résolution spatiale des images. C'est sur cette hypothèse que s'appuie notre travail de recherche, qui visera donc à la valider.

À cet effet, nous postulons également que les méthodes classiques, propres à la télédétection par satellite (recours aux indices de végétation, classification par approche pixel...), ne sont plus appropriées quand il s'agit d'exploiter la très haute résolution spatiale.

1.4. Contributions de la recherche à l'avancement des connaissances

En télédétection, jamais la « convergence des résolutions » n'a été aussi proche d'être réalisée au travers d'une même technologie. Combinant à la fois la flexibilité de déploiement (excellente résolution temporelle), l'acquisition d'images à l'échelle millimétrique (très haute résolution spatiale) et la capacité d'embarquer des capteurs variés – caméras standard RGB, capteurs multispectraux, voire hyperspectraux, lidar... – et performants (pour une meilleure résolution spectrale et radiométrique), le drone est un outil prometteur qui présente *a priori* des avantages indubitables. Malgré cela, il est loin d'avoir livré tout son potentiel et peu d'applications

agricoles sont issues de cette technologie⁵. En ce sens, notre étude cherchera à exploiter au mieux les images acquises par drone, pour contribuer à une utilisation plus répandue et plus efficace de cette technologie.

Notre démarche se révèle originale dans le sens où elle prend le parti d'exploiter la très haute résolution spatiale, plutôt que de miser seulement sur l'information spectrale à travers les indices de végétation (cf. hypothèses à la section précédente), pour améliorer la classification des images et l'extraction des paramètres biophysiques, et ainsi mieux caractériser le développement de la culture.

En relevant ce défi, notre étude cherche à contribuer à la compréhension de la variabilité spatiale afin de soutenir la production agricole à travers les outils de géomatique et de télédétection. Si le succès est au rendez-vous, nous entrevoyons de nombreuses contributions possibles, tant économiques (meilleur rendement agricole), environnementales (diminution de l'utilisation des engrais, des pesticides) que scientifiques (recours à de nouvelles façons d'utiliser l'imagerie de télédétection).

1.5. Organisation de la thèse

La thèse est divisée en trois parties. Dans la première partie (chapitres 2 à 5), nous examinerons l'état de l'art dans les applications des images droniques en agriculture de précision et plus particulièrement dans l'estimation de la vigueur, puis nous décrirons brièvement le cadre général de nos expériences. Dans la deuxième partie (chapitres 6 et 7), nous explorerons la pertinence des indices de végétation, notamment le NDVI, pour extraire l'information sur la vigueur dans le contexte de la THRS. Dans la troisième partie (chapitres 8 à 11), nous présenterons les principaux résultats de nos expériences.

⁵ Nous ne considérons ici que le champ d'application de la télédétection. Des innovations agricoles avec les drones ont déjà lieu, notamment en termes d'applications d'engrais ou de pesticides.

PARTIE I : LA TÉLÉDÉTECTION DRONIQUE

Le but de cette partie est de présenter l'état de l'art dans les applications de la télédétection dronique en agriculture de précision. Le chapitre 2 fait état de la technologie des drones pour l'acquisition des images de très haute résolution des cultures agricoles. Le chapitre 3, pour sa part, présente en détail les méthodes de traitement et d'analyse d'images pour l'extraction de l'information sur la vigueur des cultures agricoles. Ensuite, le chapitre 4 fait la synthèse des avantages et des limitations des drones, et présente, à travers la littérature, comment les résultats obtenus à partir des images droniques se comparent avec les autres plateformes. Finalement, nous décrirons au chapitre 5 le contexte général de notre recherche, les conditions expérimentales ainsi que les traitements de base.

Chapitre 2. Télédétection dronique appliquée en agriculture de précision : état de l'art

Le drone est une plateforme de télédétection assez récente, par rapport aux satellites ou aux avions. Volant à une altitude beaucoup plus basse que ces derniers, le drone offre de nouvelles façons de voir la végétation. Par sa flexibilité opérationnelle, il peut être déployé rapidement et facilement pour acquérir les images.

Dans ce chapitre, nous définirons les drones comme plateformes de télédétection (section 2.1) et présenterons un bref aperçu de la technologie des drones (section 2.2) et des capteurs embarqués (section 2.3), en mettant l'accent sur ceux disponibles au CRD d'Agriculture Canada et utilisés dans cette recherche. Le lecteur intéressé à revoir plus en détails cette technologie est référé à Krishna (2018), entre autres.

2.1. Les drones : définitions

Les drones font partie des plateformes de « télédétection basse altitude » (TBA). Ces plateformes survolent le terrain à des altitudes, par rapport au sol, représentant quelques dizaines de mètres et pouvant atteindre plusieurs centaines de mètres, cette limite du plafond de vol étant surtout de nature réglementaire. En dessous de 2 m d'altitude, nous parlons plutôt de la télédétection proximale, où des véhicules terrestres sont utilisés comme plateformes supportant les capteurs de télédétection. À part les drones, les plateformes TBA incluent notamment les cerfs-volants, les ballons, les fils suspendus, les poteaux et perches, etc.

Le rapport du Commissariat à la protection de la vie privée du Canada (2013) désigne le mot « drone », ou plus précisément l'expression « véhicule aérien sans pilote », comme :

un terme polyvalent qui désigne tout véhicule pouvant être utilisé sur des surfaces ou dans l'air sans personne à bord pour le commander et dont les dimensions, la forme, la vitesse et une foule d'autres caractéristiques peuvent varier. Il peut s'agir d'un modèle réduit d'aéronef acheté dans un commerce, d'un mini-hélicoptère utilisé par certains corps de police ou d'un aéronef de grandes dimensions envoyé en zone de guerre (Commissariat à la protection de la vie privée du Canada, 2013, p. 4).

Réservé initialement à une utilisation militaire (Krishna, 2018), le drone se déploie désormais dans le domaine civil. Que ce soit pour le loisir, pour la recherche ou pour des fins commerciales, ses applications sont nombreuses et variées (prises de vue, surveillance, transport, intervention physique, etc.) tout comme ses différentes appellations : « véhicule aérien sans pilote », « véhicule aérien non habité », « système d'aéronef non habité », « système d'aéronef piloté à distance ». Transports Canada, qui est le ministère chargé de faire respecter la réglementation concernant les vols de drone, a adopté le terme « système d'aéronef télépiloté » tel que défini dans le Règlement de l'aviation canadien (Ministère de la Justice du Canada, 2020). Ces termes, plus ou moins apparentés, cherchent à traduire les termes anglais correspondants : *Unmanned Aerial Vehicle (UAV)*, *Unmanned Aircraft System (UAS)* et *Remotely Piloted Aircraft System (RPAS)*, où le véhicule désigne spécifiquement l'aéronef (c'est-à-dire le drone) tandis que le système renvoie à l'ensemble constitué par l'aéronef et les composantes connexes nécessaires pour le faire fonctionner (base de contrôle, charges utiles, capteurs, équipement de communication et de navigation, voire même opérateurs humains...). L'expression « système d'aéronef piloté à distance » est un néologisme proposé et recommandé par l'Organisation de l'aviation civile internationale (OACI) pour souligner le fait que le système n'est pas entièrement automatique et qu'il y a toujours un pilote qui commande l'appareil à distance (Conseil de l'Union européenne, 2012).

Comme ces termes sont souvent interchangeable, et pour des raisons de concision, nous emploierons dans la suite du texte, le mot « drone » ou l'acronyme anglais UAV pour désigner le vecteur équipé de ses capteurs.

Selon Krishna (2018), l'industrie dronautique s'est intéressée à l'agriculture surtout depuis le début des années 2000 et le drone s'est répandu dans les champs agricoles dans les 5 à 10 dernières années. De militaire, le drone devient donc agricole, et « s'avère un outil précieux et novateur pour positionner, mesurer et diagnostiquer différents problèmes reliés à la conservation et à la santé des sols agricoles » (Perreault *et al.*, 2014).

2.2. Typologie des drones

Le tableau 2.1 présente les principaux types de drones utilisés en agriculture de précision. Les drones à voilure fixe (dits également ailes volantes) sont des avions miniatures, propulsés par

une ou plusieurs hélices. Très légers, ces engins ont une grande autonomie (30 à 45 minutes de vol) mais sont sensibles aux vents. Les drones à voilure tournante (ou multicoptères) possèdent des rotors qui permettent la sustentation : les modèles les plus courants ont 4 ou 6 rotors. Ces appareils ont une autonomie plus réduite (15 à 20 minutes de vol) et couvrent donc un terrain plus petit, mais sont moins sensibles aux vents et ont une charge utile plus élevée que les ailes volantes. Enfin, un type hybride de drone a récemment fait son apparition, qui combine les rotors d'un multicoptère permettant le décollage et l'atterrissage à la verticale (*vertical take-off and landing*, VTOL), et les ailes fixes d'un avion pour une meilleure autonomie en vol.

Tableau 2.1 – Typologie des drones

	Voilure fixe ou ailes fixes	Voilure tournante ou multicoptère	Voilure fixe à décollage vertical
Autonomie	30–45 minutes	10–20 minutes	30–45 minutes
Altitude de vol AGL†	entre 50 m* et 120 m**	< 120 m**	< 120 m**
Stabilité de la plateforme	Sensible aux vents	Moins sensible aux vents	Sensible aux vents
Couverture	Large	Limitée	Large
Exemples	 eBee (senseFly)	 Phantom 3 (DJI)	 WingtraOne (Wingtra)

* Altitude minimale de vol recommandée, voire contrainte, par les logiciels de vol pour éviter les turbulences d'air liées à la topographie.

** Plafond fixé par Transport Canada (400 pieds) dans les zones aériennes non contrôlées (classe G).

† Above ground level : altitude au-dessus du sol

2.3. Capteurs embarqués dans les drones

Actuellement, plusieurs types de capteurs (de télédétection) peuvent être embarqués dans un drone : caméras standard ou modifiées, caméras multispectrales et hyperspectrales, altimètre lidar. Un aperçu de ces capteurs est donné par la suite en mettant l'accent sur les caméras opérant dans le visible et proche infrarouge (PIR) utilisées dans cette recherche.

2.3.1. Caméra RGB

Un des capteurs les plus répandus pour l'acquisition des images droniques est la caméra RGB (*Red Green Blue*, en anglais), qui est une caméra commerciale et standard, c'est-à-dire offerte pour le grand public. Cette caméra a la particularité d'être constituée d'une seule matrice de photodétecteurs qui peuvent être de type CCD (*charge coupled device*) ou CMOS (*complementary metal oxide semiconductor*). Chaque photodétecteur est couvert d'un filtre optique coloré afin d'isoler le rayonnement dans le bleu, le vert ou le rouge (Phelippeau, 2009). Compte tenu de la sensibilité de l'œil humain dans le vert, il y a deux fois plus de photodétecteurs verts que de rouges ou de bleus. Différents arrangements des photodétecteurs bleus, verts, rouges sont disponibles, le plus connu étant celui de Bayer (figure 2.1).

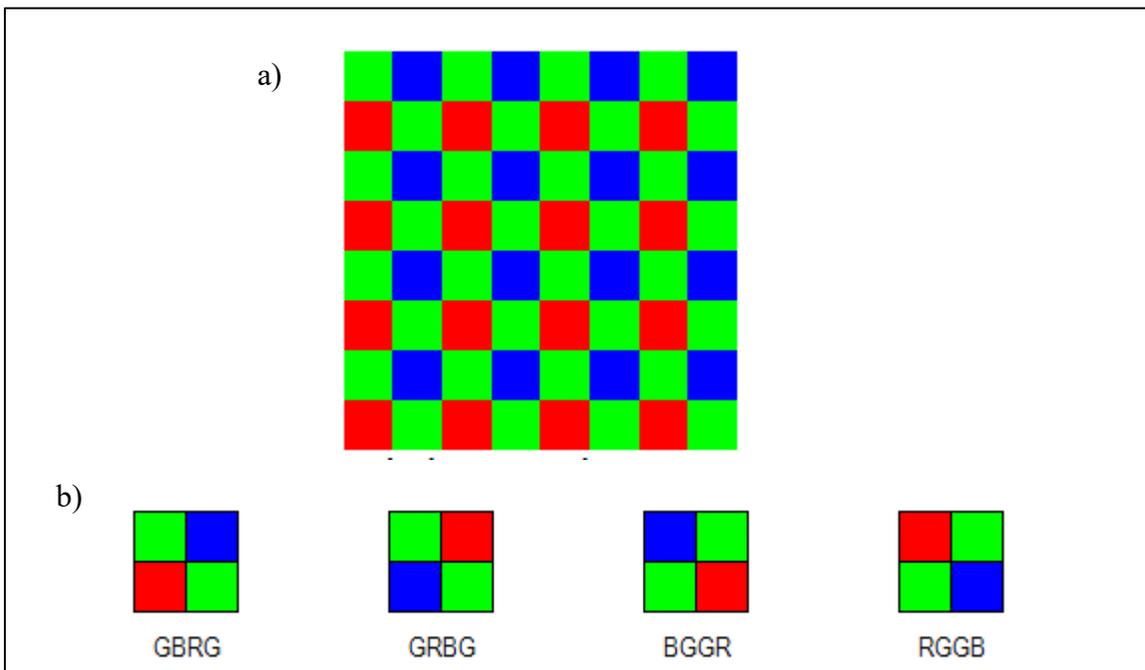
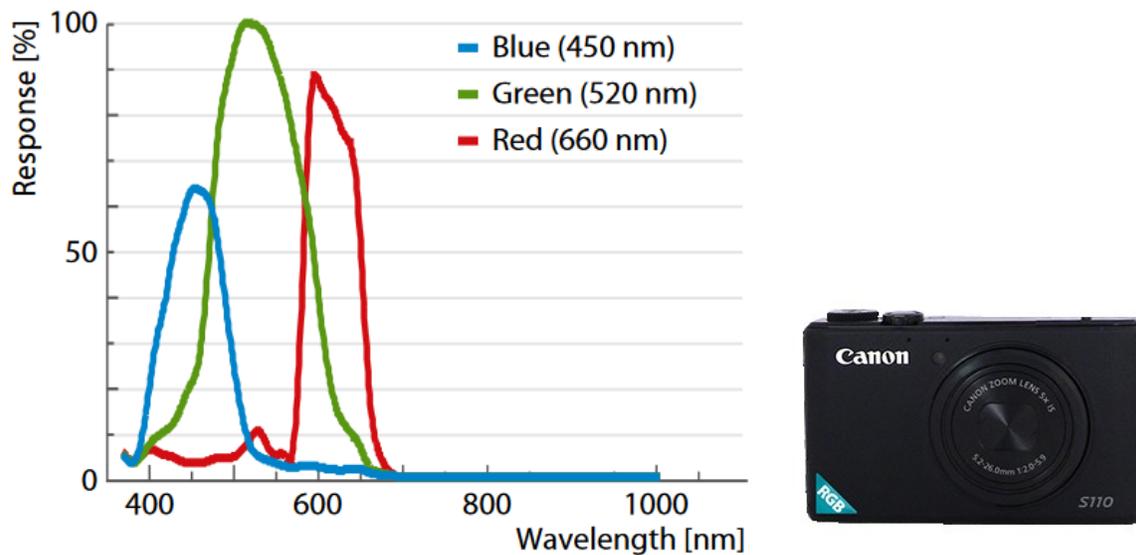


Figure 2.1 – Matrice de Bayer (1976) : a) Exemple de matrice avec l'arrangement GBRG ; b) Configurations possibles du premier bloc de 4 pixels d'une matrice de Bayer.

Pour générer une image complète RGB contenant les trois bandes spectrales pour chaque pixel de la matrice, il est alors nécessaire de recourir à une opération d'interpolation, appelée le dématriçage ou la débayerisation. Cette opération consiste à estimer pour chaque photodétecteur, les deux autres couleurs manquantes à partir des valeurs des photodétecteurs voisins : c'est donc une opération de filtrage spatial avec un noyau de convolution. Plusieurs

algorithmes de dématricage existent, les plus simples étant le plus proche voisin et l'interpolation bilinéaire, les plus complexes étant adaptatifs et cherchant à délimiter correctement les contours des objets (Phelippeau, 2009).

Il est à remarquer que ces caméras possèdent des bandes spectrales très larges, qui se superposent (figure 2.2), et sont souvent affectées par les effets de vignettage et de distorsions géométriques (voir section 3.2.1).



Les caméras RGB sont particulièrement utiles pour obtenir des images à THRS présentant des couleurs naturelles, permettant l'identification et la localisation rapides des phénomènes visibles à l'œil nu, tout en offrant la possibilité d'effectuer des mesures de distance et de volume. Il faut, en effet, souligner qu'il est également possible d'obtenir un modèle 3D de la scène avec une caméra RGB, par la technique de *Structure from Motion* (SfM), comme nous le verrons à la section 3.3.4.1.

2.3.2. Caméra RGB modifiée

Il s'agit ici d'une caméra RGB standard qui a été modifiée pour être sensible au rayonnement proche infrarouge (PIR) ou ultraviolet (UV). Pour les applications en agriculture, le PIR est intéressant, compte tenu de sa très grande sensibilité aux espèces végétales et à l'état de la végétation.

Les photorécepteurs en silicium d'une caméra sont, en temps normal, sensibles au PIR mais un filtre interne passe-haut est posé sur le capteur pour bloquer le rayonnement PIR (Lebourgeois *et al.*, 2008; Rabatel *et al.*, 2014). En retirant ce filtre et en appliquant un filtre passe-bas qui bloque les longueurs d'onde du bleu, le canal bleu enregistre désormais uniquement la lumière PIR (Ziglado *et al.*, 2001). Puis, l'information sur le signal PIR issu du canal bleu est soustraite des signaux rouge et vert pour corriger ces deux derniers canaux ; ce qui permet d'obtenir une caméra modifiée de type Rouge-Vert-PIR (*RGNIR*), dont un exemple de réponse spectrale est montré à la figure 2.3.

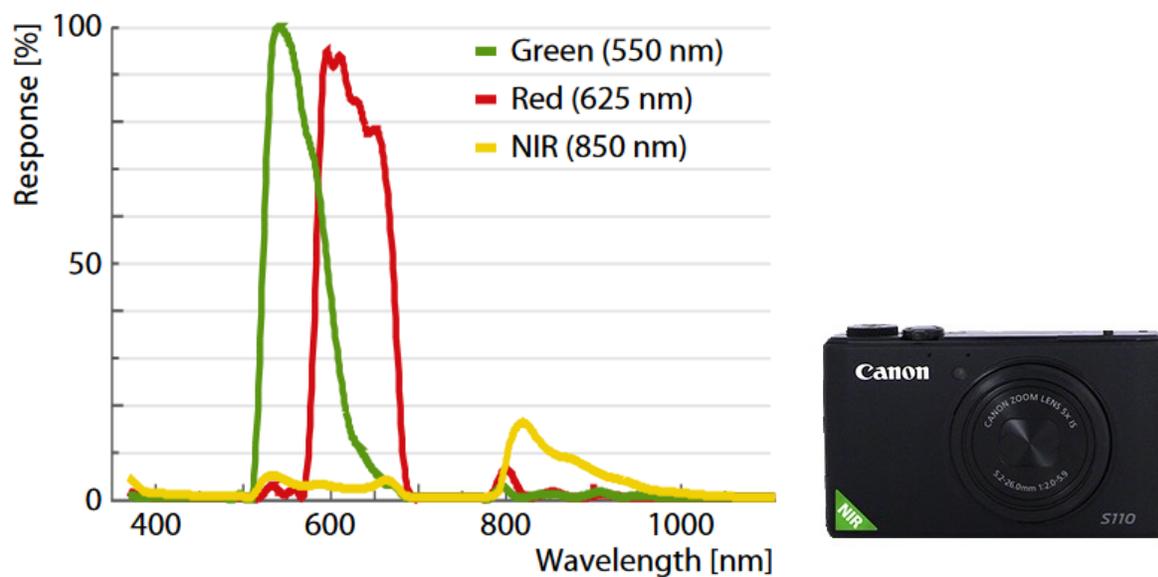


Figure 2.3 – Réponse spectrale de la caméra modifiée Canon S110 NIR (source : Sensefly).

Une autre méthode, proposée par Hunt *et al.* (2010), consiste à appliquer un filtre coupe-bande qui bloque la lumière rouge entre 610 et 725 nm ; ce qui permet d'obtenir une caméra de type bleu-vert-PIR (*BGNIR*), sans avoir à effectuer les opérations de post-traitement comme dans la méthode de Ziglado *et al.* (2001).

Les mêmes effets et défauts sont observables qu'avec la caméra RGB standard. Cependant, un défaut supplémentaire s'ajoute : chaque pixel est désormais légèrement sensible au PIR à cause de l'absence du filtre passe-haut.

Les caméras modifiées visent à imiter les caméras multispectrales, à un coût moindre ; en contrepartie, la qualité en termes de résolution spectrales et de calibration radiométrique reste

largement inférieure. Elles sont utilisées dans les mêmes applications que les caméras multispectrales, notamment pour la mesure d'indices de végétation (voir section 2.3.3).

2.3.3. Caméra multispectrale

Les caméras multispectrales utilisées habituellement en agriculture de précision présentent les bandes spectrales suivantes : le bleu, le vert, le rouge et le PIR. Souvent une bande *red edge* (« point d'inflexion rouge », autour de 725 nm) est rajoutée, et parfois la bande bleue est absente.

À la différence d'une caméra RGB, les bandes spectrales sont beaucoup plus étroites et il y a peu ou pas de superposition entre elles (figure 2.4). Les caméras les plus sophistiquées chercheront à réduire les effets de vignettage et de distorsions géométriques, et à effectuer un étalonnage radiométrique de façon automatique. De plus, l'opération de dématricage n'a pas lieu d'être puisque chaque bande spectrale est enregistrée sur une matrice différente de photodétecteurs (Assmann *et al.*, 2018).

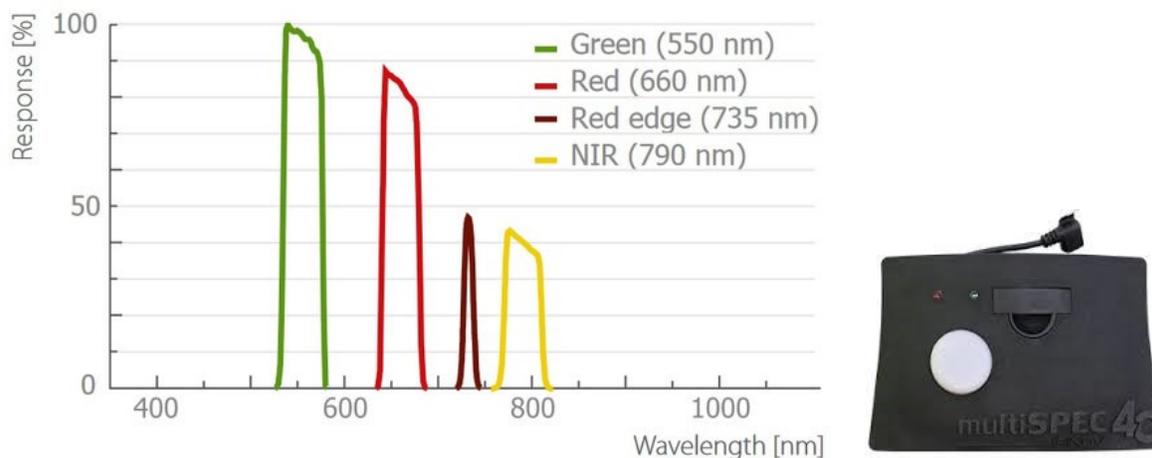


Figure 2.4 – Réponse spectrale de la caméra multispectrale Airinov Multispec 4C (source : Airinov).

Dans ce sens, une caméra multispectrale est en fait un ensemble de plusieurs capteurs monochromatiques disposés côte-à-côte, comme on peut le voir sur la figure 2.5. C'est pourquoi un effet de parallaxe se produit (figure 2.6). Il est alors nécessaire d'effectuer une opération d'alignement des bandes (Rabatel et Labbé, 2016).



Figure 2.5 – Exemples de caméras multispectrales : à gauche, la Micasense RedEdge et, à droite, la Parrot Sequoia (sources : Micasense et Parrot).

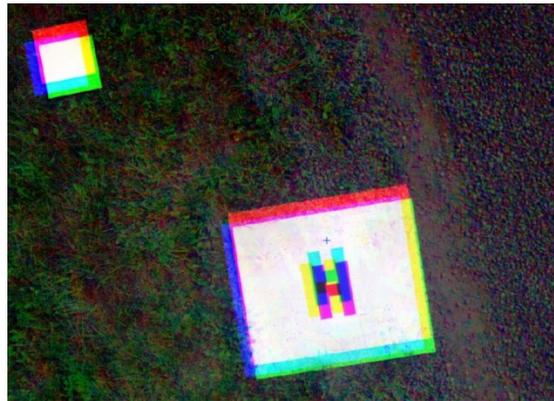


Figure 2.6 – Visualisation de l'effet de parallaxe en superposant les 3 bandes (rouge, vert, bleue) de la caméra Micasense RedEdge. Il est possible de voir que les bandes ne sont pas bien alignées.

Par leur qualité spectrale, les caméras multispectrales sont surtout utilisées pour extraire de l'information sur la réflectance des objets étudiés (voir section 3.3.2), à travers notamment les indices de végétation. Cependant, des corrections radiométriques doivent être minutieusement réalisées pour bien exploiter la réflectance (voir section 3.2.2).

2.3.4. Caméra hyperspectrale

Une caméra hyperspectrale est capable d'acquérir une scène sur une centaine de bandes spectrales. À la différence d'une caméra multispectrale, ces bandes sont beaucoup plus étroites et échantillonnent de façon quasi continue le spectre électromagnétique dans la plage considérée (par exemple de 400 nm à 1000 nm).

La caméra hyperspectrale embarquée sur un drone est le plus souvent de type capteur à barrettes (*push broom scanner*) : le capteur acquiert la scène spatialement une ligne à la fois, mais pour toutes les bandes spectrales en même temps. C'est le mouvement de la plateforme qui permet

d'obtenir l'image en 2D. L'information obtenue permet ainsi de produire un cube de données, analysable dans les deux dimensions spatiales (x et y) et dans la dimension spectrale (λ).

Pour être pleinement exploitables, ces caméras nécessitent encore une certaine miniaturisation (Fossi, 2016) pour être facilement transportées sur un drone. De plus, les algorithmes d'orthorectification doivent être capables de prendre en compte les vibrations et le mouvement de la plateforme. Enfin, la quantité phénoménale de données collectées par ce type de capteur pose un défi dans le traitement de ces données.

La fine résolution spectrale de ce type de caméra offre la possibilité d'investiguer la réponse spectrale des objets étudiés, puisque certaines longueurs d'onde sont plus sensibles à certaines caractéristiques de la culture ou du sol (Mulla, 2013).

2.3.5. Caméra thermique

L'imagerie thermique, ou thermographie, consiste à capter et à mesurer les rayonnements infrarouges émis par les objets d'une scène. L'image obtenue permet d'avoir une mesure à distance de la température des objets observés. Cependant, cette énergie mesurée ne fournit pas directement la température réelle du corps mais sa température de brillance, c'est-à-dire une température apparente, affectée par l'émissivité du corps en question. Il est ainsi nécessaire d'estimer ce paramètre d'émissivité, qui varie d'un matériau à l'autre, pour avoir une mesure juste de la température de la surface étudiée. Pour la végétation verte qui contient beaucoup d'eau, ceci n'est pas un problème important car son émissivité est proche de l'unité.

En agriculture, les thermographies servent surtout à détecter le stress hydrique d'une plante, qu'il soit dû à un manque en eau ou à une maladie. Cependant, Fang et Ramasamy (2015) soulèvent les contraintes liées à la mesure des températures, sensibles aux variations des conditions environnementales (notamment date et heure des mesures, température et humidité de l'air). Par ailleurs, cette technique ne peut permettre d'identifier précisément la cause du stress, c'est-à-dire l'infection.

2.3.6. Systèmes lidar et radar

L'altimètre lidar (pour *light detection and ranging*) est une technique de mesure de distance qui utilise le rayonnement laser monochromatique dans le visible, l'ultraviolet (UV) ou l'infrarouge

(IR). Un émetteur laser produit des impulsions qui vont se réfléchir sur les cibles avant de revenir vers un récepteur : le délai entre l'émission d'une impulsion et son retour permet de déterminer la portée des cibles. Ce système peut être embarqué sur avion, hélicoptère, plateforme terrestre, et récemment sur drone. En agriculture, le lidar permet principalement de mesurer la hauteur des plantes et de caractériser l'architecture de la canopée (Madec *et al.*, 2017).

Le radar (de l'anglais *radio detection and ranging*) est, comme le lidar, un système de détection active, basé sur le principe de l'écholocation. Dans ce cas-ci, ce sont des ondes radio qui sont émises par l'antenne radar : la portion du spectre électromagnétique utilisée se situe entre 1 mm et 1 m, soit une fréquence entre 300 GHz et 300 MHz. Ces ondes radio sont particulièrement sensibles à la structure géométrique et aux propriétés diélectriques des objets. En agriculture, le radar permet ainsi d'identifier les cultures, d'extraire des paramètres sur le sol et la végétation (notamment, la présence d'humidité) et d'estimer le rendement (Liu, Chen, *et al.*, 2019).

Chapitre 3. Traitements et analyses des images droniques

Si l'utilisation du drone comporte des avantages certains, il n'en demeure pas moins que la chaîne de traitements est longue et fastidieuse, de la planification de l'acquisition jusqu'à la production des images, et des prétraitements jusqu'à l'extraction de l'information (figure 3.1). Nous discuterons de ces étapes dans le contexte d'extraction des informations sur la vigueur d'une culture agricole, en particulier celle du maïs.

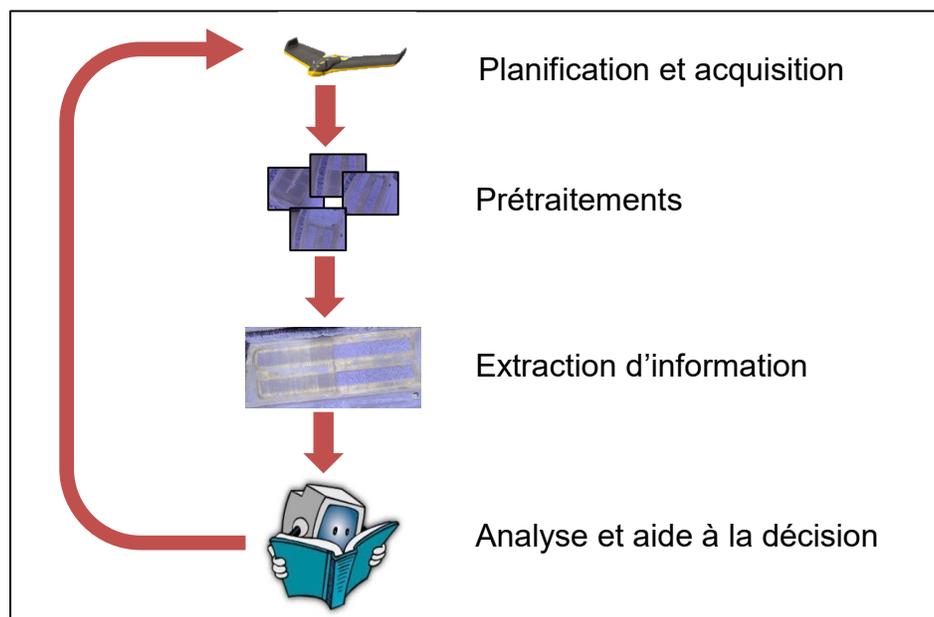


Figure 3.1 – Étapes de traitement et d'analyse des images droniques.

3.1. Planification et acquisition d'images

3.1.1. Plan de vol

Une préparation précise et adéquate du plan de vol est requise pour aboutir aux conditions les plus propices pour le prétraitement des images : choix du drone et des capteurs, altitude de vol, zone à survoler, orientation des lignes de vol, taux de recouvrement des images, etc.

Des logiciels spécialisés existent pour aider à planifier un vol. La figure 3.2 présente des exemples de plans de vol. Le survol en quadrillage est souvent utilisé. Les images sont acquises à intervalles réguliers de telle sorte qu'il existe un recouvrement suffisant entre les images consécutives (longitudinalement, c'est-à-dire dans le sens du vol) et les images voisines

(latéralement, c'est-à-dire d'une ligne de vol à l'autre). Selon les recommandations de Pix4D, dépendamment des éléments présents dans la scène étudiée et le capteur utilisé, le taux de recouvrement minimal peut aller de 50 % (bâtiments avec caméra RGB) à 75 % (végétation avec caméra multispectrale), voire 90 % (végétation avec caméra thermique)⁶. Ces estimations varient selon les auteurs et les expériences qui ont été effectuées : Assmann *et al.* (2018) recommandent un recouvrement minimal de 75 % (en longitudinal et en latéral) pour les vols avec caméras multispectrales ; tandis que Xing *et al.* (2010) suggèrent un recouvrement de 55 % longitudinalement et de 30 % latéralement pour des images RGB. Torres-Sánchez *et al.* (2018) ont comparé plusieurs niveaux de recouvrement pour la reconstruction du modèle numérique de surface (MNS) de deux oliveraies à l'aide d'une caméra RGB : à la fin de leur étude, ils ont préconisé un recouvrement de 95 % en longitudinal et de 65 % en latéral.

Si un taux de recouvrement élevé permet une meilleure précision des produits dérivés tels que le MNS ou l'orthomosaïque ; en contrepartie, il engendre un temps d'acquisition plus long, et génère beaucoup d'images à stocker et à traiter (Assmann *et al.*, 2018; Sadeq, 2018; Torres-Sánchez *et al.*, 2018).



Figure 3.2 – Trois différents plans de vol : (A) lignes de vol parallèles; (B) lignes en quadrillage; (C) lignes de vol en boîte-mobile. Les lignes jaunes représentent les lignes de vol et les points verts les points de passage le long de la ligne de vol pour la navigation GNSS (Shi *et al.*, 2016).

⁶ Voir ces pages d'aide de Pix4D :

- <https://support.pix4d.com/hc/en-us/articles/203756125-How-to-verify-that-there-is-enough-overlap-between-the-images>

- <https://support.pix4d.com/hc/en-us/articles/115002471546-Image-acquisition>

3.1.2. Échelle d'intervention

Un élément majeur à prendre en compte lors de la planification d'une mission est l'échelle d'intervention souhaitée, qui correspond à la taille et à la configuration spatiale des zones sur lesquelles l'agriculteur envisage d'intervenir.

Historiquement, le producteur gère son champ de façon uniforme (figure 3.3d) et préférera appliquer une dose maximale de fertilisant qui conviendra à l'ensemble du champ d'après son estimation personnelle. Avec l'avènement de l'agriculture de précision, la gestion se fait désormais par zones (figure 3.3f) et, d'après Mulla (2013), devrait se faire sur mesure pour chaque plante individuelle (figure 3.3a). Le mode de gestion plant-par-plant se révèle d'autant plus pertinent que le rendement du maïs peut être extrêmement variable d'un plant à l'autre (Freeman *et al.*, 2007; Kelly *et al.*, 2015; Martin *et al.*, 2005; Teal *et al.*, 2004). Par conséquent, Martin *et al.* (2005) ont recommandé de traiter les facteurs influençant le rendement, à une échelle inférieure à 0,5 m. Ce mode de gestion est particulièrement adapté aux petites exploitations, puisqu'il nécessite de la main-d'œuvre et des ressources humaines ; ce qui est souvent le cas dans les pays en développement (Omara *et al.*, 2016).

La gestion par rangs (figure 3.3b) se bute encore à l'incapacité des applicateurs d'engrais à moduler rapidement la quantité d'azote pour s'adapter à cette variabilité linéaire (P. Fulton *et al.*, 2005; Tumbo *et al.*, 2007) : comme l'ont soulevé Chan *et al.* (2004), les diverses composantes de la machinerie pour l'application à taux variable ne répondent pas instantanément au taux désiré. Pour l'instant, ce serait plutôt la gestion par tronçons (figure 3.3c) qui serait envisageable, bien que les applicateurs, réglés pour arroser plusieurs rangs à la fois, aient encore de la difficulté à gérer la variabilité entre rangs. La transition entre chaque tronçon ne saurait être aussi rapide non plus. D'ailleurs, dans leur expérience, Edmonds *et al.* (2013) ont dû injecter l'engrais dans le sol manuellement à l'aide de seringues, pour montrer la nécessité d'appliquer des taux variables à chaque rang de maïs.

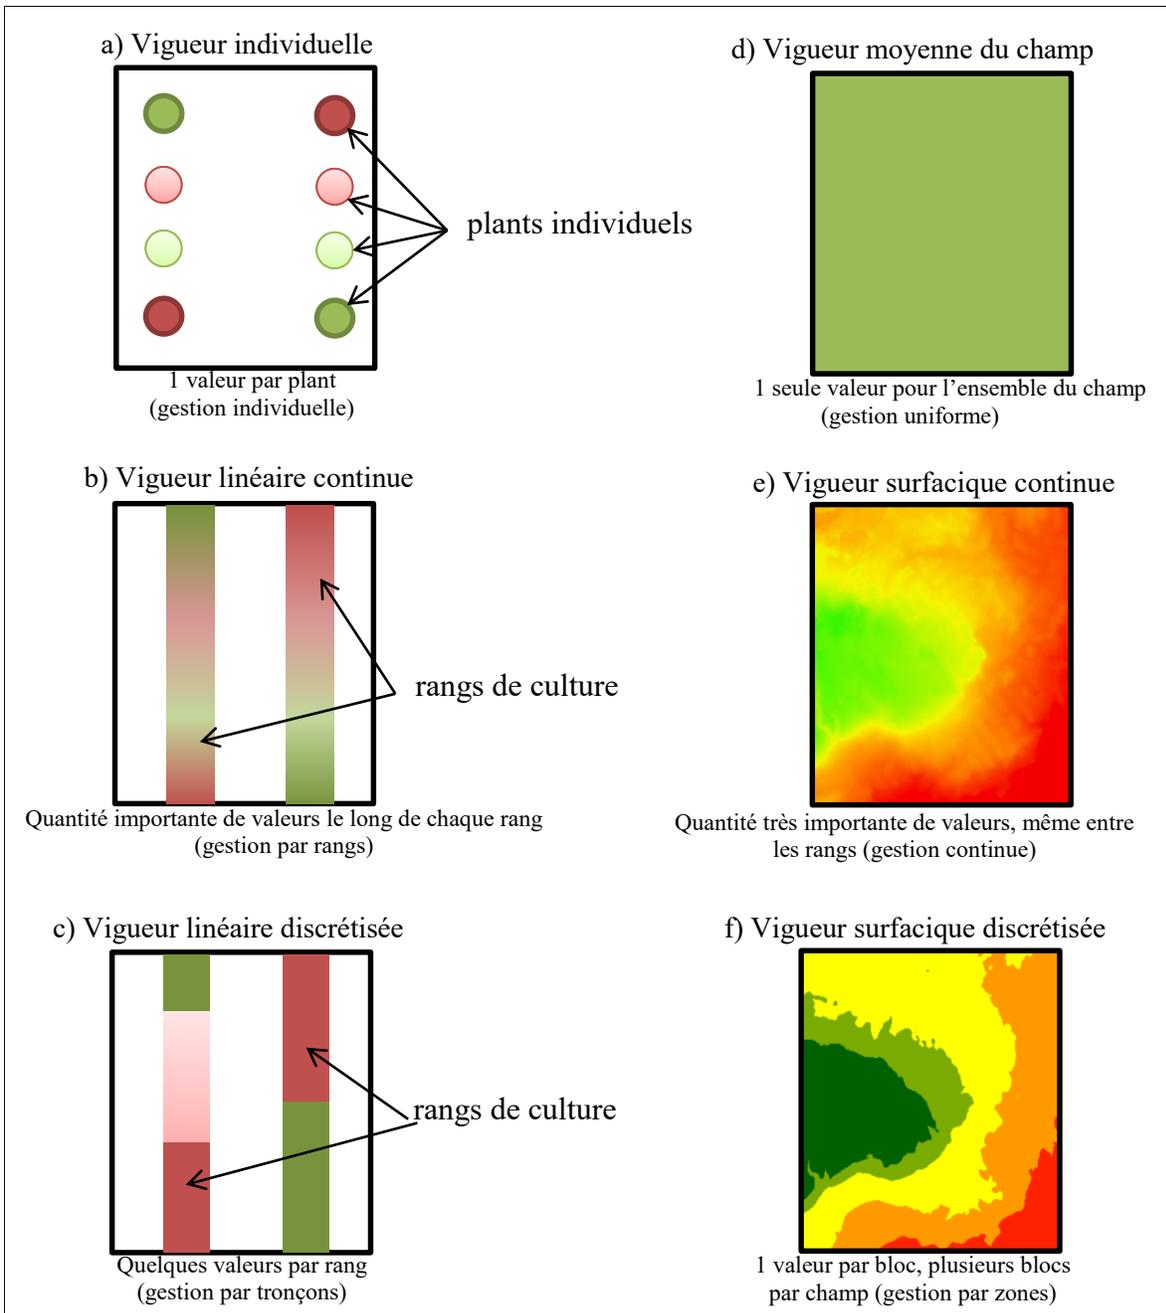


Figure 3.3 – Exemples d'échelles de mesure de la vigueur et le mode de gestion correspondant.

Quant à la gestion continue (figure 3.3e), elle n'a pas de sens pour une culture en rangs : les valeurs de vigueur hors rangs sont théoriquement nulles. L'intervention devrait donc tenir

compte de la position des rangs de culture⁷, ce qui conduirait au mieux à une version dégradée de la gestion par rangs avec les mêmes contraintes techniques. Ne pas tenir compte de l'existence de ces rangs aboutirait à une certaine perte économique (comme dans le cas de l'épandage aérien).

3.1.3. Échelle d'observation

Idéalement, l'échelle d'observation devrait être la même que l'échelle d'intervention. Elle dépend donc des limites technologiques liées à la résolution spatiale des capteurs. Les images satellitaires, avec une résolution spatiale de l'ordre du mètre, permettent seulement une gestion uniforme ou au mieux par zones.

Les images droniques permettent une grande échelle d'observation avec une résolution de l'ordre du centimètre et du millimètre. Selon la nomenclature de Morissette (2010), on parlera ainsi de centi-résolution ou de milli-résolution⁸. Cette fine échelle d'observation autorise désormais toutes les échelles d'intervention possibles. Pour l'intervention la plus précise, c'est-à-dire la gestion plant-par-plant, la résolution doit permettre aux algorithmes de distinguer chaque plant individuellement. Cela suppose donc d'être capable d'en délimiter les contours : nous estimons qu'il faudrait une résolution de l'ordre du millimètre pour correctement observer les détails de chaque plant. Rasmussen *et al.* (2013) ont constaté que la segmentation végétation-sol aux premiers stades de croissance de l'orge nécessitait des images de résolution ultrafine (<5 mm). Hunt *et al.* (2014) ont travaillé sur des images simulées de drone d'une résolution de 1 mm et en ont obtenu une meilleure estimation de la biomasse de seigle qu'avec une approche basée sur les indices de végétation moyennés à 1 m.

De plus, le nombre de pixels par plant est directement lié à la résolution spatiale et à la taille du plant. L'importance de ce facteur dépend de l'information extraite : le recours à l'information

⁷ par exemple, à l'aide d'un tracé des rangs obtenu avec un GNSS (par exemple, lors du semis) ou à travers la détection des rangs dans une image de télédétection.

⁸ Le terme « milli-résolution » n'est pas, à proprement parler, dans la nomenclature proposée et correspondrait à une résolution entre 0.001m et 0.01m. L'auteur de cette nomenclature ne semble pas avoir entrevu la possibilité de résolutions plus fines ni ne fait référence à l'imagerie dronique. Par ailleurs, cette nomenclature risque de manquer de termes pour des résolutions sub-millimétriques (entre la dizaine et la centaine de micromètres, par exemple ; mais il est raisonnable de penser que nous entrons là dans le domaine du microscope).

spectrale (comme dans l'utilisation d'un indice de végétation, par exemple) aura moins besoin de précision spatiale que pour l'extraction d'information structurale (superficie et hauteur, par exemple).

Pour calculer la résolution spatiale au sol (*ground sampling distance, GSD*) d'une image dronique acquise avec une caméra RGB ou multispectrale, il faut utiliser la formule suivante, déduite à l'aide du théorème de Thalès :

$$GSD = \frac{H \cdot p}{f} \quad (3.1)$$

où H est la hauteur de vol du drone (ou distance cible-caméra), p la taille physique d'un photodétecteur et f la distance focale de la caméra. Par exemple, la caméra embarquée sur le DJI Phantom 3 Pro possède une distance focale de 3,6 mm et chaque photodétecteur a une taille de 1,58 μm . Pour un vol à 100 m AGL, la résolution théorique obtenue sera $GSD = \frac{100 \cdot 1,58 \cdot 10^{-6}}{3,6 \cdot 10^{-3}} = 4,4 \cdot 10^{-2} \text{ m}$ soit 4,4 cm. Pour une altitude de vol différente, la résolution se déterminera proportionnellement par rapport à cette valeur trouvée pour 100 m : une altitude deux fois plus basse (50 m) permettra d'obtenir une résolution deux fois plus fine (2,2 cm), etc.

3.2. Prétraitements

Avant de pouvoir extraire l'information utile des images droniques, des prétraitements sont nécessaires afin d'obtenir une orthomosaïque de la région d'étude, corriger des distorsions géométriques et des défauts radiométriques. Plusieurs logiciels de photogrammétrie existent sur le marché, spécialisés dans le traitement des images droniques : Pix4Dmapper Pro (Pix4D SA, Lausanne, Suisse), Correlator3D (SimActive, Montréal, QC) et Metashape (Agisoft, Saint-Petersbourg, Russie). Dans notre recherche, nous avons eu recours au logiciel Pix4Dmapper Pro particulièrement adapté pour les images multispectrales utilisées dans nos expérimentations.

3.2.1. Corrections géométriques et orthomosaïquage

Grâce au recouvrement longitudinal et latéral des clichés pris par le drone, il est possible d'appliquer les principes de stéréophotogrammétrie afin de générer une orthomosaïque de qualité. L'algorithme de photogrammétrie qui est mis en œuvre est le *Structure from Motion* (SfM), dont un organigramme est donné par Iglhaut *et al.* (2019) et repris à la figure 3.4.

Tout d’abord, des points caractéristiques (*key features*) sont détectés dans chaque image puis identifiés sur les images voisines à l’aide d’un algorithme comme SIFT (*scale-invariant feature transform*) ou SURF (*speeded up robust features*). L’appariement des points caractéristiques permet ensuite à l’algorithme d’ajustement de faisceaux (*bundle adjustment*) de calculer précisément les paramètres extrinsèques de la caméra (sa position et son orientation pour chaque image) ainsi que ses paramètres intrinsèques (notamment la distance focale et les distorsions de la lentille), tout en calculant le point 3D correspondant à chaque paire de points appariés. Enfin, la densification du nuage de points est obtenu avec la stéréo multi-vues (*multi-view stereo, MVS*). Il est alors possible de générer un modèle 3D de la scène, qui sera utilisé pour orthorectifier la mosaïque obtenue. Cette phase peut être améliorée grâce à des points de contrôle (GCP) placés judicieusement au sol avant le survol, par un positionnement précis de chaque cliché grâce à un récepteur GNSS RTK (*real time kinematic*) de haute précision à bord du drone et par la correction de l’effet de l’obturateur déroulant.

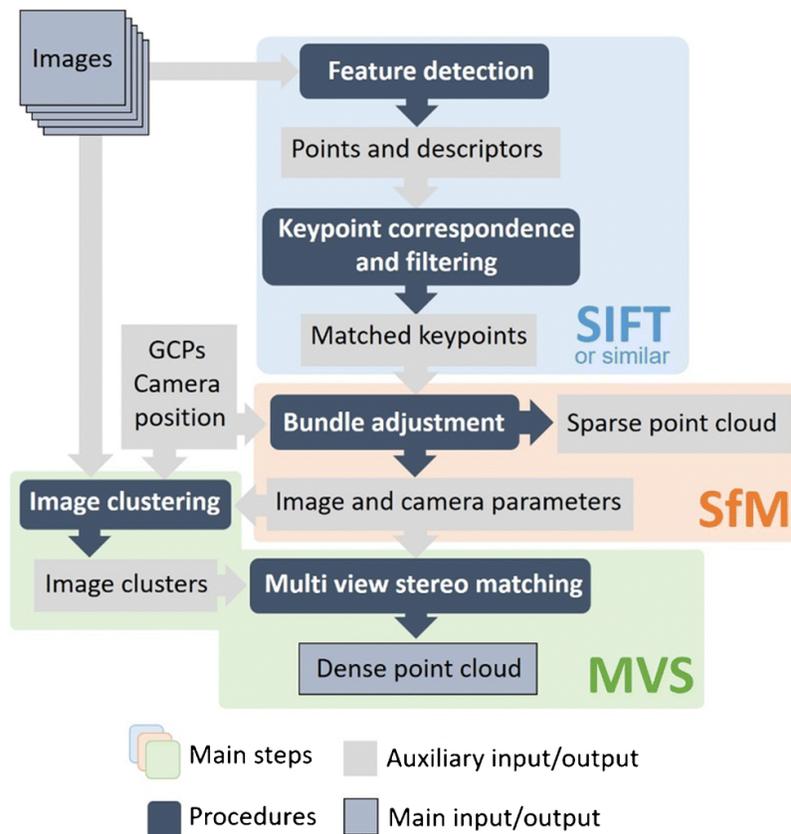


Figure 3.4 – Schéma de traitement des images pour produire un nuage de points 3D avec la méthode SfM-MVS (Structure from motion – multi-view stereo). Source : Iglhaut *et al.* (2019)

L'obturateur déroulant (ou *rolling shutter*) est un effet qui touche particulièrement les capteurs de type CMOS où une image est acquise ligne par ligne ; en opposition à l'obturation globale (ou *global shutter*), où l'image est acquise dans son intégralité en une seule fois. Avec le *rolling shutter*, une distorsion entre lignes successives de l'image existe à cause du déplacement du drone pendant l'acquisition de l'image⁹. La distorsion verticale est fonction de la vitesse du drone et du temps d'acquisition de chaque ligne de l'image ; pour exprimer ce déplacement en pixels, il faut en plus connaître les paramètres intrinsèques du capteur (distance focale, dimensions du capteur et des pixels) et l'altitude de vol. La correction de cet effet permet d'améliorer l'appariement des points caractéristiques et donc une meilleure précision de l'estimation des paramètres de la caméra.

Les corrections et techniques décrites précédemment pour arriver à mosaïquer l'ensemble des images acquises engendrent quelques défauts dans le produit final (Tahtirvanci et Durdu, 2018; Zhang *et al.*, 2018). Pour reconstituer une seule image – la mosaïque – à partir de plusieurs images prises selon des géométries et des luminosités diverses, il faut en effet les rééchantillonner et les déformer pour les aligner avant de les « raccorder ». La qualité de l'image finale s'en trouve dégradée géométriquement (déformation, mauvais raccords) et radiométriquement (effets de flou, raccords plus ou moins visibles, contrastes entre portions de l'image).

3.2.2. Corrections radiométriques

Sur la plupart des caméras commerciales, il existe des défauts radiométriques qu'il faut corriger, si nous voulons obtenir des valeurs radiométriques uniformes sur un cliché et entre clichés. À titre d'exemple, Pix4Dmapper Pro pour effectuer les corrections radiométriques tient compte aussi d'autres paramètres tels les facteurs d'exposition (vitesse d'obturation, ouverture de l'objectif et sensibilité ISO), la sensibilité de chaque bande spectrale, le courant d'obscurité (*dark current*) ; paramètres enregistrés dans le fichier des métadonnées accompagnant chaque image (EXIF¹⁰). L'effet de vignettage correspond à un assombrissement de la périphérie des

⁹ <https://www.pix4d.com/blog/rolling-shutter-correction>

¹⁰ Exchangeable image file format : format permettant d'enregistrer les métadonnées d'une image dans le fichier numérique.

images, dû à la présence d'accessoires devant la lentille (vignettage mécanique) ou aux dimensions de la lentille (vignettage optique). Cet effet étant radial, on le modélise par une fonction polynomiale pour en faire la correction.

Pour préparer les images en vue de leur analyse, il est souvent nécessaire de transformer les valeurs numériques des pixels en valeurs de réflectance. La méthode la plus simple consiste à utiliser une cible d'étalonnage de réflectance connue, souvent une plaque de *Spectralon* (Labsphere Inc., North Sutton, NH). Celle-ci est disposée au sol et son image est prise par la caméra au début ou au moment du survol. Cette image est ensuite utilisée par le logiciel pour étalonner radiométriquement la mosaïque.

Il existe plusieurs autres stratégies pour améliorer l'estimation de la réflectance, en complément ou en remplacement de la cible d'étalonnage. L'angle de visée et l'angle solaire influencent également la radiométrie des images et leurs effets doivent être pris en compte pour améliorer l'estimation de la réflectance. Certaines caméras sont ainsi accompagnées de capteurs d'éclairage incident, ce qui permet de mesurer l'illumination solaire, corrigée en fonction de l'heure et de la date du survol. Une excellente description des étapes de calibration radiométrique est donnée par Assmann *et al.* (2018)

3.3. Extraction de l'information

3.3.1. Traits caractéristiques et vigueur

L'approche générale pour évaluer la vigueur à partir des images droniques est donnée schématiquement par la figure 3.5. Dans un premier temps les images prétraitées sont analysées afin de faire ressortir les traits caractéristiques des plants, des rangs ou d'un champ au complet selon l'échelle d'observation.

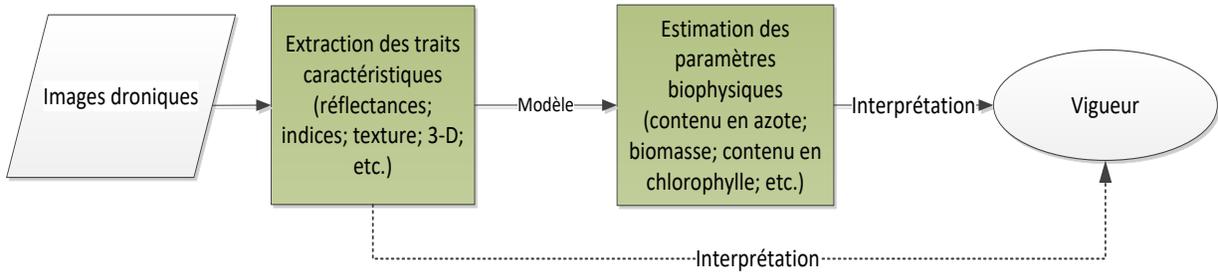


Figure 3.5 – Approche d’analyse des images drones.

Ces traits sont souvent des intrants dans des modèles d’estimation des paramètres biophysiques, et peuvent être basés sur :

- l’aspect spectral des végétaux, ce qui conduit à étudier les réflectances dans une ou plusieurs bandes spectrales, à les combiner pour produire des indices de végétation ;
- l’aspect structural des plantes, comme leur hauteur, leur densité, leur superficie, etc.

Plusieurs paramètres biophysiques peuvent être candidats à devenir un proxy de la vigueur. Ceux souvent mentionnés dans les études avec les images drones tels la teneur en azote, la biomasse, ou l’indice de surface foliaire (LAI), sont définis au tableau 3.1.

Tableau 3.1 – Principaux paramètres biophysiques.

Paramètre biophysique (unité)	Définition/Commentaires
Teneur en azote (kg ha ⁻¹)	La teneur en azote dans la plante montre si celle-ci dispose suffisamment de nutriments dans son environnement immédiat, si elle absorbe bien l’azote disponible dans le sol et si elle couvrira ses besoins de croissance.
Biomasse (g m ⁻² ou t ha ⁻¹)	La biomasse végétale se définit comme toute matière organique d’origine végétale, dans laquelle l’énergie est stockée sous forme de liens chimiques. Elle se mesure souvent en masse de matière sèche par superficie. Pour un individu donné, la biomasse s’exprime directement par le poids de la plante (en grammes).
Indice de surface foliaire (LAI ; adimensionnel)	L’indice de surface foliaire (LAI) se définit globalement comme la superficie de feuillage s (en m ²) par unité de surface au sol G (en m ²) : $LAI = \frac{s}{G}$ Le LAI varie généralement entre 0 et 5. Du point de vue de la plante individuelle, cet indice n’a plus de sens. On ne parle que de la surface foliaire, c’est-à-dire la superficie totale du feuillage (en cm ²).

Teneur en chlorophylle (g cm ⁻²)	Responsable de l'activité photosynthétique, la chlorophylle absorbe l'énergie solaire utile au développement de la plante. La teneur en chlorophylle est un autre indice de la vigueur de la plante et un bon indicateur de la déficience en azote
Fraction du couvert végétal (FCV ; en %)	La fraction du couvert végétal exprime le taux de couverture de la canopée végétale par rapport à la surface au sol

Quant aux modèles d'estimation, ils peuvent être de nature déterministe, des modèles semi-empiriques ou empiriques (Guissard *et al.*, 2005). Les valeurs des paramètres biophysiques ainsi estimés sont alors interprétées pour arriver à évaluer la vigueur de la culture. Il y a aussi des cas où les cartes des traits caractéristiques, souvent des cartes d'indices de végétation, sont directement interprétées sans passer par l'étape d'estimation des paramètres biophysiques. Ces différentes étapes sont examinées par la suite.

3.3.2. Information spectrale

L'information spectrale permet d'abord de discriminer les différents objets d'une scène. Dans un contexte agricole, nous sommes principalement en présence de sol et de végétation, dont la signature spectrale est donnée à la figure 3.6.

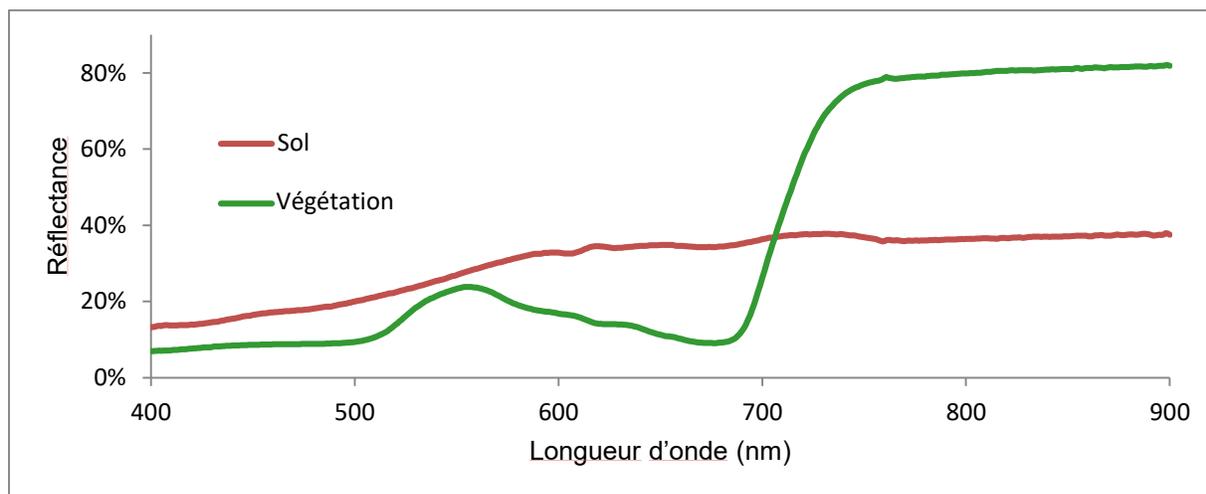


Figure 3.6 – Exemples de signature spectrale pour les deux principaux objets rencontrés dans un champ : la végétation et le sol. Les mesures ont été effectuées avec le spectroradiomètre ASD FieldSpec Handheld 2, dans un champ de maïs (été 2015).

Plusieurs études démontrent que la réflectance de la végétation verte varie dans l'intervalle spectral de 400 à 3000 nm en fonction des paramètres comme la teneur en chlorophylle et autres pigments, la structure et la forme des feuilles ainsi que la teneur en eau ou en matière sèche. Cette variation s'explique par l'absorption due aux différents composants d'une feuille verte (figure 3.7).

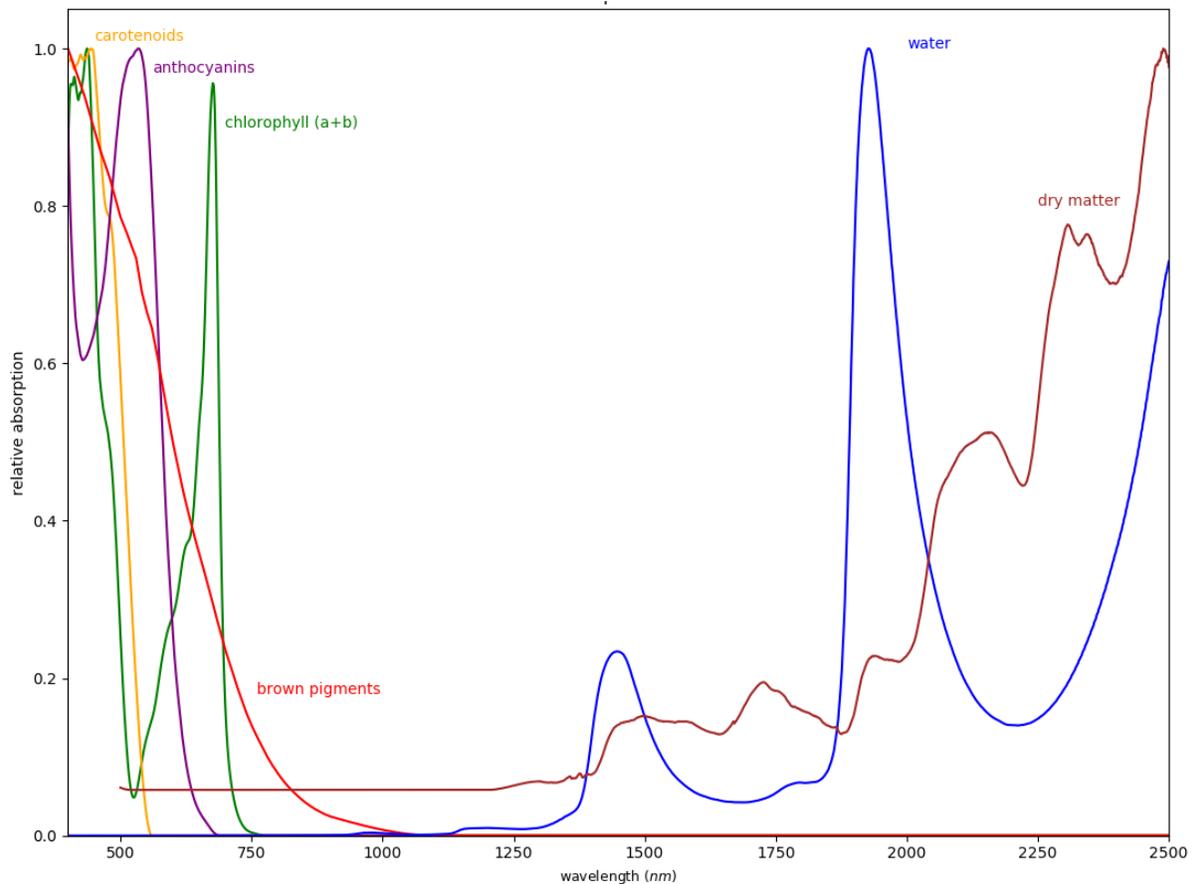


Figure 3.7 – Coefficients d'absorption des différents composants d'une feuille verte, d'après le modèle PROSPECT-D (Jacquemoud et Baret, 1990). Les courbes représentent l'absorption relative de chaque composant par rapport à son absorption maximale.

Dans le visible, ce sont surtout les pigments de chlorophylle qui modulent la réflectance de la végétation avec une forte absorption dans les bandes bleue (400–500 nm) et rouge (600–700 nm) et un pic de réflectance dans le vert qui ne dépasse cependant pas les 10 % environ. Dans le proche infrarouge (700–1100 nm), c'est plutôt la structure du feuillage qui explique la forte réflexion du rayonnement solaire qui peut atteindre les 50 % et parfois plus. Particulièrement l'intervalle spectral de 700 à 800 nm environ, appelé le « *red edge* », où la

réflectance de la végétation verte présente un point d'inflexion est selon plusieurs études une bande spectrale de grand intérêt pour l'estimation des paramètres biophysiques. Finalement, dans la partie de l'infrarouge à ondes courtes (1100–3000 nm), c'est la teneur en eau de la végétation et la concentration en matière sèche qui expliquent la réflectance plus faible du couvert végétal que dans le proche infrarouge.

Les variations spectrales dans les différentes bandes spectrales en fonction des divers paramètres biophysiques, ont amené très tôt les chercheurs à proposer des ratios de réflectances, particulièrement dans le PIR et le rouge, et des combinaisons arithmétiques des réflectances dans deux ou plusieurs bandes, les indices de végétation (VI). À titre d'exemple, Daughtry *et al.* (2000) étudient les variations de la réflectance (et de la transmittance) des feuilles vertes de maïs dans le visible et le PIR, en fonction de la teneur en chlorophylle, qui est influencée par le taux d'azote appliqué (figure 3.8).

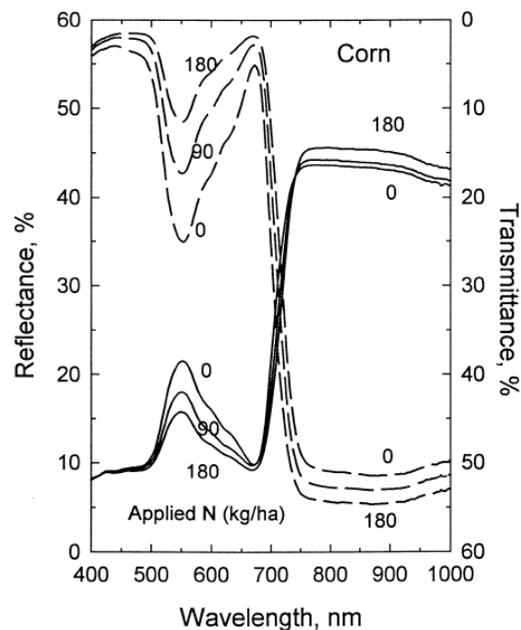


Figure 3.8 – Réflectance et transmittance des feuilles de maïs pour 0, 90 et 180 kg N ha⁻¹ (Daughtry *et al.*, 2000).

Il est clair que plus cette teneur augmente, plus la réflectance dans le visible baisse tandis que l'inverse se passe dans le PIR. Un indice de végétation tel le NDVI capte en principe cette variabilité conjointe des réflectances dans les bandes du PIR et du rouge. Il semble donc logique d'avoir recours à des indices de végétation pour étudier la végétation : c'est l'approche que nous

qualifierons de « classique ». Aussi n'est-il pas étonnant de voir l'imagerie dronique utilisée dans le but premier de calculer des indices de végétation. Bon nombre d'expériences empruntent cette voie et, dans une majorité de publications, l'extraction des paramètres biophysiques de la culture se fait à partir d'indices de végétation.

Une multitude d'indices de végétation existent, suivant le choix des bandes spectrales utilisées, la façon de combiner ces bandes et les corrections éventuelles pour tenir compte des effets du sol, de l'atmosphère ou de la topographie. Le site *Index Database* (<https://www.indexdatabase.de>) recense ainsi plus de 250 indices utilisés en télédétection qui s'appliquent à la végétation (Henrich *et al.*, 2012). Le tableau 3.2 présente une liste non exhaustive des indices souvent proposés dans le contexte des applications des images droniques en agriculture. Nous présenterons dans la section suivante quelques exemples d'études avec des indices de végétation.

3.3.3. Indices de végétation vs paramètres biophysiques

Il va sans dire que l'indice de végétation le plus populaire est le NDVI tel que calculé à partir d'une caméra multispectrale, le capteur fréquemment embarqué sur un drone agricole (Berni *et al.*, 2009; Caturegli *et al.*, 2016; Laliberte *et al.*, 2011; Matese *et al.*, 2015; Tattaris *et al.*, 2016). De leur côté, Tremblay *et al.* (2014) ont eu recours plutôt au SAVI et au ratio TCARI/OSAVI.

Selon les bandes spectrales présentes sur les capteurs multispectraux, d'autres indices de végétation peuvent être calculés : NGRDI, OSAVI, NDRE, etc. (le lecteur est invité à consulter le tableau 3.2 pour la définition des différents indices de végétation). Tel que mentionné à la section 3.2.2, pour obtenir des réflectances, des prétraitements radiométriques des images brutes sont souvent nécessaires (Lelong *et al.*, 2008). Les caméras multispectrales étant assez dispendieuses, certaines recherches ont recours à des caméras RGB modifiées (ou *color-infrared*), sensibles au proche-infrarouge (voir chapitre 2).

Tableau 3.2 – Exemples d’indices de végétation utilisés avec les images droniques.

Indice	Formulation	Auteur
Indices de couleur, fondés uniquement sur les bandes du visible : rouge (R), vert (V), bleu (B) d’une caméra standard		
ExG : Excess Green Index	$ExG = 2g - r - b$ avec $r = \frac{R}{R+G+B}$, $g = \frac{G}{R+G+B}$, $b = \frac{B}{R+G+B}$.	Woebbecke <i>et al.</i> (1995)
ExR : Excess Red Index	$ExR = 1.4r - g$ avec $r = \frac{R}{R+G+B}$, $g = \frac{G}{R+G+B}$.	Meyer <i>et al.</i> (1998)
NDI : Normalized Difference Index	$NDI = \frac{G - R}{G + R}$	Perez <i>et al.</i> (2000)
Indices fondés sur les réflectances du visible, du « red edge » (RE) et du proche infrarouge (NIR) d’une caméra multispectrale ou RGB modifiée		
TGI : Triangular Greenness Index	$TGI = -0.5[(\lambda_R - \lambda_B)(R - G) - (\lambda_R - \lambda_G)(R - B)]$ où λ_R , λ_G et λ_B désignent respectivement les longueurs d’onde centrales des bandes rouge, verte et bleue.	Hunt <i>et al.</i> (2011)
NGRDI : Normalized Green-Red Difference Index	$NGRDI = \frac{G - R}{G + R}$	Gitelson <i>et al.</i> (2002)
GNDVI : Green Normalized Difference Vegetation Index	$GNDVI = \frac{NIR - G}{NIR + G}$	Gitelson et Merzlyak (1998)
MSAVI : Modified Soil Adjusted Vegetation Index	$MSAVI = \frac{2NIR + 1 - \sqrt{(2NIR + 1)^2 - 8(NIR - R)}}{2}$	Qi <i>et al.</i> (1994)
NDRE : Normalized Difference Red-Edge Index	$NDRE = \frac{NIR - RE}{NIR + RE}$	Barnes <i>et al.</i> (2000)
NDVI : Normalized Difference Vegetation Index	$NDVI = \frac{NIR - R}{NIR + R}$	Rouse <i>et al.</i> (1974)
OSAVI : Optimized Soil Adjusted Vegetation Index	$OSAVI = (1 + 0.16) \frac{NIR - R}{NIR + R + 0.16}$	Rondeaux <i>et al.</i> (1996)
SAVI : Soil Adjusted Vegetation Index	$SAVI = \frac{NIR - R}{NIR + R + L} (1 + L)$ où L est un paramètre entre 0 et 1, à choisir en fonction de la densité de la végétation et de la réponse du sol sous-jacent	Huete (1988)
Indices fondés sur les bandes étroites d’un capteur hyperspectral		
TCARI : Transformed Chlorophyll Absorption Reflectance Index	$TCARI = 3[(R_{700} - R_{670}) - 0.2(R_{700} - R_{550})] \frac{R_{700}}{R_{670}}$ où R est la réflectance et l’indice exprime la longueur d’onde en nm	Haboudane <i>et al.</i> (2002)
MCARI : Modified Chlorophyll Absorption in Reflectance Index	$MCARI = [(R_{700} - R_{670}) - 0.2(R_{700} - R_{550})] \frac{R_{700}}{R_{670}}$	Daughtry <i>et al.</i> (2000)

Avec une caméra de type RGNIR, Lelong *et al.* (2008) ont ainsi pu calculer les indices NDVI, SAVI, et GNDVI ; Rabatel *et al.* (2014) ont utilisé le NDVI pour valider leur méthode de modification de deux caméras RGB en caméras RGNIR. Hunt *et al.* (2014) ont utilisé, quant à eux, une caméra de type BGNIR pour calculer l'indice GNDVI. Dans le cas d'une caméra RGB standard non modifiée, il est seulement possible de calculer des indices impliquant les bandes du visible dont les indices Excess Green, Excess Red et NDI (Meyer et Neto, 2008). Les bandes R, G et B n'étant pas étalonnées, il n'est pas possible de transformer les valeurs numériques en valeurs de réflectance. Cependant, dans les indices cités ci-dessus, une certaine normalisation est effectuée puisque les bandes sont combinées entre elles sous forme de ratio. Il serait quand même possible d'obtenir des valeurs de réflectance à partir des images RGB mais cela nécessite que ces images soient enregistrées directement au format *RAW*, ce qui peut s'avérer impossible pour certaines caméras¹¹. Hunt *et al.* (2014) ont utilisé une caméra offrant cette possibilité afin de calculer les indices spectraux NGRDI et TGI.

Les caméras hyperspectrales ont également été testées (Quemada *et al.*, 2014). Tel que mentionné au chapitre 2, l'utilisation de caméras hyperspectrales embarquées sur un drone est encore en phase de recherche. L'équipement reste onéreux et le recours à un balayeur à râteau rend le mosaïquage difficile tandis que les caméras de type instantané présentent un nombre restreint de photodétecteurs, ce qui diminue grandement la résolution spatiale. Avec une caméra hyperspectrale, les indices de végétation visent surtout à mesurer les propriétés biochimiques de la plante, notamment la quantité de chlorophylle au niveau de la canopée.

Nous présenterons par la suite un aperçu d'études par paramètre biophysique (repris dans le tableau 3.1) en mettant l'accent sur le maïs.

3.3.3.1. Teneur en azote

Afin de contourner les opérations complexes de définition de la teneur en azote en laboratoire, il n'est pas étonnant de constater le recours aux capteurs multispectraux voire hyperspectraux pour estimer ce paramètre avec un indice de végétation ou par inversion d'un modèle de transfert

¹¹ Le format *RAW* n'est généralement pas disponible pour les caméras RGB standard. Celles-ci stockent leurs images directement au format *jpeg*, qui est une norme de compression d'images avec perte (*lossy compression*).

radiatif dans différents types de culture (Geipel *et al.*, 2016; Ryu *et al.*, 2011; Vigneau *et al.*, 2011; Zhang *et al.*, 2016). Particulièrement dans le cas du maïs, Gabriel *et al.* (2017) établissent de meilleures corrélations entre les indices de végétation et la teneur en azote lorsque ceux-ci sont calculés à partir des images prises par avion que par drone. Les auteurs ne donnent pas une interprétation des raisons de cette plus faible performance. Tahir *et al.* (2013), pour leur part, estiment la réflectance des feuilles de maïs à différents stades de croissance par des mesures *in situ* avec un spectroradiomètre et présentent quelques modèles statistiques d'estimation de la teneur en azote en fonction des réflectances ou des indices de végétation. Leurs modèles sont repris au tableau 3.3 à des fins d'illustration du processus d'estimation des paramètres biophysiques par modèle empirique.

Tableau 3.3 – Exemples des modèles statistiques d'estimation de la teneur en azote en fonction des paramètres spectraux (adapté de Tahir *et al.* (2013)).

Stade de croissances	Paramètre spectral	Coefficient de détermination	Modèle (Y = contenu en azote, X = paramètre spectral)
6–8 feuilles	Réflectance 710 nm	0,59	$Y = 4,361 * e^{-3,06 * X}$
10–12 feuilles	GNDVI	0,90	$Y = 4,450 - 17,99 * X^2 + 10,469 * X^3$
Floraison	Réflectance 730 nm	0,73	$Y = 3,092 + 1,684 * X + 1,995 * X^2$
Apparition des soies	GNDVI	0,81	$Y = 3,986 * X^{0,161}$
Stade précoce des grains dentés	Réflectance 720 nm	0,65	$Y = -3,860 - 12,692 * X + 7,632 * X^3$

3.3.3.2. La biomasse végétale

La biomasse est un indicateur efficace de la mesure de la vigueur des cultures et constitue donc un bon paramètre biophysique pour la gestion des cultures (Yu *et al.*, 2013). Elle permet alors une meilleure évaluation de la variabilité spatiale sur le terrain et une gestion plus fine des applications de l'azote. Une plante qui croît bien aura une biomasse plus élevée qu'une plante présentant un déficit de croissance. Afin de mesurer la biomasse sur le terrain, un échantillonnage destructif est effectué : sur une petite superficie déterminée, la plante est coupée

puis pesée pour obtenir la biomasse humide ; ou séchée avant la pesée pour obtenir la biomasse sèche.

Niu *et al.* (2019) ont testé différents indices fondés sur les bandes du visible d'une caméra RGB à bord d'un drone dans le cas d'une culture de maïs. Ils ont obtenu des corrélations significatives avec la biomasse estimée à partir d'un échantillonnage *in situ*. Les coefficients de détermination dans le cas des modèles linéaires simples variaient entre 0,63 et 0,73. L'utilisation de plusieurs indices de végétation dans des modèles de régression multiple augmentait le coefficient de détermination à 0,82. Les auteurs ont aussi étudié la hauteur des plants de maïs seule ou en combinaison avec des indices de végétation comme il le sera question plus loin. Han *et al.* (2019), pour leur part, ont eu recours à l'apprentissage machine pour produire un modèle permettant de prédire la biomasse du maïs. Plusieurs variables indépendantes ont été sélectionnées à partir d'indices spectraux et structuraux obtenus avec des images droniques. Ensuite, quatre algorithmes ont été évalués et comparés : la régression linéaire multiple, le SVM (*support vector machine*), le réseau de neurone artificiel (ANN) et le classificateur *Random Forest* ; ce dernier donnant le meilleur R^2 tant sur les données d'entraînement ($R^2=0,944$) que sur les données de validation ($R^2=0,699$).

3.3.3.3. *La teneur en chlorophylle*

Comme la mesure en laboratoire est une opération peu pratique, il existe des instruments de terrain qui permettent d'estimer la teneur en chlorophylle de façon non destructive. Par exemple, le SPAD 502 (Konica Minolta Inc., Osaka, Japon) mesure la transmittance de la feuille pour deux longueurs d'onde : 650 nm et 940 nm (Spectrum Technologies, 2009). La bande autour de 650 nm (rouge) correspond à la région spectrale la plus sensible à l'activité chlorophyllienne, tandis que la transmittance à 940 nm (PIR) permet de corriger certains facteurs comme l'humidité et l'épaisseur de la feuille (Blackmer et Schepers, 1995; Zhu *et al.*, 2012). La valeur affichée par l'appareil est sans unité et exprime une grandeur ponctuelle, proportionnelle à la concentration en chlorophylle présente à l'endroit de la feuille mesurée. Sur le terrain, la teneur en chlorophylle est mesurée à partir d'un ou plusieurs échantillons d'une même plante pour

caractériser un individu, puis ces mesures peuvent être moyennées sur plusieurs individus pour obtenir une valeur par zone d'échantillonnage.

Zhang *et al.* (2016) ont eu recours à six indices (DVI, RVI, NDVI, GNDVI, SAVI et OSAVI) pour en étudier la corrélation avec la teneur en chlorophylle (mesurée avec le SPAD) dans un champ de riz. Yun *et al.* (2015) ont utilisé un drone au-dessus d'un champ où poussait de la vesce hérissée (*Vicia hirsuta* L.). Trois indices de végétation (NDVI, GNDVI et ExG) ont été calculés et corrélés à deux paramètres terrain : la biomasse et la teneur en chlorophylle. Les auteurs ont ainsi montré qu'il existait une relation linéaire entre chaque indice de végétation et les paramètres terrain, avec un R^2 variant entre 0,7 et 0,8. De la même manière, Geipel *et al.* (2016) ont comparé les indices NDVI et REIP aux paramètres de biomasse et de teneur en chlorophylle du blé d'hiver (*Triticum aestivum* L.).

Dans le cas du maïs, Daughtry *et al.* (2000) ont montré que la réflectance dans les longueurs d'onde de 550 nm (vert) et 715 nm (*red edge*) était inversement proportionnelle à la teneur en chlorophylle tandis que la réflectance à 670 nm (rouge) ne changeait que très peu (figure 3.9). Ils ont ainsi proposé certains indices de végétation qui seraient particulièrement sensibles à la teneur en chlorophylle : le MCARI (voir tableau 3.2) et l'indice NIR/Green. Lang *et al.* (2019) se sont plutôt appuyés sur les indices de couleur calculés à partir des images RGB pour prédire la teneur en chlorophylle à l'aide d'un réseau de neurones à rétropropagation d'erreur. Le modèle obtenu fournissait un coefficient de détermination $R^2=0,70$ qui pouvait être amélioré lorsqu'on combinait également des indices de texture ($R^2=0,72$) et qu'on segmentait l'image pour éliminer les pixels correspondant au sol ($R^2=0,76$).

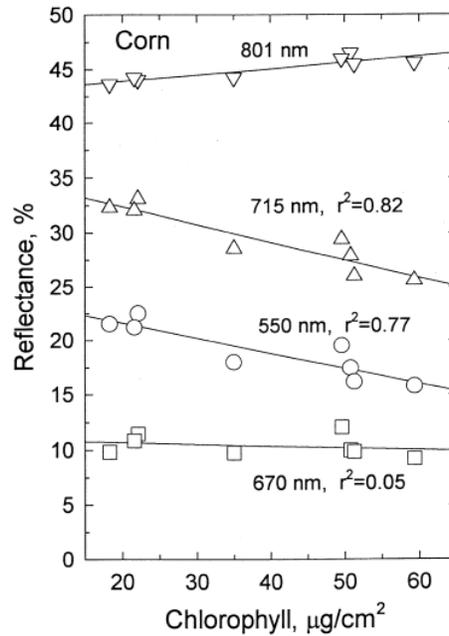


Figure 3.9 – Réflectance des feuilles de maïs en fonction de la teneur en chlorophylle (Daughtry *et al.*, 2000).

3.3.3.4. LAI

Les processus biogéochimiques se déroulent au niveau de la canopée d'une plante : photosynthèse, transpiration, échange d'énergie. La mesure de la surface foliaire est donc un indicateur important de la condition de la végétation (Asner *et al.*, 2003). D'ailleurs, l'architecture de la canopée et la morphologie des feuilles ont été manipulées génétiquement afin d'augmenter la performance et donc le rendement de la plante (Mathan *et al.*, 2016), en renforçant sa capacité à intercepter la lumière, effectuer la photosynthèse et transporter les photosynthétats (sucres servant à la croissance, issus de la photosynthèse). Asner *et al.* (2003), dans leur revue des ouvrages traitant du LAI, soulignent qu'il existe plusieurs façons de calculer le LAI. La méthode la plus répandue consiste à mesurer la surface qu'occupe chaque côté d'une feuille – à l'aide d'un planimètre par exemple – et de faire la somme pour l'ensemble des feuilles contenues dans l'unité de surface au sol. Des appareils, appelés analyseurs de couvert végétal, ont été spécialement développés pour mesurer le LAI rapidement sur le terrain, sans avoir à mesurer la surface des feuilles. On peut citer, par exemple, le modèle LAI-2200C (LI-COR, Lincoln, Nebraska) qui dérive le LAI à partir d'une mesure de la fraction de trous (*gap fraction*) dans la canopée.

Ainsi Hunt *et al.* (2008) ont étudié le blé d'hiver et ont trouvé qu'il existait une relation entre le LAI – mesuré avec l'analyseur LAI-2000 – et l'indice GNDVI obtenu à partir d'une caméra BGNIR modifiée : pour un LAI inférieur à 2,5, l'équation de régression était $GNDVI = 0,5 + 0,16 LAI$, avec un coefficient de détermination $R^2=0,85$. Pour le maïs, Simic Milas *et al.* (2018) ont montré qu'il existait une relation empirique entre le LAI – déterminé à partir de photographies hémisphériques – et l'indice NDRE calculé à partir d'images acquises avec la caméra multispectrale Sequoia (Parrot, Paris, France) : $NDRE = 0,086 LAI + 0,055$ avec $R^2=0,62$.

3.3.4. Information structurale

Des études récentes démontrent la pertinence des traits structuraux dans l'extraction des informations sur les paramètres biophysiques, particulièrement la biomasse. Par exemple, la hauteur de canopée peut être estimée par photogrammétrie et validée avec des mesures terrain (Holman *et al.*, 2016; Hu *et al.*, 2018; Madec *et al.*, 2017). Il en est de même avec la FCV (Breckenridge *et al.*, 2012; Torres-Sánchez *et al.*, 2014) ou le dénombrement des plants (Gnädinger et Schmidhalter, 2017; Varela *et al.*, 2018).

3.3.4.1. La hauteur des plants

Les images droniques, grâce à la capacité des logiciels pour leur traitement photogrammétrique, permettent ainsi de déduire la hauteur des plants, un trait structural souvent utilisé pour estimer la vigueur. Tel que mentionné, l'acquisition de l'imagerie dronique se fait le plus souvent selon un plan de vol qui quadrille la zone survolée, avec un certain taux de recouvrement entre les images voisines. Chaque objet ou point d'intérêt apparaît ainsi sur plusieurs images et est vu sous plusieurs angles : il est alors possible d'utiliser le principe de *Structure from motion* (SfM), qui permet de reconstituer une structure 3D des objets à partir d'images 2D. Mais contrairement à la vision stéréoscopique où plusieurs caméras sont utilisées pour voir un objet sous des angles différents, c'est le déplacement de la caméra embarquée sur le drone, qui permet de voir un objet sous plusieurs angles et d'en reconstituer la structure 3D (Brocks *et al.*, 2016; Ullman, 1979).

Le traitement des images droniques permet ainsi de générer un modèle numérique de surface (MNS). Puis en disposant d'un modèle numérique de terrain (MNT) ou en l'extrayant à partir

du MNS, on obtient un modèle numérique de canopée (*CSM* : *Crop Surface Model*, ou *CHM* : *Canopy Height Model*). Cette méthode a été utilisée par Bendig *et al.* (2014), Geipel *et al.* (2014) pour mesurer la hauteur de l'orge et du maïs, respectivement. Dans l'étude de Geipel *et al.* (2014), les auteurs constatent que la résolution spatiale doit être très élevée pour pouvoir effectuer une discrimination entre le sol et la végétation dans les premiers stades de croissance du maïs, puis pour reconstituer le CSM. Plus récemment, Niu *et al.* (2019) et Han *et al.* (2019) établissent une forte corrélation entre la hauteur des plants de maïs estimée à partir des images droniques RGB et la hauteur mesurée *in situ*. Niu *et al.* (2019) soulignent la difficulté à définir la hauteur de la canopée à partir du nuage de points obtenu par photogrammétrie : ils ont ainsi décidé de comparer la hauteur PH_{ref} mesurée sur le terrain (avec un mètre ruban) avec différents percentiles de la hauteur estimée par le CSM. Les auteurs ont ainsi trouvé que le 99^e percentile représentait le mieux la hauteur mesurée, avec un $R^2=0,90$ et une pente de 0,87.

L'utilisation du système LIDAR embarqué sur drone se révèle être une solution de plus en plus explorée que ce soit pour mesurer la hauteur du blé (Madec *et al.*, 2017) ou du maïs (Zhou *et al.*, 2020). Madec *et al.* (2017) ont même constaté que le lidar, par sa meilleure résolution (3–5 mm) reconstituait plus fidèlement le haut de la canopée que la technique SfM (qui utilisait une résolution de 10 mm).

3.3.4.1. La fraction du couvert végétal (FCV)

Effectuer un suivi de la variation spatiale et temporelle de la FCV a de nombreuses applications en agriculture, notamment pour l'estimation des caractéristiques phénologiques et physiologiques de la plante (Yu *et al.*, 2013).

Pour mesurer la FCV sur le terrain, on peut utiliser une grille uniforme qu'on place au-dessus de la zone à échantillonner. On compte ensuite le nombre de cases où la végétation est présente. Ce nombre est divisé par le nombre total de cases de la grille pour obtenir la FCV. Évidemment, la taille des cases aura un impact sur la précision de la mesure. Par définition, la FCV ne peut s'appliquer à une plante individuelle.

Dans le cas des images avec des résolutions métriques ou décimétriques l'estimation de la FCV s'effectue comme pour les autres paramètres via des indices de végétation (Gitelson *et al.* 2001), à cause des pixels mixtes « sol-végétation ». Avec la haute résolution des images droniques, la

plupart du temps un pixel représente soit uniquement de la végétation, soit uniquement le sol nu¹² ; on parle alors de « pixel pur ». Très peu de pixels vont être mixtes, contenant à la fois de la végétation et du sol nu (on parle alors de « mixels »). La FCV peut se calculer simplement comme la proportion de pixels classés en végétation par unité de surface au sol (Torres-Sánchez *et al.*, 2014). Le défi réside dans la discrimination des pixels « végétation » par rapport aux pixels « non-végétation ». Pour cela, un indice de végétation est utilisé puis une valeur seuil est choisie pour segmenter l'image en deux classes. Torres-Sánchez *et al.* (2014) ont ainsi évalué 6 indices spectraux calculés à partir d'une caméra RGB pour cartographier la FCV dans un champ de blé.

3.3.4.2. *Le dénombrement et la densité*

D'autres informations sur la structure de la canopée peuvent provenir du dénombrement de plantes individuelles dans une superficie donnée. Avec une résolution spatiale ultra-fine, il devient en effet plus facile de percevoir chaque individu. Le dénombrement permet ainsi d'avoir une idée de la densité de semis et d'évaluer la qualité d'émergence des plantules (Gnädinger et Schmidhalter, 2017). On détermine ainsi la vigueur de germination (*seed vigor*) dès les premiers stades. La possibilité de dénombrer les individus sur une image offre aussi l'avantage de peaufiner les mesures absolues en les transformant en mesures moyennes par individu. Par exemple, si l'on mesurait la biomasse à un point d'échantillonnage, on pourrait l'exprimer de façon absolue (en grammes) ou par unité de surface (en grammes par mètre carré) ou, après décompte des individus, « *per capita* » (en grammes par individu). Ce qui donnerait une idée de la mesure en absolu et en relatif. Dans le contexte de la fertilisation, la biomasse par mètre carré pourrait ne pas se traduire par la même dose d'azote, en fonction de la densité des plantes dans la zone considérée : pour une même valeur de 1 kg m^{-2} , cela pourrait se traduire par une biomasse moyenne de 500 g par individu pour une densité de 2 plantes par m^2 , ou 100 g par individu pour une densité de 10 plantes par m^2 . Dans le premier cas, les plantes présentent une grande vigueur

¹² Par abus de langage, nous utiliserons le terme *sol nu* (de végétation) pour désigner tous les autres éléments de l'image qui ne rentrent pas dans la classe « végétation ».

tandis que dans le second cas, les plantes sont beaucoup plus petites ; la dose d'azote à appliquer devrait donc être modifiée en conséquence.

Chapitre 4. L'imagerie dronique comme alternative aux autres méthodes de calcul de la vigueur

Dans ce chapitre, nous décrirons les avantages et les inconvénients de l'imagerie dronique. Puis, à travers une revue de littérature, nous verrons les méthodes utilisées pour estimer la qualité des paramètres biophysiques mesurés, notamment en lien avec les autres technologies telles que l'imagerie satellitaire ou aérienne et les capteurs de proximité.

4.1. Avantages et désavantages du drone comme plateforme de télédétection

4.1.1. Avantages

Le grand avantage de l'imagerie dronique par rapport à l'imagerie satellitaire est qu'avec les drones nous pouvons combiner fine résolution spatiale et temporelle. Cet avantage est plus lié aux caractéristiques de la plateforme en elle-même (le drone) qu'à la performance du capteur à bord.

En premier lieu, la faible altitude de vol – quelques dizaines de mètres au-dessus du sol – permet d'être proche de la cible étudiée et donc d'obtenir une très haute résolution spatiale. Selon les capteurs embarqués, il est ainsi désormais possible d'atteindre des résolutions de l'ordre du centimètre voire du millimètre. De plus, à ces altitudes, les images sont moins impactées par les effets atmosphériques (diffusion et absorption) et par la présence des nuages (obstruction).

Deuxièmement, la résolution temporelle est grandement améliorée grâce à la flexibilité du drone : il est ainsi théoriquement possible de survoler la même zone dans un très court intervalle, c'est-à-dire à une fréquence élevée. Dépendamment de la superficie de la zone couverte, un survol peut être répété quotidiennement, voire plusieurs fois par jour.

4.1.2. Inconvénients

Si le drone a des avantages par rapport aux plateformes traditionnelles, il présente également des faiblesses : notamment, la stabilité de l'appareil en vol, son autonomie et la couverture spatiale.

Contrairement à un satellite ou à un avion dont la trajectoire est assez stable¹³, le drone est sans cesse confronté aux conditions de vents qui ont un fort impact sur sa trajectoire. De plus, les vibrations des moteurs de l'engin peuvent se répercuter sur la qualité des images acquises. Un système de nacelle (*gimbal*) permet de réduire l'impact des vibrations et des mouvements brusques de l'engin.

Par son mode d'alimentation par batteries lithium-ion, un drone civil a une durée maximale de vol inférieure à trente minutes¹⁴. Pour assurer des vols de longue durée, l'opérateur doit disposer de batteries de rechange et interrompre les survols pour permettre le changement de batteries. Cette lourdeur logistique réduit fortement l'autonomie de l'appareil et, par là même, les possibilités d'acquisition d'images. Des recherches sont en cours pour trouver des solutions à ce défi : par exemple, utiliser une pile à combustible fonctionnant à l'hydrogène, recourir au ravitaillement en vol ou se servir de la structure de l'appareil pour répartir les batteries ou stocker le combustible différemment.

Enfin, en raison de la basse altitude de vol et de la faible autonomie, le drone est incapable de couvrir une grande superficie ; ce qui est un inconvénient majeur pour l'étude d'un grand champ agricole. Pour espérer acquérir la totalité des images sur un grand site, il faut effectuer plusieurs survols dans la même journée, voire sur plusieurs jours. Cette situation engendre des conditions d'acquisition différentes d'un survol à l'autre (évolution de la météo, des conditions lumineuses, des stades de croissance de la végétation étudiée) qui ne sont pas propices aux traitements de télédétection.

Mais la question fondamentale sur les drones qui se pose est de savoir si l'estimation des paramètres biophysiques est plus exacte avec les images droniques et si leur plein potentiel est atteint en utilisant la méthode classique des indices de végétation.

¹³ Le satellite subit peu de frottements atmosphériques à cause de son orbite à très haute altitude. L'avion, par sa taille, est moins soumis aux aléas du vent que le drone.

¹⁴ https://www.lemonde.fr/la-foire-du-drone/article/2018/09/18/de-nouvelles-pistes-pour-doper-l-autonomie-des-drones_5356881_5037916.html

4.2. Qualité d'estimation des paramètres biophysiques

Lorsque l'imagerie dronique est utilisée pour calculer un indice de végétation, la méthode la plus simple et la plus directe est de comparer les valeurs obtenues via l'imagerie dronique avec celles obtenues par l'imagerie satellitaire ou aéroportée ou les données d'un capteur de proximité.

4.2.1. Comparaison drone vs satellite ou avion

4.2.1.1. Comparaison directe entre images

Certains auteurs comparent pour un champ ou une région d'intérêt au complet, les valeurs d'indice de végétation extraites des images droniques d'un côté avec celles extraites des images aériennes ou satellitaires. Les images acquises par drone doivent être au préalable corrigées géométriquement et rattachées pour former une orthomosaïque (chapitre 3) représentant le champ en entier, tandis que les images aériennes ou satellitaires sont livrées par le fournisseur déjà mosaïquées ou suffisamment grandes pour recouvrir la région étudiée. Matese *et al.* (2015) ont ainsi comparé des cartes de NDVI produites avec des images prises à partir d'un drone, d'un avion et du satellite RapidEye. Le but de l'expérience était d'évaluer la performance de chacune des plateformes à détecter la variabilité spatiale à l'intérieur de deux vignobles V1 et V2. Comme attendu, les images de meilleure résolution – c'est-à-dire acquises par drone – présentaient mieux la variabilité spatiale avec une dynamique plus élevée (plus grande plage de valeurs). Ils ont également proposé une façon originale de comparer ces images en utilisant les méthodes de décomposition par quadrant et d'analyse des semi-variogrammes. Ils ont ainsi constaté que l'imagerie dronique était surtout pertinente pour discriminer les petites variations de valeurs (donc un meilleur pouvoir de discrimination radiométrique) et les petites structures spatiales (donc un meilleur pouvoir de discrimination spatiale). Dans le cas inverse où ces variations étaient faibles à l'intérieur du champ, toutes les plateformes étaient équivalentes.

Les méthodes statistiques précédentes ont l'avantage d'opérer sur des images à la résolution native, c'est-à-dire sans dégradation de la résolution spatiale. Cependant, il n'est pas possible de comparer les images pixel à pixel, puisque les résolutions obtenues d'une plateforme à l'autre diffèrent. Il est alors nécessaire de sous-échantillonner la mosaïque dronique qui a la résolution

la plus fine à la même résolution que l'image la plus grossière (l'image satellitaire). Après cette opération, on peut alors déterminer la corrélation entre les pixels des images.

Matese *et al.* (2015) ont ainsi dégradé la résolution de toutes leurs images à 5 m. Ils ont constaté visuellement les mêmes patrons spatiaux de végétation puis, à travers des indices de similarité (coefficient de Pearson et indice de Lee), ils ont montré que la corrélation entre les différentes plateformes était d'autant plus élevée qu'il existait une grande variabilité à l'intérieur du champ étudié. Pour effectuer correctement la corrélation, il fallait veiller à ce que tous les pixels soient parfaitement alignés entre les images.

Dans les études mentionnées précédemment, où des images de résolutions différentes sont comparées, la méthode de sous-échantillonnage est souvent passée sous silence. Deux ensembles de méthodes sont cependant envisageables :

- l'interpolation spatiale (plus proche voisin, bilinéaire, bicubique...), qui ne nécessite pas un alignement des grilles des 2 images comparées
- et le moyennage spatial : pour toute cellule de plus grande taille, on moyenne les valeurs de l'ensemble des pixels fins qui s'y trouvent, la moyenne pouvant être n'importe quelle statistique descriptive (moyenne arithmétique, médiane, mode, voire moyenne pondérée, géométrique...). Cela suppose qu'il est possible de faire correspondre un pixel grossier avec les pixels fins : les 2 grilles doivent être suffisamment alignées.

La question du changement d'échelle et de la « scalabilité » des paramètres détectés a été soulevée par Chen (1999), où il abordait les problèmes de non-linéarité et de discontinuité qui pouvaient générer d'importants biais. Les divers modèles (Chen, 1999; Du *et al.*, 2016; Liu, Cao, *et al.*, 2019; Zhang *et al.*, 2006) ont montré que l'information contenue dans les pixels (types d'objets présents, hétérogénéité, structure et orientation...) devait être prise en compte lors du changement d'échelle, sans cela la comparaison risquait d'être faussée.

4.2.1.2. Comparaison à travers un paramètre de référence

Souvent, des mesures sur le terrain sont utilisées comme référence pour estimer la performance des différents instruments. Dans ces cas, les plateformes sont comparées entre elles seulement en ces points d'échantillonnage. C'est ainsi le cas pour Tremblay *et al.* (2014) où 64 zones

d'échantillonnage ont été déterminées aléatoirement dans les parcelles de maïs et c'est seulement en ces points-là que la comparaison a été faite entre les images acquises par drone et par satellite (Pléiades 1B) : l'indice SAVI calculé à partir des images droniques présentait une meilleure corrélation avec la biomasse fraîche ($R^2 = 0,93$ pour le drone vs $0,88$ pour le satellite) et le LAI ($R^2 = 0,91$ pour le drone vs $0,74$ pour le satellite).

Les points d'échantillonnage peuvent être des parcelles expérimentales entières, chacune ayant reçu un traitement particulier. C'est notamment le cas pour des expériences de phénotypage. Comme les résolutions diffèrent d'une plateforme à l'autre, les valeurs des pixels inclus dans chaque zone d'échantillonnage sont moyennées avant d'être comparées¹⁵. Dans ce cas-ci, l'alignement entre images est moins crucial, l'important étant de repérer correctement chaque zone d'échantillonnage dans les deux images. Ainsi Tattaris *et al.* (2016) ont seulement considéré les pixels inclus à l'intérieur d'un masque qui délimitait chacune des micro-parcelles de dimensions 2 m x 0,8 m. Les auteurs ont ensuite comparé, pour chaque parcelle, la valeur de NDVI calculée à partir de l'imagerie dronique avec celle obtenue à partir de l'imagerie satellitaire (Worldview-2) : la corrélation trouvée était élevée ($r = 0,84$). En utilisant la biomasse comme référence, il se dégageait que le NDVI satellitaire présentait la meilleure corrélation ($r = 0,58$), suivi du NDVI dronique ($r = 0,52$) et du NDVI proximal mesuré avec un GreenSeeker ($r = 0,41$).

La question du changement d'échelle posée à la section 4.2.1.1 reste valide, ce qui impose une certaine prudence dans les résultats obtenus lors de ces comparaisons.

4.2.2. Comparaison drone vs capteur de proximité

Tel que mentionné, les traits caractéristiques peuvent être utilisés directement pour évaluer la vigueur d'une culture par l'intensité de sa verdure (Bouroubi *et al.*, 2013; Crain *et al.*, 2012). Le principe d'utiliser un indice de végétation pour estimer la vigueur de la culture s'est transposé,

¹⁵ Nous soulignons ici une problématique qui est passée sous silence dans la plupart des études. Le moyennage des pixels pour un indice de végétation peut s'effectuer de deux manières : 1) on moyenne les valeurs de l'indice, ou 2) on moyenne d'abord les valeurs de réflectance avant de calculer l'indice à partir des réflectances moyennes. Par la définition même des indices tels que le NDVI, il n'y a aucune raison que ces deux méthodes produisent le même résultat (cf. démonstration à l'Annexe A).

dans les champs, sous la forme de capteurs de proximité. Ceux-ci, tel le GreenSeeker (Trimble, Sunnyvale, Californie), se placent et se déplacent à quelques dizaines de centimètres de la canopée (figure 4.1) et mesurent une valeur de NDVI, qui est censée caractériser l'état de santé des plantes. Ces capteurs embarqués sont souvent des scanners qui balayent une certaine largeur de fauchée au-dessus des rangs de culture, pour en mesurer les valeurs de réflectance. Ces mesures, à une résolution spatiale très grossière (de l'ordre du mètre, dépendamment de la hauteur du scanneur et de la vitesse du véhicule), servent ensuite à prescrire la quantité d'engrais à épandre, ou à prédire le rendement.

La plupart des capteurs de proximité, dont la finalité est la mesure de la vigueur, sont des capteurs actifs qui mesurent la réflectance de la canopée dans les longueurs d'onde du visible et du PIR (Muñoz-Huerta *et al.*, 2013). Les capteurs de proximité les plus répandus sont : GreenSeeker (Trimble, Sunnyvale, Californie), Crop Circle (Holland Scientific, Lincoln, Nebraska) ou Yara N-Sensor (Yara, Oslo, Norvège). Il est ainsi possible également de comparer les valeurs d'indice de végétation issues de l'imagerie dronique avec celles fournies par ces capteurs de proximité.

À partir d'un capteur de proximité embarqué sur un tracteur, une carte de NDVI peut être générée pour un champ entier puis comparée avec celle produite avec le drone. Cependant, à notre connaissance, aucune étude n'a encore utilisé cette possibilité à part Khun *et al.* (2016) dont l'expérience sera décrite et discutée dans la deuxième partie de la thèse.



Figure 4.1 – Système embarqué GreenSeeker (source : Trimble).

En revanche, la plupart des expériences de ce genre ont recours aux capteurs de proximité portatifs (*handheld NDVI crop sensor*) où il est impossible de produire une carte de NDVI pour un champ au complet (figure 4.2). Dans ces cas, des points d'échantillonnage sont sélectionnés

et les valeurs de NDVI sont mesurées par le capteur portable. On compare ensuite les valeurs de NDVI mesurées en ces points avec celles extraites de l'imagerie dronique. Les valeurs de NDVI peuvent provenir chacune d'un seul pixel (Caturegli *et al.*, 2016) ou de plusieurs pixels (Tattaris *et al.*, 2016) couvrant le point d'échantillonnage – dans ce dernier cas, les valeurs des pixels sont moyennées.



Figure 4.2 – Capteur portable GreenSeeker (source : Trimble).

L'estimation de la vigueur à partir des images droniques se fait par modélisation, avec comme intrants des traits caractéristiques spectraux (section 3.3.3) ou géométriques (section 3.3.4). La plupart des publications dans ce domaine testent la validité des différents modèles de régression entre les traits caractéristiques et les paramètres biophysiques. Ces derniers sont connus par des mesures *in situ* à partir de techniques plus « traditionnelles », notamment via un échantillonnage destructif. Très peu de publications vont au-delà de ces tests avec une analyse des résultats de l'application du modèle statistique à la grandeur des champs.

Caturegli *et al.* (2016) de même que Tattaris *et al.* (2016) ont remarqué que les corrélations entre les mesures de ces deux instruments (GreenSeeker portable et capteur sur drone) étaient fortes et significatives : le coefficient de corrélation r variait entre 0,83 et 0,97 pour Caturegli *et al.* (2016), et entre 0,72 et 0,91 sauf pour une date ($r = 0,41$) pour Tattaris *et al.* (2016).

Chapitre 5. Mesurer la vigueur du maïs : cadre général

Notre revue de littérature au chapitre précédent a permis de soulever quelques défis dans l'estimation de la vigueur de la culture agricole. Tout d'abord, le type de plante étudiée détermine la taille et la configuration spatiale des échelles d'intervention et d'observation. Ensuite, le paramètre biophysique utilisé comme proxy de la vigueur influence l'information à extraire d'une image dronique et donc les algorithmes de traitement.

Dans ce chapitre, nous justifions ainsi le choix de la culture du maïs pour notre étude et détaillons l'importance de la mesure de la vigueur dans le contexte de la fertilisation azotée.

5.1. Le maïs-grain

5.1.1. Importance de la culture du maïs

La culture choisie dans le cadre de notre étude est le maïs (*Zea Mays* L.), plus précisément le maïs-grain, deuxième culture en termes de production mondiale en 2016, derrière la canne à sucre selon l'Organisation des Nations Unies pour l'alimentation et l'agriculture (FAO). Le maïs est la production céréalière la plus importante au monde, avec 1,06 milliard de tonnes produites en 2016, devançant le blé et le riz (tableau 5.1). Les États-Unis et la Chine arrivaient en tête des producteurs de maïs en 2016, produisant respectivement 384,8 millions de tonnes et 231,7 millions de tonnes. Le Canada est le 10^e producteur mondial de maïs avec 12,3 millions de tonnes de maïs-grain produit en 2016.

Tableau 5.1 – Production mondiale et canadienne des principales céréales et graines oléagineuses, 2016 (source : FAO, mise à jour du 28 mai 2018)

Produit	Production (en tonnes)		Part du total (Canada vs Monde)	Rang mondial (Canada)
	Monde	Canada		
Maïs	1 060 107 470	12 349 400	1,2 %	10
Blé	749 460 077	30 486 700	4,1 %	5
Riz, paddy	740 961 445	--	--	--
Soja	334 894 085	5 827 100	1,7 %	7
Orge	141 277 993	8 704 300	6,2 %	6
Colza	68 855 446	18 423 600	26,8 %	1

Le Québec représente 27 % de la production canadienne, ce qui en fait le deuxième producteur de maïs au Canada, derrière l'Ontario (MAPAQ, 2015). Selon Statistique Canada, 396 830 hectares étaient consacrés à la culture du maïs-grain au Québec en 2016, ce qui représente environ 21 % des superficies cultivées (tableau 5.2). Alors que le maïs-grain représente moins de 4 % des terres cultivées au Canada, il accapare plus de 43 % des terres cultivées de la Montérégie ; ce qui souligne l'importance de cette culture dans cette région.

Tableau 5.2 – Superficies cultivées en maïs-grain par rapport aux terres en culture, en Montérégie, au Québec et au Canada, 2016 (source : Statistique Canada¹⁶)

	Superficies cultivées		%
	Maïs-grain	Total*	
Canada	1 462 802	37 790 608	3,9 %
Québec	396 830	1 866 829	21,3 %
Montérégie	239 587	547 801	43,7 %

* Terres en culture (excluant la superficie en arbres de Noël)

5.1.2. Principes de culture du maïs

Le maïs a la particularité d'être cultivé en rangs, en opposition avec des cultures « en tapis ». En Amérique du Nord, la plupart des champs de maïs présentent un écartement entre les rangs de 30 pouces, soit environ 75 cm (DuPont Pioneer, 2014). Au Québec et en Ontario, les champs de maïs sont semés entre fin avril et début mai¹⁷. Comme le développement du maïs dépend des températures, il est crucial de bien choisir le cultivar qui est adapté au climat de la zone de culture. Au Québec, le système de classification de l'adaptabilité des hybrides de maïs se base sur l'indice de l'unité thermique maïs ou UTM (Tremblay, 2018). Les UTM sont calculées à partir d'une formule mathématique prenant en compte les températures minimales et maximales quotidiennes. Elles sont cumulées dans l'année et utilisées, à la fois, pour décrire le potentiel d'une région pour la production de maïs, et pour indiquer les exigences thermiques d'un cultivar pour arriver à maturité (Lepage *et al.*, 2012). En Montérégie, les valeurs UTM cumulées se situent généralement entre 2700 et 3000 (Agriculture et Agroalimentaire Canada, s. d.).

¹⁶ Statistique Canada, Tableau 32-10-0416-01 (Foin et grandes cultures) et Tableau 32-10-0406-01 (Utilisation des terres).

¹⁷ <https://www.brevant.ca/fr/centre-d-agronomie/dates-de-semis-optimales-pour-le-mais.html>

Le cycle de développement du maïs s'effectue en 2 phases (MAAARO, 2017) : la phase végétative (V) qui s'étend de la germination (stade VE) jusqu'à la transition florale (stade VT) ; et la phase reproductive (R) qui s'étend de l'apparition des soies (R1) jusqu'à la maturité (R6).

Durant la phase végétative, les stades de croissance foliaire sont déterminés selon l'échelle de l'Iowa State University, qui tient compte du nombre de collerettes visibles¹⁸. Une collerette visible correspond ainsi au stade V1, tandis que le stade V8 correspond à 8 collerettes visibles (figure 5.1).

Stade	VE	V1	V4	V6	V8	V12	VT
							
Collerettes	0	1	4	6	8	12	(variable)
Pointe des feuilles	1	3	7	10	11	15	(variable)
Feuille recourbée	0	2	6	8	10	14	(variable)

Figure 5.1 – Stades végétatifs du maïs. Source : MAAARO (2017)

5.1.3. Bien mesurer la vigueur pour mieux fertiliser

Pour avoir un réel impact, la fertilisation azotée doit se faire dans les premiers stades de croissance de la plante. Dans le cas du maïs, il s'agit des stades V3 à V8, c'est-à-dire lorsque la plante possède de 3 à 8 collerettes visibles. Passé ce stade, l'effet de l'apport en engrais azotés a un impact moindre.

Dans le contexte de l'optimisation de la fertilisation, la question est de savoir dans quelle mesure une plante en un point donné profiterait d'un apport en azote : une dose d'engrais supplémentaire sera-t-elle pleinement mise à profit par la plante pour son développement ? ou sera-t-elle gaspillée parce que l'azote n'était pas le facteur limitant et que d'autres contraintes

¹⁸ <https://crops.extension.iastate.edu/encyclopedia/corn-growth-stages>

environnementales limitaient la croissance de la plante ? En bref, il est nécessaire d'estimer son potentiel de réponse à l'azote.

Mesurer la vigueur de la culture en un point donné n'est pas suffisant : sans référence, il n'est pas possible de savoir si cette vigueur peut être encore stimulée. Pour ce faire, on s'assure que, quelque part dans le champ, il existe une zone où l'azote n'est pas limité en y appliquant une dose suffisamment élevée d'engrais. La vigueur de la culture dans cette zone pourra ainsi servir de référence pour le reste du champ (Adamchuk, 2013; Bouroubi *et al.*, 2013; Tremblay, 2004).

C'est cette approche qui est utilisée par le système SCAN du CRD dont nous avons fait mention au chapitre 1. Pour estimer le potentiel de réponse à l'azote, l'algorithme a recours à un proxy qui normalise la vigueur mesurée par une valeur de référence obtenue dans une zone où les conditions de fertilisation ont été suffisantes. L'indice utilisé dans l'algorithme SCAN est l'indice de suffisance en azote (NSI) qui s'exprime par :

$$NSI = \frac{NDVI}{NDVI_{max}} \quad (5.1)$$

où $NDVI_{max}$ est la valeur de l'indice NDVI obtenue au niveau de la zone du champ suffisamment fertilisée. Le choix de cette valeur de référence est, par ailleurs, raffiné en fonction de la texture du sol approximée par la conductivité électrique apparente CEa, dans un voisinage immédiat de chaque point considéré. Cette approche basée sur les « références locales naturelles » est décrite plus en détails dans Bouroubi *et al.* (2013).

Dans le cas du NSI, la vigueur est exprimée à travers l'indice NDVI. Cependant, d'autres façons d'estimer la vigueur sont possibles, notamment avec l'imagerie dronique. L'objectif de notre thèse est donc d'exploiter au mieux la THRS inhérente aux images droniques pour estimer la vigueur de la culture à diverses échelles d'observation. Il est à noter que, pour les stades qui nous intéressent (V3–V8), le couvert foliaire ne s'est pas encore refermé. Par conséquent, les rangs de maïs sont nettement discernables, le sol parfaitement visible et il est souvent possible de distinguer chaque plante individuelle.

5.2. Les expériences menées

5.2.1. Sites à l'étude

Pour répondre aux objectifs de notre recherche, nous avons effectué une série de 5 expériences entre 2015 et 2018. Le terrain d'étude choisi était la région de la Montérégie, dans le sud du Québec. Agriculture et Agroalimentaire Canada (AAC) y disposait d'un centre de recherche et de développement basé à St-Jean-sur-Richelieu, qui offrait les outils et le terrain pertinents à la mise en œuvre de nos expériences, notamment à la Ferme expérimentale de L'Acadie.

Toutes les expériences avec vols de drone ont été réalisées soit sur des champs de maïs commerciaux (appartenant à des exploitants agricoles), soit sur des parcelles *ad hoc* à la Ferme de L'Acadie.

5.2.2. Données et prétraitements

Le choix du type de drone dépendait de l'étendue des champs à couvrir. Les drones de type avion ayant plus d'autonomie permettent de couvrir des champs étendus tandis que les drones de type multicoptère offrent plus de stabilité mais moins d'autonomie que le premier type (voir chapitre 2). Les deux types de drones ont été utilisés dans notre recherche. Quant aux capteurs embarqués, nous disposions de diverses caméras : caméra standard RGB, caméra RGB modifiée, caméra multispectrale.

Les prétraitements effectués incluaient l'ensemble des opérations telles que présentées à la section 3.2 : orthomosaiquage, corrections des distorsions radiométriques, normalisation des valeurs radiométriques (par conversion en réflectances ou normalisation des valeurs RGB), calcul des indices de végétation ou de couleur, etc.

5.2.3. Choix du paramètre de référence : la biomasse

Pour estimer l'exactitude et la précision des résultats issus de nos travaux, nous nous devons de disposer d'une « vérité terrain », qui consiste en des mesures prises sur des points d'échantillonnage, à différents stades de croissance de la plante. Cette vérité terrain est comparée aux données extraites des images droniques pour en évaluer la performance.

Comme nous l'avons vu dans la section 3.3, il existe un certain nombre de paramètres biophysiques qui permettent de caractériser la vigueur de la culture. Dans notre étude, nous avons opté pour la biomasse afin de représenter la vigueur de la plante : pour une culture comme le maïs dont la croissance est assez prévisible, la quantité de biomasse accumulée est un bon prédicteur de l'état de santé de la plante. Elle résume directement les résultats de la photosynthèse et traduit à la fois la disponibilité des ressources (nutriments, énergie solaire, etc.) et la capacité de la plante à transformer ces ressources en matière organique. Cette biomasse accumulée sera ensuite utile au développement et à la maturation de la plante.

Le choix entre la biomasse sèche et la biomasse humide peut se discuter. En temps normal, c'est-à-dire en l'absence de stress hydrique, le taux d'humidité contenu dans un plant de maïs est constant et avoisine 90 %, d'après les données que nous avons collectées sur plusieurs saisons. Le taux d'humidité s'exprime comme :

$$\tau_h = \frac{\text{masse}_{\text{humide}} - \text{masse}_{\text{sèche}}}{\text{masse}_{\text{humide}}} \quad (5.2)$$

Comme le but de notre étude n'est pas de détecter le stress hydrique, l'une ou l'autre des mesures est valable. Dans nos travaux, nous avons effectué les deux types de mesure et les avons utilisés comme paramètres de référence. Nous considérons cependant que c'est la biomasse sèche qui est primordiale, car la teneur en eau pourrait fluctuer au cours d'une même journée et le long de la saison selon des variations ponctuelles dans les conditions météorologiques.

Pour mesurer la biomasse fraîche, les plants de maïs sont coupés à ras du sol (c'est-à-dire sans les racines : il s'agit donc de la biomasse aérienne), et immédiatement pesés. En cas d'impossibilité de pesée dans l'heure qui suivait la coupe, les plants étaient placés dans une glacière à basse température pour garder toute leur humidité, pour ensuite être pesés dans la journée même. Après cette première pesée, les plants de maïs étaient mis à sécher dans un four à 65°C pendant au moins 4 jours. Au bout de ce temps de séchage, les plants étaient à nouveau pesés pour en déterminer la biomasse sèche.

5.2.4. Validation des résultats et corrélation entre paramètres

Dans toutes nos expériences, nous avons traité l'imagerie dronique pour extraire un paramètre qui serait ensuite comparé à la biomasse, utilisée comme vérité terrain. Les comparaisons et les

validations ont été exprimées à l'aide du coefficient de corrélation de Pearson (r) ou du coefficient de détermination R^2 . Les régressions ont été réalisées dans Microsoft Excel et validées avec le module *statsmodels* dans Python (Seabold et Perktold, 2010). Un test de significativité a été effectué pour ces valeurs statistiques, et sauf mention contraire, elles ont été considérées comme significatives avec un niveau $p < 0,01$. C'est également le module *statsmodels* qui a été utilisé pour tester la significativité des valeurs.

PARTIE II : LA THRS ET LES INDICES DE VÉGÉTATION

Le but de cette partie est de décrire nos expériences visant à démontrer les limitations de l'approche d'estimation de la vigueur d'une culture de maïs par des indices de végétation lorsque nous travaillons avec des images de très haute résolution spatiale. Nous avons procédé de deux façons pour étudier la pertinence des indices de végétation, particulièrement le NDVI : une étude théorique avec des réflectances simulées (chapitre 6) et une étude avec des images droniques des champs de maïs (chapitre 7).

Chapitre 6. Étude théorique : simulation avec le modèle

PROSPECT

6.1. Introduction

En télédétection, les indices de végétation sont calculés à partir des réflectances mesurées dans les bandes visibles et dans le proche infrarouge. Ces indices ont été mis en place de façon empirique, et nombre d'études ont prouvé leur pertinence dans l'estimation des paramètres biophysiques cités à la section 3.3.3. Ainsi le NDVI, le plus connu et le plus populaire des indices de végétation, fut développé dans les années 1970, à partir des images issues du capteur MSS des missions Landsat (Rouse *et al.*, 1974). Cet indice est en effet facile à mettre en œuvre et son utilisation est soutenue par une littérature abondante. Déjà massivement employé avec les images satellitaires, il garde sa popularité avec les images droniques.

Cependant, ce changement de plateformes s'accompagne également d'un changement de résolution spatiale : de la déca-résolution¹⁹ à la milli-résolution, le pixel ne capture plus les mêmes détails. En effet, dans le premier cas où la résolution est grossière, il est très probable qu'une cellule de l'image comporte plusieurs classes d'objets (par exemple, sol et végétation) ; on parle alors de mixel (Arai, 2013). À l'inverse, la THRS obtenue avec l'imagerie dronique donne lieu à la présence d'une majorité de pixels purs, où une seule classe d'objet est présente dans chaque cellule de l'image (Yue *et al.*, 2019). Par ce changement d'échelle, qu'advient-il de l'information véhiculée par un indice de végétation tel que le NDVI ?

Dans un mixel où végétation et sol sont présents, le NDVI a l'avantage de donner une certaine idée de la densité de végétation et donc de la vigueur : on comprend facilement que plus la proportion de végétation est importante par rapport au sol, plus la lumière sera réfléchie dans le PIR et absorbée dans le rouge, et donc plus le NDVI sera élevé. Pour un pixel pur « végétation », nous avançons l'hypothèse que le NDVI ne sera plus un bon indicateur de la vigueur. En effet, ce pixel pur devrait se comporter comme un pixel de résolution grossière dont la fraction de

¹⁹ La résolution du capteur MSS était de 68 m x 83 m, généralement rééchantillonnée à 60 m (<https://landsat.gsfc.nasa.gov/the-multispectral-scanner-system/>).

couvert végétal (FCV) est de 100 % : le NDVI devrait plafonner. Gitelson *et al.* (2002) ont même constaté que le NDVI saturait lorsque la FCV atteignait 60 % pour une parcelle de blé.

Pour mieux comprendre le comportement du NDVI pour un pixel pur « végétation », nous avons eu recours à une étude théorique basée sur le modèle PROSPECT.

6.2. Méthodologie

Le modèle PROSPECT est un modèle de transfert radiatif appliqué à la végétation, plus précisément à une feuille verte, basé sur un modèle généralisé de plaque (*plate model*). Il a été proposé par Jacquemoud et Baret (1990), et permet de produire des courbes de réflectance (et également de transmittance) en fonction des constituants biochimiques de la feuille. Sa description en anglais explique le nom PROSPECT : *model of leaf optical PROperties SPECTra*.

En plus d'un paramètre N correspondant à la structure physique de la feuille, la dernière version du modèle de simulation PROSPECT prend en compte le rôle de 6 constituants de la feuille verte : la chlorophylle a+b (Cab), les caroténoïdes (Ccx), les anthocyanines (Canth), les pigments bruns (Cbp), l'eau (Cw) et la matière sèche (Cm).

Pour comprendre la contribution de chacun des paramètres du modèle dans un pixel pur « végétation », nous avons effectué une analyse de sensibilité en faisant varier un paramètre à la fois (méthode OFAT, *one-factor-at-a-time*) et en fixant les autres paramètres à une valeur nominale. Les plages de valeurs utilisées pour faire varier chaque paramètre provient des travaux de Jay *et al.* (2016) tandis que les valeurs nominales sont tirées des échantillons de maïs, telles qu'observées lors de l'expérience Lopex93 (Hosgood *et al.*, 1993) qui a servi à calibrer le modèle PROSPECT (tableau 6.1). Pour cette thèse, nous nous sommes cantonné aux deux paramètres qui pourraient être de bons proxys pour la vigueur : la teneur en chlorophylle (Cab) et la teneur en matière sèche (Cm).

Tableau 6.1 – Valeurs nominales et plages de valeurs utilisées pour l’analyse de sensibilité du modèle PROSPECT (N : structure physique de la feuille, Cab : concentration en chlorophylle, Cm : teneur en matière sèche, Cw : teneur en eau).

	N	Cab ($\mu\text{g cm}^{-2}$)	Cm (g cm^{-2})	Cw (g cm^{-2})
Valeur nominale	1,518	58,0	0,003662	0,013100
Limite inférieure	1	0	0,001	0,00005
Limite supérieure	3,5	100	0,03	0,1

Les valeurs nominales des autres paramètres sont données ci-après : Ccx = 12 $\mu\text{g cm}^{-2}$; Canth = 0 $\mu\text{g cm}^{-2}$; Cbp = 0 (unité arbitraire).

Pour effectuer l’analyse de sensibilité, nous avons adapté la version Matlab de PROCOSINE ainsi que la version Python de PROSAIL basée sur le modèle PROSPECT version D, datant du 16 janvier 2017. PROCOSINE est un modèle combinant PROSPECT et COSINE (*Close-range spectral imaging of leaves*) pour étudier les propriétés foliaires à grande proximité (Jay *et al.*, 2016; Morel *et al.*, 2018). PROSAIL combine PROSPECT avec le modèle 4SAIL (*Scattering by Arbitrarily Inclined Leaves*) pour étudier les propriétés de diffusion de la lumière au niveau des canopées (Jacquemoud *et al.*, 2009; Verhoef, 1984). Les codes sources de ces modèles sont accessibles en ligne à l’adresse suivante : <http://teledetection.ipgp.fr/prosail/>.

Nous avons adapté ces codes sources pour faire un programme en Python qui simule les réflectances d’une feuille de maïs pour l’analyse de sensibilité. Les signatures spectrales produites ont ensuite été analysées pour les longueurs d’onde correspondant à la valeur centrale des bandes spectrales utilisées par la caméra Micasense RedEdge : bleu (475 nm), vert (560 nm), rouge (668 nm), *red edge* (717 nm) et PIR (840 nm). Nous avons tracé l’évolution des valeurs de réflectance pour ces 5 longueurs d’onde en fonction du paramètre étudié, et nous avons calculé quelques indices de végétation standard : le NDVI et le NGRDI (voir tableau 3.2). Nous rappelons ici la définition de ces deux indices :

$$NDVI = \frac{NIR - R}{NIR + R} \quad (6.1)$$

$$NGRDI = \frac{G - R}{G + R} \quad (6.2)$$

L'indice NGRDI a été inclus dans notre étude parce qu'il est de plus en plus utilisé, en complément ou en remplacement du NDVI (Gitelson *et al.*, 2002), pour des images droniques : il peut en effet être calculé aussi bien à partir des données acquises avec une caméra multispectrale qu'avec une caméra RGB.

Lorsque le NDVI ou le NGRDI n'étaient pas adaptés pour la détection du paramètre étudié, nous avons également proposé un autre indice qui fournissait de meilleurs résultats. Le nouvel indice proposé était défini comme une différence normalisée, sur le même principe que le NDVI, entre deux valeurs de réflectance r_{λ_1} et r_{λ_2} où λ_1 et λ_2 sont 2 longueurs d'onde choisies de telle sorte que, pour l'une, la réflectance variait étroitement avec le paramètre étudié, sans plafonner ; tandis que, pour l'autre, la réflectance restait constante.

6.3. Résultats

6.3.1. Variation de la teneur en chlorophylle (Cab)

En faisant varier la teneur en chlorophylle (Cab), nous pouvons constater, d'après la figure 6.1a, que ce paramètre n'agit que dans une plage spectrale allant du vert au *red edge*. Dans le PIR et SWIR, la réflectance ne change pas en fonction de Cab. On le voit particulièrement bien à la figure 6.1b : la réflectance diminue lorsque Cab augmente, pour les bandes *red edge*, verte et rouge ; tandis que le bleu et le PIR ne sont guère sensibles à ce paramètre. Comme la réflectance dans le rouge diminue très rapidement pour atteindre sa valeur minimale alors que la réflectance dans le PIR reste constante, une saturation très rapide du NDVI s'observe dès une valeur de 20 $\mu\text{g}\cdot\text{cm}^{-2}$ de Cab (figure 6.1c). Pour Cab < 15 $\mu\text{g}\cdot\text{cm}^{-2}$, le NDVI augmente clairement en fonction de Cab. Au fur et à mesure que la quantité de chlorophylle augmente, l'absorption dans le rouge atteint ses limites et le NDVI plafonne pour Cab > 20 $\mu\text{g}\cdot\text{cm}^{-2}$.

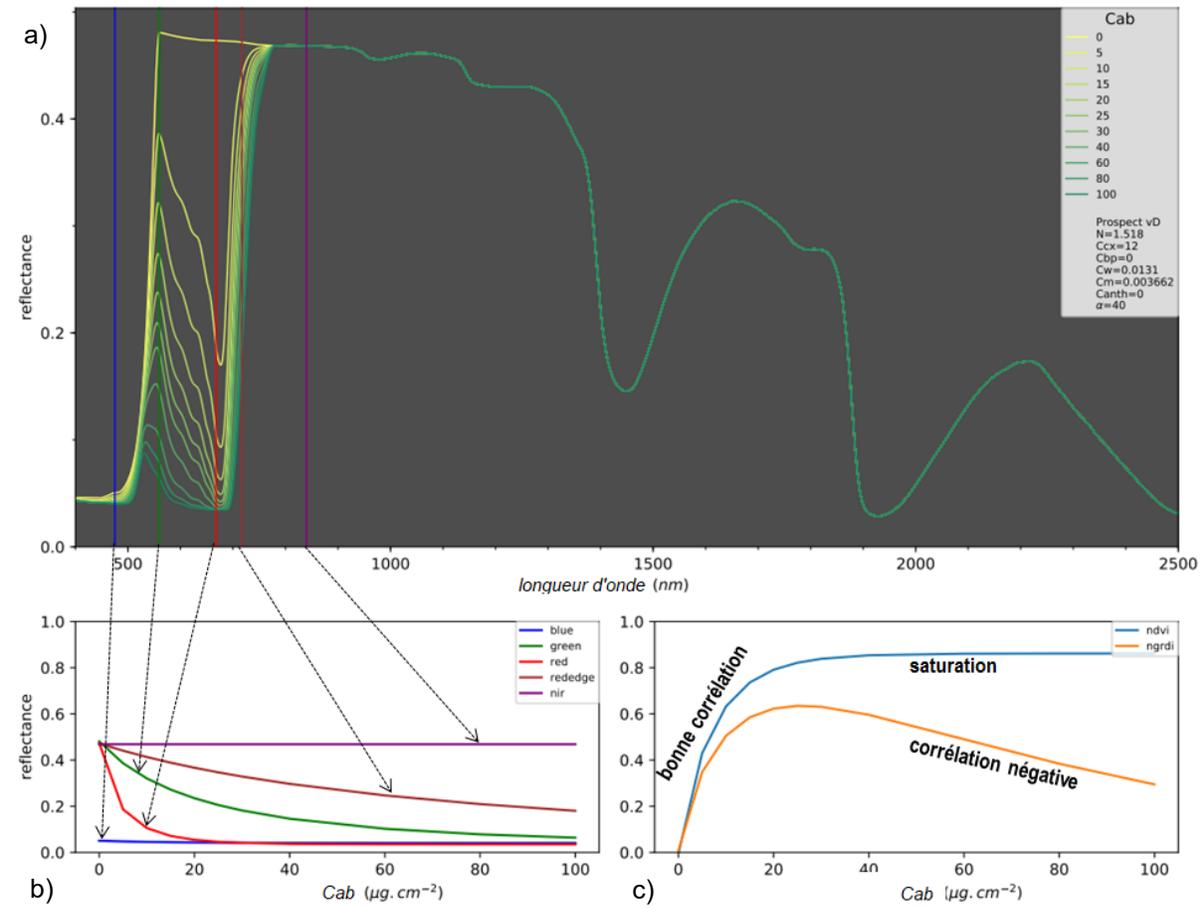


Figure 6.1 – Simulation PROSPECT en variant le paramètre Cab (teneur en chlorophylle, en $\mu\text{g}\cdot\text{cm}^{-2}$) : a) signatures spectrales selon les valeurs de Cab, b) courbes de réflectance en fonction de Cab dans les 5 bandes de la Micasense RedEdge, c) évolution du NDVI et du NGRDI en fonction de Cab. Les valeurs des autres paramètres du modèle ont été fixées comme suit : $N = 1,518$; $C_{cx} = 12 \mu\text{g cm}^{-2}$; $C_{an\text{th}} = 0 \mu\text{g cm}^{-2}$; $C_{bp} = 0$ (unité arbitraire) ; $C_m = 0,003662 \mu\text{g cm}^{-2}$; $C_w = 0,0131 \mu\text{g cm}^{-2}$.

Ce phénomène de saturation du NDVI est connu et a été observé dans d'autres études, quoique souvent de façon empirique avec des résolutions spatiales plus grossières, notamment avec des images satellitaires (Gu *et al.*, 2013; Zhu et Liu, 2015) ou des spectroradiomètres (Gitelson, 2004; Mutanga et Skidmore, 2004; Tan *et al.*, 2020). Quant au NGRDI, cet indice croît avec la chlorophylle jusqu'à la même valeur seuil (autour de $15\text{--}20 \mu\text{g}\cdot\text{cm}^{-2}$) puis décroît rapidement. Par conséquent, ni le NDVI ni le NGRDI ne sont de bons candidats pour prédire correctement la chlorophylle. Nous notons également que Gitelson *et al.* (2002), dans leur revue de littérature, ont relevé une valeur seuil autour de $100\text{--}150 \text{mg}\cdot\text{m}^{-2}$ pour la concentration en chlorophylle, où l'absorption dans le rouge et dans le bleu atteignait sa limite. Cela correspond à une valeur seuil de $10\text{--}15 \mu\text{g}\cdot\text{cm}^{-2}$, ce qui est proche de la valeur trouvée dans cette étude.

Pour détecter la teneur en chlorophylle, l'indice $NDRE = \frac{nir-rededge}{nir+rededge}$ semble être un excellent candidat (figure 6.2). Cet indice fait intervenir la bande *red edge* à la place du rouge : l'absorption du *red edge* se fait de façon progressive au fur et à mesure que la chlorophylle augmente. Le NDRE augmente donc progressivement aussi et ne sature pas rapidement, contrairement au NDVI. Ceci explique la présence de cette bande *red edge* sur la plupart des caméras multispectrales utilisées en agriculture de précision. Ainsi, Boiarskii et Hasegawa (2019) ont utilisé une caméra Micasense RedEdge embarquée sur un drone, pour comparer les indices NDVI et NDRE pour détecter la teneur en chlorophylle dans une parcelle de jeunes cèdres. Ils ont constaté que le NDVI montrait une parcelle quasi uniforme alors que le NDRE présentait une grande variabilité spatiale : ils en ont conclu que le NDVI permettait seulement d'analyser la densité et la verdure de la végétation, alors que le NDRE était capable de déterminer le besoin en fertilisation à travers la teneur en chlorophylle.

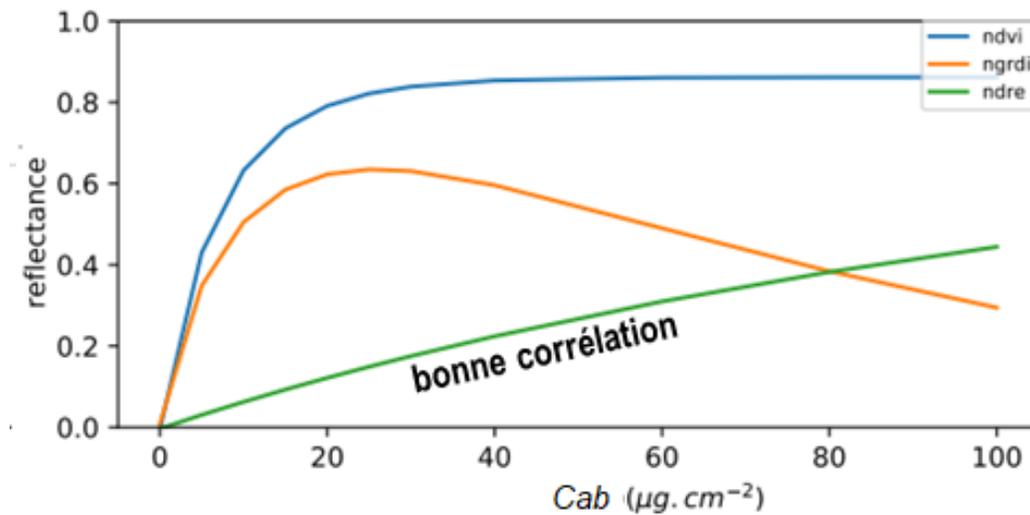


Figure 6.2 – Évolution de l'indice NDRE en fonction de la teneur en chlorophylle.

6.3.2. Variation de la quantité de matière sèche (Cm)

D'après la figure 6.3a, nous pouvons faire les constations suivantes :

- la matière sèche n'interagit pas avec les longueurs d'onde du visible ;
- c'est plutôt dans l'infrarouge courtes ondes (SWIR) que la matière sèche interagit avec le rayonnement solaire.

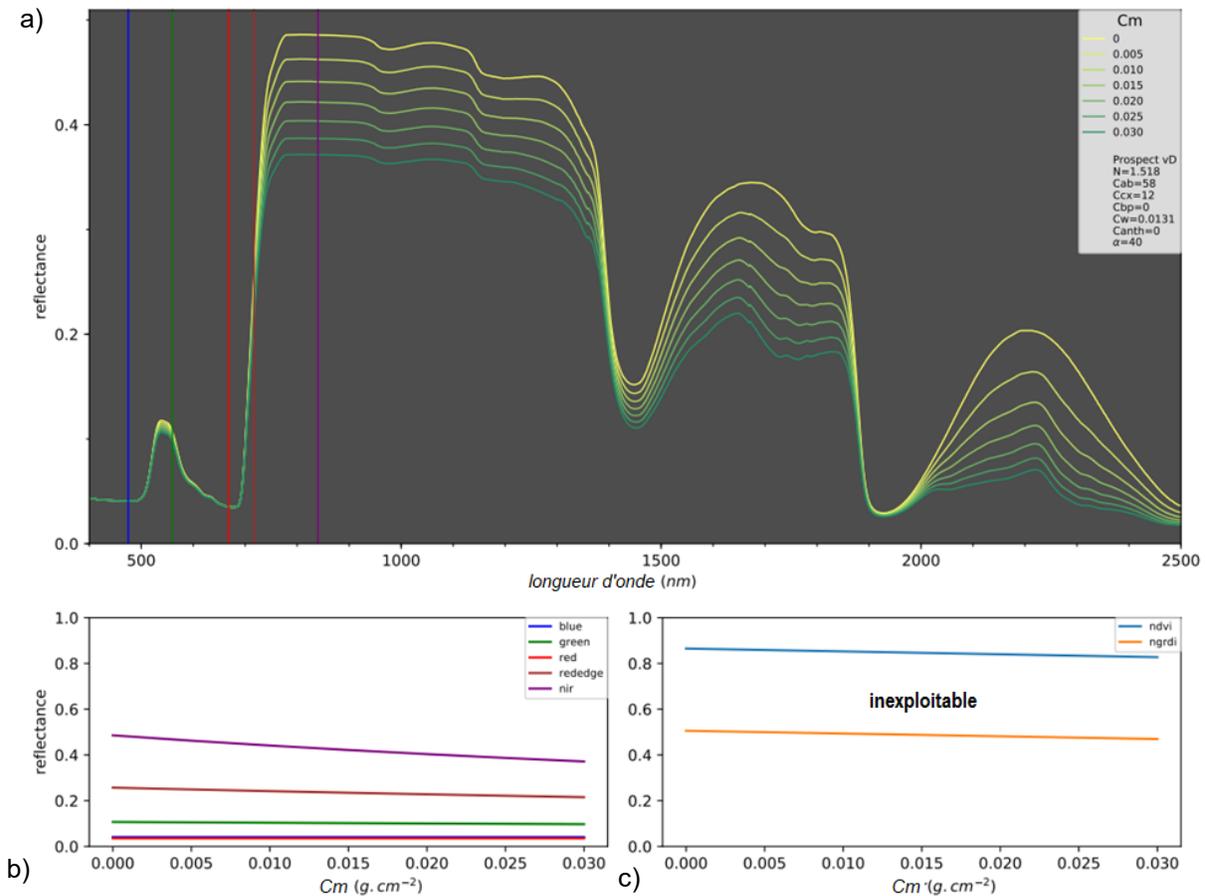


Figure 6.3 – Simulation PROSPECT en variant le paramètre Cm (teneur en matière sèche, en $\mu\text{g cm}^{-2}$) : a) signatures spectrales selon les valeurs de Cm, b) courbes de réflectance en fonction de Cm dans les 5 bandes de la Micasense RedEdge, c) évolution du NDVI et du NGRDI en fonction de Cm. Les valeurs des autres paramètres du modèle ont été fixées comme suit : $N = 1,518$; $C_{cx} = 12 \mu\text{g cm}^{-2}$; $C_{anth} = 0 \mu\text{g cm}^{-2}$; $C_{bp} = 0$ (unité arbitraire) ; $C_{ab} = 58 \mu\text{g cm}^{-2}$; $C_w = 0,0131 \mu\text{g cm}^{-2}$.

À l'exception de la courbe du PIR qui présente une légère pente négative, les courbes de réflectance dans les bandes de la Micasense RedEdge ont une pente quasi nulle (figure 6.3b). Par conséquent, ni le NDVI ni le NGRDI ne réagissent suffisamment à la quantité de matière sèche (figure 6.3c) pour être de bons indicateurs. Il faudrait plutôt faire intervenir une bande dans le SWIR, notamment autour de 2160 nm, qui se montre plus sensible à Cm. C'est ainsi que l'on peut proposer l'indice $NDBI = \frac{R_{860} - R_{2160}}{R_{860} + R_{2160}}$ (Normalized Difference Biomass Index) qui s'inspire de l'indice $NDBleaf = \frac{R_{2160} - R_{1540}}{R_{2160} + R_{1540}}$ (Le Maire *et al.*, 2008) et présente une bonne corrélation avec la teneur en matière sèche (figure 6.4).

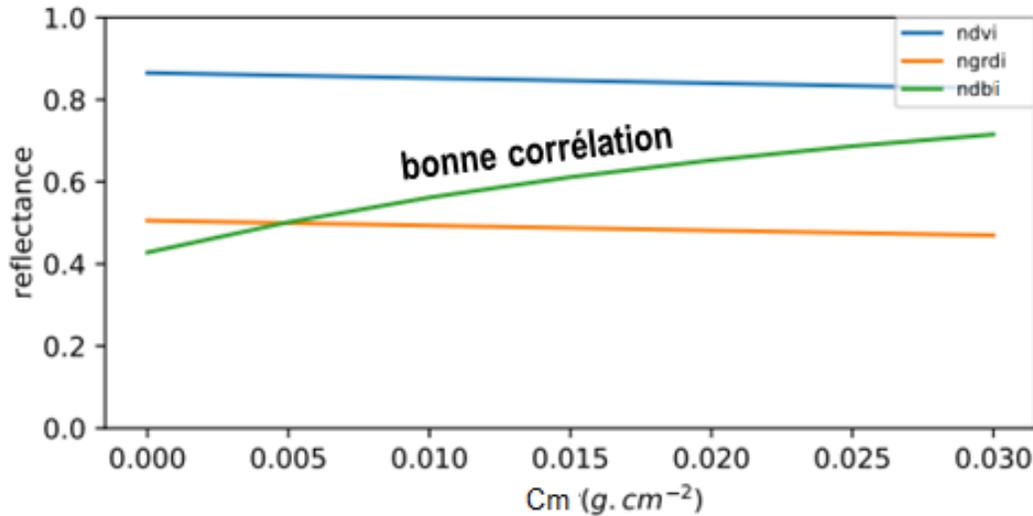


Figure 6.4 – Évolution de l'indice NDBI en fonction de la teneur en matière sèche.

6.4. Discussion

Les résultats tirés de notre étude théorique avec le modèle PROSPECT ont permis de montrer l'inaptitude de l'indice NDVI à mesurer l'évolution des différents composants biochimiques de la feuille. Ces conclusions auraient pu être avancées, rien qu'en observant les valeurs des coefficients d'absorption de ces composants. Comme on peut le voir à la figure 3.7, où les coefficients d'absorption sont tracés en fonction de la longueur d'onde, il est d'ores et déjà possible de constater que pour les longueurs d'onde qui concernent le NDVI :

- tous les constituants de la feuille ont un coefficient d'absorption très faible dans la bande du PIR autour de 800 nm : le rayonnement solaire n'y est pratiquement pas absorbé ; ce qui, associé à la structure de la feuille, explique la forte réflectance dans cette bande spectrale ;
- le pic d'absorption de la chlorophylle dans le rouge (autour de 675 nm) indique que le rayonnement solaire y est fortement absorbé et que la réflectance y est faible.

Par conséquent, le NDVI d'un pixel pur « végétation » ne varierait qu'en fonction de sa concentration en chlorophylle. Les autres paramètres n'auraient donc qu'un impact faible sur la valeur du NDVI ; ce qui a été confirmé dans ce chapitre.

L'analyse de sensibilité du modèle PROSPECT avec la méthode OFAT a permis de mettre en relation le rôle de chaque composant biochimique d'une feuille verte, notamment la

chlorophylle et la matière sèche, avec la signature spectrale observée. Cette méthode suppose que chaque paramètre du modèle peut évoluer indépendamment les uns des autres.

Cependant, certains paramètres pourraient être corrélés (positivement ou négativement) entre eux : la chlorophylle et la matière sèche, par exemple ; ou les différents pigments (Cab, Ccx, Canth, Cbp). Par ailleurs, si on suppose un taux d'humidité constant de 90 % (comme relevé à la section 5.2.3), la teneur en eau C_w devrait varier avec la quantité de matière sèche C_m . Dans ce cas, le fait de fixer C_w pendant que C_m augmente signifie que le taux d'humidité diminue ; ce qui ne reflèterait pas forcément la réalité. Il faudrait ainsi étudier la corrélation entre ces paramètres pour savoir s'ils peuvent être considérés comme indépendants. Le modèle PROSPECT, lui, ne tient pas compte de cette indépendance des paramètres : il permet seulement d'obtenir la signature spectrale d'une feuille verte selon sa structure physique et sa composition biochimique.

Par ailleurs, la valeur nominale choisie pour chacun des différents paramètres correspondait à des échantillons utilisés lors de l'expérience Lopex93 (Hosgood et al., 1993). Comme le stade de croissance de la plante n'était pas indiqué, il est impossible de savoir si les valeurs nominales utilisées étaient représentatives et applicables pour des plantes entre les stades V3 et V8 qui nous intéressent dans cette thèse.

Nous admettons que les résultats obtenus sont quand même exploitables, puisque proches de ce qui a déjà été publié pour des études empiriques (saturation du NDVI, meilleurs résultats avec les indices NDRE et NDBI). Le modèle PROSPECT montre qu'il est théoriquement possible de créer un indice de végétation pour estimer les différents composants biochimiques d'une feuille verte, en ayant recours aux bonnes longueurs d'onde. Cet indice ne saurait cependant être le NDVI, qui est particulièrement sensible à la chlorophylle mais seulement pour de faibles valeurs de celle-ci. Il faut ainsi utiliser les indices pertinents, par exemple le NDRE pour la chlorophylle ou le NDBI pour la matière sèche.

Néanmoins, en pratique, l'estimation de la réflectance pour chacune des longueurs d'onde utilisées se bute à différents défis qu'il faut bien comprendre lorsque l'on est à l'échelle d'un pixel aussi fin.

Tout d'abord, les bandes spectrales des caméras utilisées doivent être étroites avec peu ou pas de superposition entre elles : c'est le cas pour les caméras multispectrales et hyperspectrales comme vu aux sections 2.3.3 et 2.3.4 ; avec les défauts inhérents qu'il faut corriger, dont les effets de vignettage (Lelong *et al.*, 2008) et de parallaxe (Rabatel et Labbé, 2016). Le défi majeur reste cependant la prise en compte de la réflectivité bidirectionnelle ou BRDF (*bidirectional reflectance distribution function*) qui caractérise la surface étudiée. En effet, dans le cas général, la réflectance dépend à la fois de la direction d'illumination et de la direction d'observation, par rapport à l'orientation de la surface. Pour enlever ces effets, on effectue alors une calibration radiométrique à l'aide d'une référence, soit une surface de réflectance connue (genre Spectralon) ou un capteur de lumière incidente (Assmann *et al.*, 2018) : pour ce faire, on suppose une surface lambertienne et horizontale. Cette hypothèse simplificatrice n'est plus valide à l'échelle des petites facettes d'une feuille où la diffusion est anisotrope avec, notamment, la présence d'une réflexion spéculaire (Bousquet *et al.*, 2005; Comar *et al.*, 2012).

Le mauvais alignement des bandes et la difficile calibration radiométrique, associés à une dégradation radiométrique lors du mosaïquage, rendent l'exploitation d'un indice de végétation précaire dans le cadre de l'imagerie dronique. Certains défis peuvent être surmontés en dégradant la THRS de l'image. C'est une voie possible pour continuer à exploiter les indices de végétation, une qui retourne à l'approche classique de la télédétection mais qui abandonne l'échelle d'observation fine offerte par la THRS.

6.5. Conclusion

Le recours au modèle PROSPECT nous a permis de mieux comprendre la relation entre le NDVI et les paramètres potentiels de la vigueur : Cab et Cm. L'indice NDVI, qui est couramment utilisé en télédétection, est surtout sensible à la teneur en chlorophylle. Sa variation dans un pixel pur n'est donc dû qu'à ce paramètre. Mais comme le NDVI est rapidement saturé, cet indice ne saurait être le meilleur pour correctement estimer ce paramètre biophysique : un indice comme le NDRE faisant intervenir les bandes *red edge* et PIR est plus pertinent. Dans notre cas, où nous cherchons à estimer la biomasse, le NDVI ne montre donc *a priori* pas beaucoup d'intérêt, à moins de supposer qu'il y a une forte corrélation entre la biomasse et la teneur en chlorophylle.

Comme nous l'avons vu à la section 6.3.2, la biomasse sèche interagit avec la lumière dans la portion SWIR du spectre électromagnétique. Le NDVI ne peut ainsi être un bon indicateur pour faire ressortir la biomasse d'une feuille. Cependant, il reste l'indice phare de la télédétection végétale notamment pour les capteurs de proximité. Nous allons donc y avoir recours pour comparer les performances du GreenSeeker par rapport aux images droniques (chapitre 7).

Un indice comme le NDBI pourrait à même d'estimer la biomasse sèche mais nous prenons la décision de ne pas poursuivre dans cette voie pour les raisons vues à la section précédente (section 6.4).

Chapitre 7. Étude avec des images droniques : comparaison avec le GreenSeeker

7.1. Introduction

Dans le cadre de la fertilisation, l'estimation de la vigueur du maïs, à travers la télédétection, est effectuée en utilisant un indice de végétation ou en estimant des paramètres biophysiques tels que la biomasse, l'indice de surface foliaire (LAI) ou la teneur en chlorophylle. Habituellement, le producteur a recours à un capteur de la vigueur embarqué sur un tracteur : capteurs actifs tels le GreenSeeker, le Crop Circle ou le Yara N-Sensor, qui mesurent l'état de la santé de la culture à travers l'indice NDVI (Amaral *et al.*, 2015).

L'introduction récente des drones (UAV) offre une autre option pour l'évaluation à distance du statut de l'azote dans le maïs. Les drones peuvent être déployés rapidement et ont une résolution spatiale très élevée. Il est important de comparer leurs performances par rapport aux technologies existantes, pour en faire ressortir les avantages et les inconvénients. Zhang et Kovacs (2012) ont réalisé une revue détaillée des utilisations, du potentiel et des limites des drones pour l'agriculture de précision. Cependant, peu d'études ont effectué la comparaison de performance entre l'imagerie « classique » acquise par satellite et celle acquise par drone, et encore moins entre l'imagerie dronique et celle acquise par un capteur de proximité.

Il existe quelques études comparant l'imagerie dronique à un capteur de proximité (Caturegli *et al.*, 2016; Tattaris *et al.*, 2016). Ce dernier était portatif et effectuait seulement des mesures ponctuelles : il était alors impossible d'obtenir une cartographie continue à l'échelle du champ. Pour cartographier la vigueur de la culture de façon complète, le capteur de proximité doit être embarqué sur un véhicule (tracteur en l'occurrence) qui parcourt l'ensemble du champ. À notre connaissance, aucun exemple de comparaison avec des capteurs embarqués n'a été trouvé dans la littérature.

L'objectif de cette étude était donc de comparer l'imagerie acquise à partir d'un drone à voilure fixe aux mesures obtenues avec des capteurs embarqués GreenSeeker dans le contexte de l'estimation de la vigueur du maïs via la télédétection. Le système GreenSeeker est utilisé

comme référence pour la comparaison avec le drone, parce qu'il constitue la norme de l'industrie. Étant donné la meilleure résolution spatiale de l'imagerie dronique, nous nous attendons à ce que celle-ci donne des résultats significativement meilleurs, comparés à ceux du GreenSeeker.

7.2. Méthodologie

7.2.1. Sites à l'étude

Notre expérience a été menée à l'été 2015 sur deux champs commerciaux de maïs (*Zea mays* L., cultivar Dekalb 4617, 2900 UTM). Les stades de croissance visés étaient ceux pour lesquels les plants de maïs comportaient 4 à 6 feuilles pleinement déroulées (stades V4 à V6). Ces deux champs, que nous désignerons comme champ 1 (45°16'35.78" Nord, 73°17'26.48" Ouest) et champ 2 (45°14'23.22" Nord, 73°23'53.72" Ouest), étaient situés près de Saint-Jean-sur-Richelieu, dans le sud du Québec.

Le champ 1, relativement petit (2,9 ha) et plat, présentait des zones infestées par des mauvaises herbes, principalement du souchet comestible (*Cyperus esculentus* L.). Le champ 2, beaucoup plus grand (12,9 ha), présentait une plus grande variation topographique : il comportait un monticule au centre et se terminait par une légère dépression. Ce champ contenait des zones avec une présence significative de prêles (*Equisetum arvense* L.).

7.2.2. Images droniques et prétraitements

Pour l'acquisition des images droniques, nous avons opté pour l'utilisation d'un drone à aile fixe, plutôt qu'un drone de type multicoptère. En effet, tel que mentionné au chapitre 2, les drones de type avion permettent de couvrir une étendue plus vaste, du fait de leur plus grande autonomie. En couvrant l'entièreté d'un champ étudié avec un drone à aile fixe, nous supposons qu'il sera possible de mieux faire ressortir toute la variabilité spatiale de ce champ.

La campagne d'acquisition d'images a été menée le 13 juin 2015 pour le champ 1, et le 17 juin 2015 pour le champ 2 (tableau 7.1). Les vols eurent lieu en milieu de journée, entre 10h et 14h, sous un ciel dégagé, avec des vents faibles (inférieurs à 15 km h⁻¹). L'altitude moyenne de vol

était de 150 m (champ 1) et 140 m (champ 2) AGL. Le plan de vol fut généré et contrôlé par le logiciel eMotion 2 (senseFly SA, Cheseaux-Lausanne, Suisse).

Tableau 7.1 – Dates d’acquisition des données pour l’expérience en 2015

	Acquisition GreenSeeker	Acquisition UAV	Échantillonnage terrain
Champ 1	12 juin 2015	13 juin 2015	14 juin 2015
Champ 2	18 juin 2015	17 juin 2015	17 juin 2015

La trajectoire de vol se présentait sous forme de lignes en quadrillage pour le champ 1 (figure 7.1) et en boîte mobile pour le champ 2 (figure 7.4) avec un espacement entre les lignes de vol suffisamment proche afin d’obtenir un recouvrement latéral minimum de 70 %. La vitesse de vol du drone ainsi que la fréquence d’acquisition des clichés par la caméra étaient réglées de sorte à obtenir un recouvrement longitudinal supérieur à 70 % également. Ce recouvrement était nécessaire pour garantir un bon mosaïquage.



Figure 7.1 – Trajectoire de vol en quadrillage au-dessus du champ 1, le 13 juin 2015. La zone d’intérêt à survoler est identifiée par le rectangle rouge, dont les dimensions sont environ 570 m x 280 m (source : capture-écran du logiciel eMotion 2).



Figure 7.2 – Trajectoire de vol en boîte mobile au-dessus du champ 2, le 17 juin 2015. La zone d'intérêt à survoler est identifiée par le rectangle rouge, dont les dimensions sont environ 1390 m x 125 m (source : capture-écran du logiciel eMotion 2).

Le drone utilisé était le modèle eBee (senseFly SA, Cheseaux-Lausanne, Suisse), de type aile fixe. Les deux caméras disponibles sur ce drone, permettant d'avoir la bande du proche-infrarouge (PIR), étaient :

- la Multispec 4C (Airinov, Paris, France), une caméra multispectrale à 4 bandes (vert, rouge, *red edge*, PIR) ;
- et la Canon Powershot S110 NIR (Canon Inc., Tokyo, Japon), une caméra RGB modifiée, convertie par senseFly pour produire une caméra de type RGNIR.

Nous avons eu recours aux deux caméras pour notre étude, embarquées à tour de rôle pour chaque survol. Mais, après traitement, nous avons éliminé la Multispec 4C : sa résolution spatiale était faible pour l'altitude de vol visée (10 cm de résolution pour une altitude de 100 m AGL) par rapport à la Canon (2,5 cm pour une altitude de 100 m AGL) ; et les corrections

radiométriques présentait des erreurs malgré la présence d'un capteur de luminosité intégré²⁰. Finalement, ce furent les images acquises avec la Canon Powershot S110 NIR qui furent analysées.

Les images brutes issues de la caméra Canon furent converties au format TIFF et importées dans le logiciel Pix4Dmapper Pro (Pix4D SA, Lausanne, Suisse). Grâce aux algorithmes d'aérotriangulation et d'ajustement par faisceaux (*bundle block adjustment*), les attitudes et la position des clichés ont été déterminées, en même temps que les coordonnées-terrain des points repérés dans ces clichés. Une mosaïque orthorectifiée fut ensuite générée, calibrée géométriquement à l'aide des points de contrôle (GCP) placés dans les champs et localisés avec un récepteur GNSS muni de la technologie RTK²¹ (SXBlue III-L, Geneq Inc., Montréal, Québec).

Concernant les corrections radiométriques, les images ont été étalonnées grâce à des panneaux Spectralon (Labsphere Inc., North Sutton, NH), de réflectance connue, dont l'image était prise immédiatement avant chaque vol de drone. Cette image servait au logiciel Pix4Dmapper Pro à calibrer radiométriquement les données de la caméra afin d'obtenir des valeurs de réflectance. Par ailleurs, le logiciel corrigeait également l'effet de « *rolling shutter* » (obturateur déroulant) propre à ces caméras commerciales utilisant un capteur CMOS. Enfin, comme chaque pixel de la mosaïque était généralement visible sur plusieurs clichés, sa valeur de réflectance était la moyenne pondérée²² des valeurs calculées sur ces clichés (Pix4D, s. d.) ; ce qui permettait ainsi de réduire l'effet de la BRDF. Des cartes de réflectance à 5 cm de résolution pouvaient ainsi

²⁰ La Multispec 4C corrigeait directement l'effet de l'éclairage solaire dans les images enregistrées. Cependant, le logiciel Pix4Dmapper Pro, qui a mis à jour son algorithme de correction radiométrique, nécessite dans sa dernière version que les informations sur l'éclairage solaire soient inscrites dans les métadonnées des images. Un firmware a été produit par Airinov pour mettre à jour la caméra en conséquence. Nos images étant acquises avant cette mise à jour, leur radiométrie ne pouvait malheureusement plus être corrigée par Pix4Dmapper Pro.

²¹ RTK pour *real time kinematic* (cinématique temps réel) est une technique de positionnement par satellite qui utilise les mesures de phase de ondes porteuses des systèmes GNSS.

²² Selon la documentation fournie par Pix4D, un poids plus important est assigné aux pixels proches du centre de l'image, ainsi qu'aux pixels les proches et les plus perpendiculaires au terrain (<https://support.pix4d.com/hc/en-us/articles/204894705-Camera-Requirements-for-Precision-Agriculture>).

être produites et utilisées dans le calcul du NDVI (ci-après NDVI_UAV_{5cm}). Ce calcul a été fait à l'aide du logiciel PCI Geomatica.

Pour comparer le drone au GreenSeeker, la carte NDVI_UAV_{5cm} a été utilisée pour extraire la valeur de NDVI dans chaque empreinte du GreenSeeker (voir section 7.2.3.1), ci-après NDVI_UAV_{6x2m}.

Pour comparer le drone aux données de biomasse, la carte NDVI_UAV_{5cm} a été exploitée pour générer deux produits dérivés :

- 1) NDVI_UAV_{plots} : un rectangle de 1,5 m x 1 m (appelé par la suite « parcelle *in situ* ») correspondant à chaque zone échantillonnée, a été dessiné et affecté de la valeur moyenne des pixels contenus dans ce rectangle²³.
- 2) NDVI_UAV_{rows} : pour exploiter davantage la haute résolution spatiale offerte par les images droniques, les rangs de culture à l'intérieur de chaque zone échantillonnée ont été délimités manuellement (appelés « rangs *in situ* ») et seuls les pixels inclus dans ces rangs étaient moyennés.

7.2.3. Données de GreenSeeker et traitements

7.2.3.1. Fonctionnement du GreenSeeker

Le GreenSeeker (Trimble, Sunnyvale, Californie) est un capteur commercial qui permet de mesurer la réflectance de la canopée. C'est un système actif, produisant sa propre source de lumière grâce à deux diodes électroluminescentes (*LED*) illuminant le sol dans deux longueurs d'onde spécifiques : 656 nm (rouge) et 774 nm (PIR). Ces deux mesures sont utilisées pour le calcul du NDVI.

²³ Il est important de savoir que le NDVI étant le résultat d'une division, le NDVI moyen (c'est-à-dire calculé comme la moyenne des valeurs de NDVI des pixels considérés) n'est pas forcément égal au NDVI calculé à partir des valeurs moyennes de réflectance. L'annexe A montre que les valeurs trouvées peuvent théoriquement être très différentes. Cependant, pour notre expérience en question, les deux méthodes fournissaient des résultats assez proches.

Dans notre expérience, un tracteur a été équipé de huit capteurs GreenSeeker (appelés têtes). Les opérations d'acquisition des données ont été effectuées le 12 juin 2015 dans le champ 1 et le 18 juin 2015 dans le champ 2, avec un jour de différence par rapport au survol avec le drone (tableau 7.1). Les huit têtes de capteur GreenSeeker étaient orientées et positionnées directement sur huit rangs de maïs, à une hauteur d'environ 1 m. La fauchée – c'est-à-dire l'empreinte latérale au sol – de chaque tête GreenSeeker était d'environ 60 cm.

L'ordinateur de bord était directement connecté au système d'autoguidage du tracteur, équipé d'un GNSS RTK amélioré (Trimble, Sunnyvale, Californie). La vitesse du tracteur était d'environ $7,2 \text{ km.h}^{-1}$ (soit 2 m.s^{-1}) afin d'obtenir un espacement de 2 m entre chaque enregistrement de données.

7.2.3.2. *Cartographie du NDVI*

Chaque mesure de point GreenSeeker était en fait la valeur moyenne du NDVI mesurée par les huit têtes sur la zone balayée par le capteur depuis le dernier point d'acquisition. Sa véritable empreinte était alors un rectangle dont les dimensions correspondaient à la fauchée des huit têtes (soit 6 m) et à la distance parcourue par le tracteur entre deux points GNSS (environ 2 m, selon la vitesse du tracteur). Pour chaque enregistrement de GreenSeeker, l'empreinte correspondante a été numérisée dans le logiciel ArcGIS (ESRI, Redland, Californie) et la valeur NDVI mesurée ($\text{NDVI_GS}_{6 \times 2 \text{m}}$) lui est alors assignée, tel qu'illustrée à la figure 7.3. Afin de mieux comprendre le NDVI mesuré par le système GreenSeeker en fonctionnement normal, c'est-à-dire à l'échelle des polygones définis précédemment, le $\text{NDVI_GS}_{6 \times 2 \text{m}}$ a été ensuite comparé au $\text{NDVI_UAV}_{6 \times 2 \text{m}}$ dérivé de l'imagerie dronique.

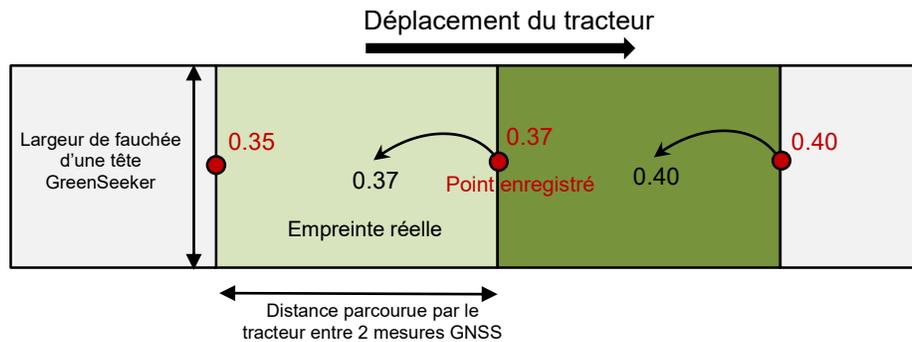


Figure 7.3 – Conversion des valeurs GreenSeeker enregistrées en empreintes réelles (NDVI_GS_{6x2m}), utilisées pour comparer avec les données UAV.

Par ailleurs, nous avons développé un script Python (Python Software Foundation, <https://www.python.org>) qui permettait d'extraire l'emplacement de chaque tête GreenSeeker ainsi que la valeur enregistrée par chacun de ces capteurs. Il était donc possible d'obtenir le NDVI de la culture directement pour chaque rang et non une valeur moyennée sur 8 rangs. L'ensemble des données ponctuelles (10 144 points pour le champ 1 et 55 951 points pour le champ 2) a ensuite été interpolé par krigeage ordinaire avec le logiciel GS+ (Gamma Design Software, Plainwell, Michigan).

La validation de l'interpolation a été effectuée par la méthode de validation croisée (*cross-validation*) proposée par le logiciel : chaque point est tour à tour retiré du jeu de données et sa valeur estimée par krigeage (Robertson, 2008) ; le point est ensuite réintégré dans le jeu de données avant l'estimation du point suivant. Il est alors possible de montrer graphiquement la valeur estimée du NDVI en fonction de la valeur réellement mesurée de chaque point (figure 7.4) : on peut ainsi constater un R^2 proche de 0,60 pour les deux champs.

La taille de la grille du raster interpolé (NDVI_GS_{1m}) a été fixée à 1 m pour la cartographie et l'analyse des données (figure 7.5). Cette valeur de 1 m pour la taille de la grille d'interpolation a été choisie pour s'approcher de l'ordre de grandeur des objets dans le champ (espace inter-rang de 0,75 m, quadrat d'échantillonnage de 1,5 m x 1 m) ; tout en améliorant la résolution « native » du GreenSeeker (empreinte de 6 m x 2 m) sans aller vers une résolution trop fine qui demanderait un traitement trop long, étant donné la taille des champs étudiés. NDVI_GS_{1m} a été utilisé pour comparer avec les points d'échantillonnage au sol.

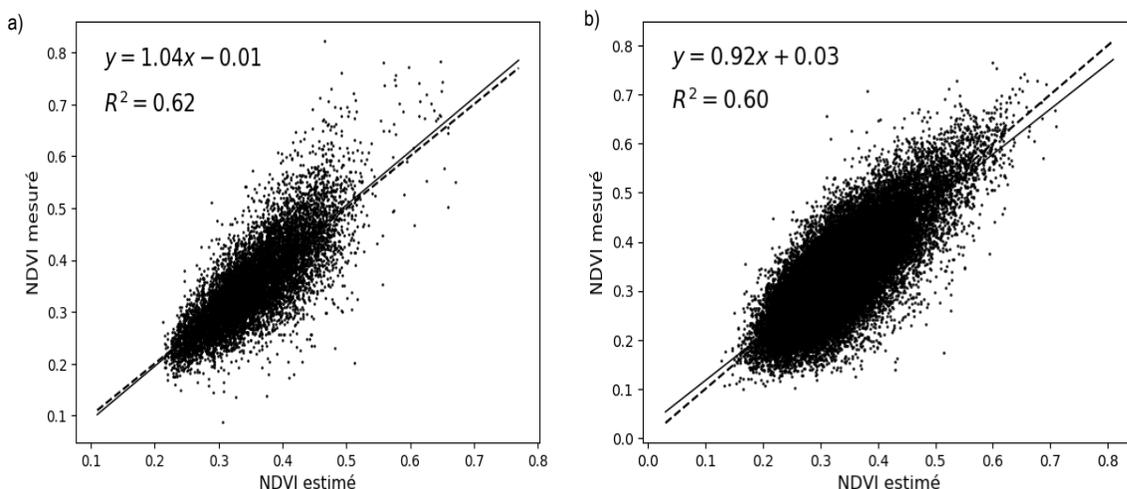


Figure 7.4 – Validation croisée des valeurs de GreenSeeker krigées pour a) Champ 1, N=10 144 et b) Champ 2, N=55 951.

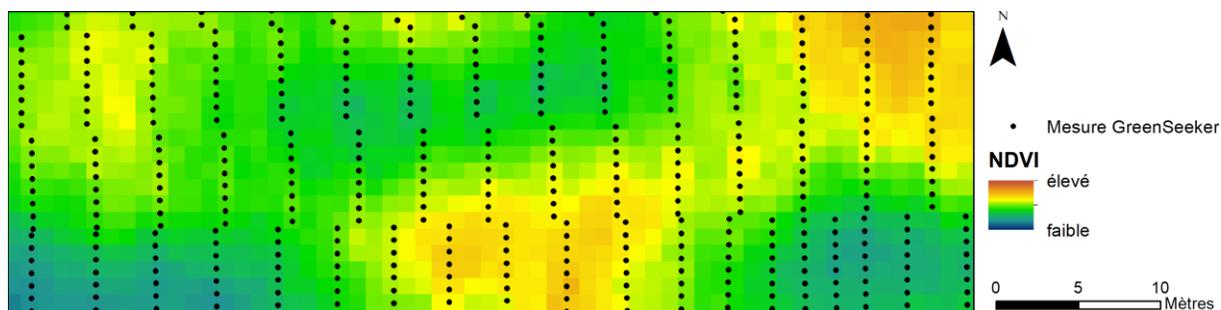


Figure 7.5 – Extrait de la carte NDVI_GS_{1m} après krigage, utilisée pour comparer avec les données terrain. Les points alignés représentent la position des valeurs NDVI enregistrées par chaque tête GreenSeeker lors du déplacement du tracteur.

7.2.4. Données de vérité terrain

Une campagne d'échantillonnage au sol a été menée pour recueillir des données sur la biomasse, aux fins de validation des données acquises par drone et par GreenSeeker. Pour chaque champ, l'intervalle séparant les dates d'acquisition de données et les dates d'échantillonnage au sol était inférieur à 3 jours (tableau 7.1).

Une stratégie d'échantillonnage stratifié basée sur des contraintes spatiales à deux couches (carte NDVI_GS_{1m} et bandes de traitement d'azote) a été utilisée pour identifier un bassin de 30 et 40 points d'échantillonnage pour les champs 1 et 2, respectivement. Chaque point a été positionné avec un récepteur GNSS RTK (SXBlue-III L, Geneq Inc., Montréal, Québec) qui

était précis à 5 cm. Une zone couvrant 2 rangs de 1 mètre linéaire a été définie à partir de chaque point d'échantillonnage. L'emplacement réel des zones échantillonnées a été ajusté latéralement pour couvrir les 2 rangs les plus proches et, si nécessaire, déplacé le long des rangs pour éviter une végétation anormalement clairsemée. Tous les plants contenus dans chaque zone d'échantillonnage ont été prélevés et pesés (biomasse fraîche), puis séchés et pesés à nouveau (biomasse sèche). Ces mesures de biomasse ont été utilisées pour établir une corrélation avec les paramètres de télédétection.

7.3. Résultats et discussion

7.3.1. Comparaison des cartes de NDVI : GreenSeeker vs UAV

La figure 7.6a et la figure 7.6b montrent comment les deux capteurs (caméra embarquée sur drone et GreenSeeker monté sur tracteur) perçoivent les variations de l'indice NDVI dans le champ 1. Comme prévu, la carte NDVI_GS_{1m} présente moins de détails que la carte NDVI_UAV_{5cm}. Les patrons de variabilité spatiale mis en évidence par les deux cartes sont très similaires, mais les rangs de culture sont parfaitement visibles sur la carte basée sur l'imagerie dronique (figure 7.6b, encadré b1). Les zones infestées par les mauvaises herbes –présentant un NDVI plus élevé en rouge (figure 7.6b, encadré b2) – peuvent être clairement distinguées alors qu'elles peuvent être seulement devinées à partir de la carte GreenSeeker (figure 7.6a, encadré a2).

La plage de valeurs du NDVI est plus large pour la carte basée sur le drone, variant de -0,10 à 0,85 (figure 7.6b). Cela s'explique par la résolution plus fine de l'image dronique : avec une taille de 5 cm, la plupart des pixels sont des pixels purs représentant soit le maïs, soit les mauvaises herbes ou soit le sol. Dans la carte GreenSeeker (figure 7.6a), les valeurs de NDVI varient de 0,21 à 0,65 : chaque zone balayée étant composée d'éléments hétérogènes, l'indice NDVI calculé à partir des réflectances moyennes a une plage de valeurs plus étroite. Des résultats similaires ont été observés dans le champ 2 (données non présentées).

La capacité de la THRS dronique à appréhender la variabilité spatiale était attendue et avait été confirmée par Matese *et al.* (2015), d'autant plus pour une culture en rangs où une résolution grossière masque ce patron spatial (Khaliq *et al.*, 2019). On aurait pu diminuer la taille de la

grille d'interpolation pour le GreenSeeker, et choisir 5 cm comme pour le drone. Cependant, la méthode de krigeage ne saurait faire apparaître des variations complexes entre 2 points de mesure : elle ne peut que prédire une tendance. Elle sera encore moins capable de faire ressortir les rangs de culture. D'ailleurs, les valeurs relativement faibles du R^2 (autour de 0,60), obtenues lors de la validation croisée, confirment que l'algorithme de krigeage n'a su prendre en compte toute la complexité spatiale au sein des 2 champs.

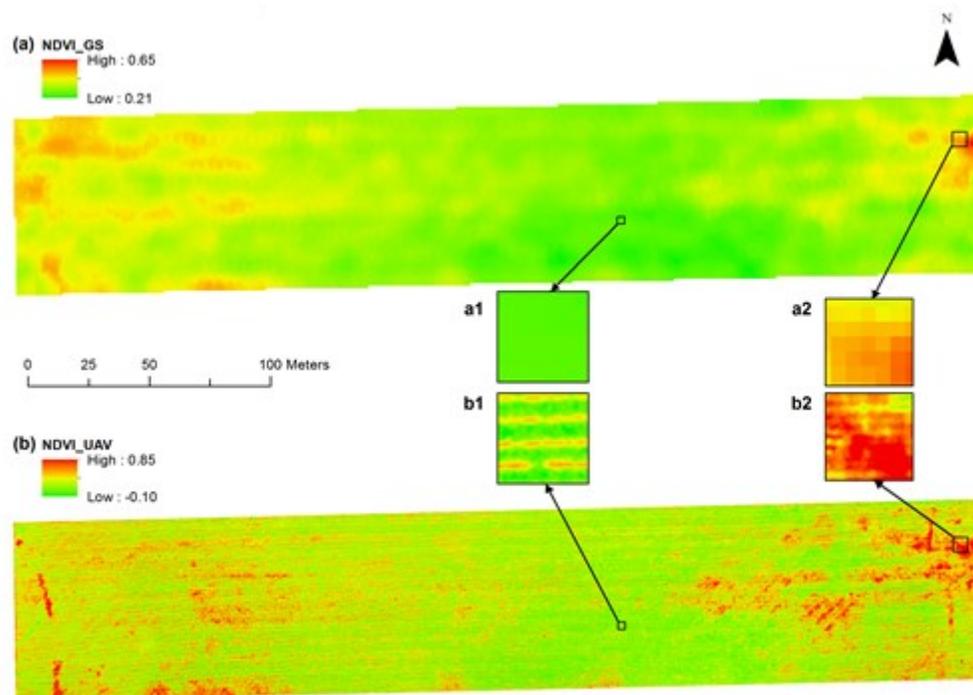


Figure 7.6 – Comparaison entre les cartes de NDVI pour le champ 1, en date du 13 juin 2015 : a) carte obtenue par krigeage des mesures GreenSeeker, résolution : 1 m (NDVI_GS_{1m}), b) carte obtenue par photogrammétrie à partir des images droniques, résolution : 5 cm (NDVI_UAV_{5cm}). Les encadrés a1 et b1 montrent, avec plus de détails, une zone du champ sans mauvaises herbes ; tandis que les encadrés a2 et b2 montrent une zone fortement envahie par les mauvaises herbes.

Pour mieux quantifier les différences entre les capteurs, nous avons utilisé le NDVI assigné à chaque empreinte GreenSeeker (NDVI_GS_{6x2m} et NDVI_UAV_{6x2m}). Une régression linéaire a été effectuée avec les deux jeux de données, ce qui a démontré des corrélations élevées (figure 7.7). Cependant, nous pouvons constater que les faibles valeurs de NDVI_UAV_{6x2m} sont surestimées par rapport à celles de NDVI_GS_{6x2m}. Mais les capteurs génèrent des valeurs assez similaires à la borne supérieure de l'intervalle NDVI. La distribution des valeurs de NDVI sur le terrain dépend donc des capteurs et de leur résolution spatiale – comme l'ont également

constaté Tremblay *et al.* (2008). Ce constat a des implications agronomiques pour la gestion des cultures, telles que les recommandations concernant les taux d'azote variables.

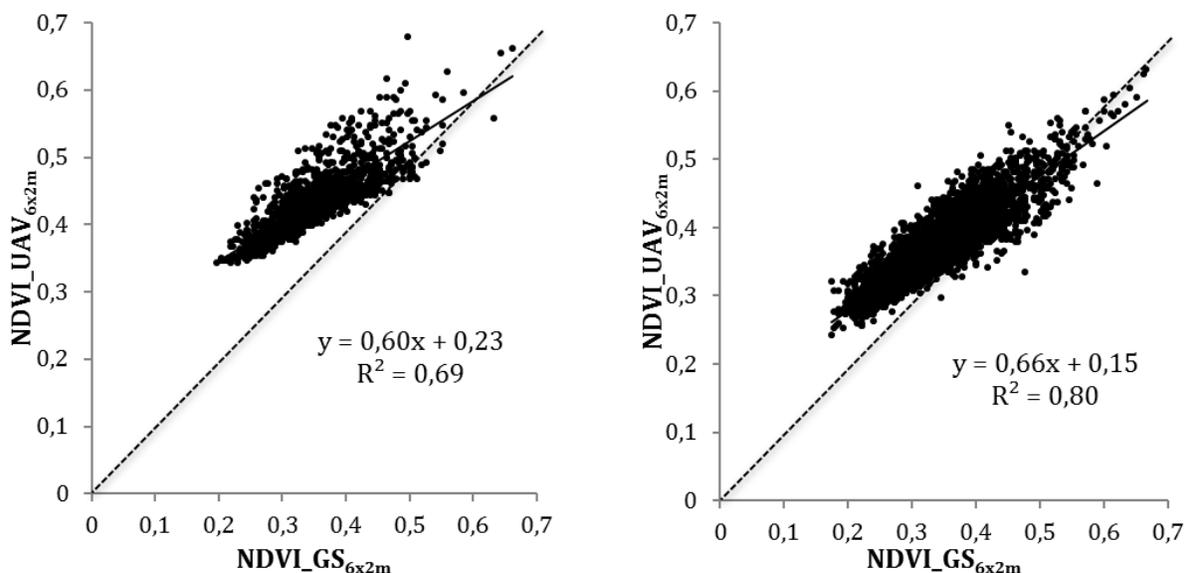


Figure 7.7 – Relation entre NDVI_GS_{6x2m} et NDVI_UAV_{6x2m} pour les champs 1 (N=1216, à gauche) et 2 (N=6690).

Sur la base de ces fortes corrélations, NDVI_GS_{6x2m} a été utilisé pour prédire NDVI_UAV_{6x2m}. Une carte de différence a été produite en comparant NDVI_UAV_{6x2m} prédit et le NDVI_UAV_{6x2m} mesuré pour le champ 1 (figure 7.8). Les zones où les valeurs NDVI_UAV_{6x2m} mesurées sont supérieures à leur valeur prédite correspondent parfaitement aux zones infestées par les mauvaises herbes. Des résultats similaires ont été observés dans le champ 2 (données non présentées).

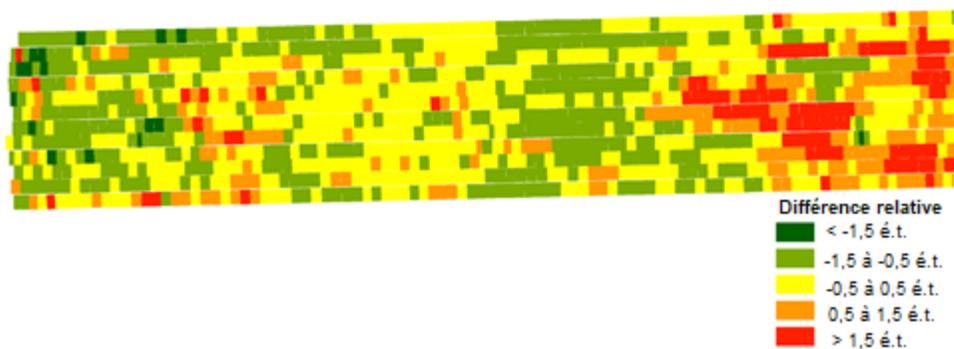


Figure 7.8 – Carte résiduelle montrant la différence relative entre les données NDVI_UAV_{6x2m} mesurées et celles prédites à partir de NDVI_GS_{6x2m}, pour chaque empreinte GreenSeeker, exprimée en écart-type (é.t.).

Ce résultat pourrait s'expliquer en partie par les différentes géométries de visualisation des deux capteurs. Vu que les têtes GreenSeeker étaient positionnées directement sur les rangs de maïs et qu'elles émettent un faisceau de lumière qui allait en s'élargissant jusqu'au sol où leur fauchée n'était que de 60 cm (inférieure à l'espace inter-rang de 75 cm), le NDVI_GS_{6x2m} était plus sensible au couvert de maïs qu'aux mauvaises herbes et au sol, situés plus bas dans les entre-rangs. En revanche, la moyenne de NDVI_UAV_{6x2m} a été calculée à partir de tous les pixels (y compris ceux entre les rangs) situés dans l'empreinte GreenSeeker. Étant donné que les pixels de l'image dronique après orthorectification ont été visualisés perpendiculairement au sol à partir du nadir, chaque pixel dans l'empreinte de 6 m x 2 m avait un poids égal dans le calcul du NDVI moyen. Par conséquent, la présence de mauvaises herbes a davantage contribué aux valeurs NDVI_UAV_{6x2m} qu'aux valeurs NDVI_GS_{6x2m}.

Tattaris *et al.* (2016) ont comparé le NDVI calculé à partir d'images droniques avec celui mesuré avec un GreenSeeker portatif. Les valeurs de corrélation, obtenues pour 10 séries de mesure, se situaient autour de 0,8 et 0,9 (sauf pour une expérience où la corrélation était de 0,41). Traduites en termes de R^2 (entre 0,64 et 0,81), ces valeurs sont ainsi comparables à ce que nous avons trouvé pour nos 2 champs (0,69 et 0,80). De meilleures corrélations ont été trouvées par Caturegli *et al.* (2016) en comparant le GreenSeeker portatif et le drone : entre 0,83 et 0,97.

Il faut cependant signaler que ces expériences étaient menées sur du blé à maturité (Tattaris *et al.*, 2016) et du gazon (Caturegli *et al.*, 2016), des cultures « en tapis » (où l'effet du sol peut être supposé moins important que dans notre expérience), avec un plan de traitement minimisant les variations intra-parcellaires et maximisant les variations inter-parcellaires. Nous nous attendions à des résultats meilleurs.

7.3.2. Comparaison entre NDVI (UAV et GS) et points de validation au sol

Une relation linéaire peut être établie entre la biomasse sèche échantillonnée et le NDVI calculé pour les pixels de chaque zone d'échantillonnage (NDVI_UAV_{plots}) pour les deux champs. Mais le coefficient de détermination reste quand même bas (un peu plus que 30 %). Il n'y a pas d'amélioration significative lorsque l'on considère uniquement les pixels à l'intérieur des 2 rangs de maïs, NDVI_UAV_{rows}, pour chaque zone d'échantillonnage. Les relations linéaires sont

en général plus fortes lorsque l'on compare les NDVI_GS_{1m} avec les données de biomasse sèche. Ces relations sont illustrées dans la figure 7.9 pour les champs 1 et 2.

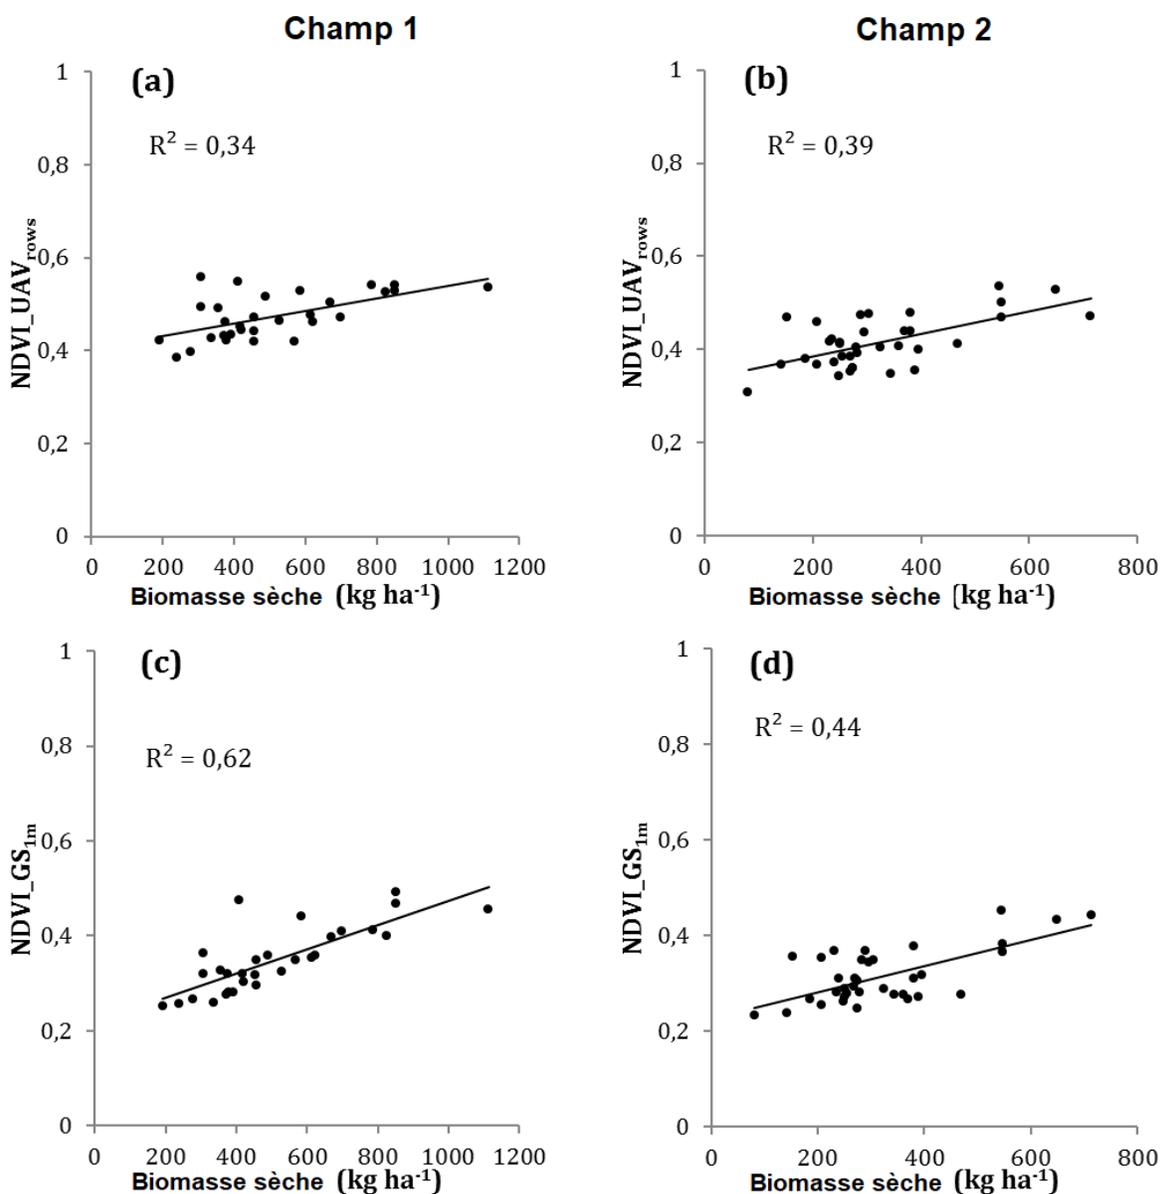


Figure 7.9 – Relation entre la biomasse sèche du maïs et le NDVI (UAV et GS) pour le champ 1 (a, c), N=30 ; et pour le champ 2 (b, d), N=40. NDVI_UAV_{rows} a été calculé à partir des rangs *in situ*.

Ces résultats montrent qu'il existe une certaine relation positive entre la biomasse et le NDVI que ce soit pour le drone ou le GreenSeeker, avec un R² supérieur pour le GreenSeeker. Cependant les valeurs de R² restent faibles (0,34 et 0,39 pour le drone ; 0,62 et 0,44 pour le GreenSeeker). Tilly *et al.* (2015), qui ont utilisé un spectroradiomètre pour mesurer les

réflectances, ont trouvé un R^2 semblable pour la relation linéaire entre la biomasse sèche de l'orge et l'indice NDVI ($R^2 = 0,34$) en considérant seulement les stades avant la floraison ; le R^2 devenait médiocre lorsque tous les stades jusqu'à la maturité étaient considérés ($R^2 = 0,07$). Cela confirme l'incapacité de l'indice NDVI à mesurer la biomasse sèche, trouvée dans notre étude théorique au chapitre 6.

Le fait qu'il existe quand même une certaine relation linéaire entre le NDVI et la biomasse pourrait être dû à une corrélation entre la biomasse et la teneur en chlorophylle. Mais sans mesures de la chlorophylle, il n'est pas possible de confirmer cette hypothèse.

Lelong *et al.* (2008) ont observé une relation linéaire similaire entre le LAI et le NDVI_UAV dans des expériences menées sur le blé aux premiers stades. Hunt *et al.* (2014) ont trouvé un coefficient de corrélation de 0,58 en comparant le GNDVI et la biomasse à l'échelle de la parcelle. Ces études ont utilisé des micro-parcelles avec réplication alors que notre étude était menée sur des champs commerciaux à grande échelle avec des images orthomosaiquées. Hong *et al.* (2007) pour leur part ont également constaté que le NDVI mesuré par le GreenSeeker entraînait une bonne corrélation avec le poids sec du maïs au stade V6–V7 ($r = 0,79$), mais dans leur cas, l'imagerie dronique n'a pas été comparée aux cartes GreenSeeker.

Plusieurs facteurs pourraient expliquer les meilleurs résultats pour le GreenSeeker dans notre cas :

1) la **précision du positionnement géographique des parcelles *in situ***. Leurs coordonnées GNSS, bien que fournies par le système RTK, n'étaient pas complètement précises. Ces coordonnées étaient celles théoriques générées aléatoirement au préalable. Une fois dans les champs, cependant, l'emplacement réel de chaque zone échantillonnée était légèrement décalé. NDVI_GS_{1m} a été extraite d'une carte krigée qui était plus robuste aux valeurs aberrantes et aux imprécisions spatiales dans le positionnement des parcelles. En effet, le krigeage tend à lisser les valeurs de NDVI pour les zones voisines. Les valeurs aberrantes avaient moins d'impact et le positionnement des parcelles pouvait tolérer une imprécision de quelques mètres. En revanche, les valeurs moyennes de NDVI_UAV_{plots} pourraient être complètement différentes si la zone tracée était décalée par erreur de quelques centimètres le long des 2 rangs ou, pire, sur

des rangs différents. De plus, les petites erreurs de géoréférencement dans les images droniques peuvent avoir augmenté cette imprécision spatiale.

2) la **qualité spectrale des images droniques**. Par son mode d'acquisition, l'imagerie dronique contenait des bruits inhérents aux conditions d'illumination (ombres, BRDF dont réflexions spéculaires et effets *hotspot*), des défauts de capteur (vignettage, *rolling shutter*, largeur et chevauchement des bandes spectrales, etc.) et le comportement instable du drone de type voilure fixe (roulis, tangage, lacet), bruits qui ne pouvaient être parfaitement corrigés par les prétraitements. Ces effets ont été rapportés par Zhang et Kovacs (2012) dans leur revue des applications droniques dans l'agriculture de précision. Les effets de la BRDF joueraient un rôle important dans la correction de la réflectance, mais leur impact sur l'imagerie haute résolution des drones a peu été étudié (Rasmussen *et al.*, 2016). L'orthomosaïquage a également diminué la qualité de l'image à cause du rééchantillonnage, ce qui a généré une image dégradée, où les pixels purs ont été mélangés spectralement. De plus, en tant que capteur actif, le GreenSeeker n'a pas été autant influencé par les conditions d'illumination et le prétraitement des images.

Pour améliorer la qualité de ces données, Link *et al.* (2013) ont recommandé un recouvrement élevé des images. Cela a été réalisé pour le champ 1 où les images ont été acquises par deux survols dont les lignes de vol étaient perpendiculaires. Le champ 2 étant trop grand, un tel plan de vol aurait nécessité un temps d'opération excessif, en plus du temps nécessaire aux atterrissages et décollages du drone pour le remplacement des batteries, ce qui aurait finalement entraîné des conditions d'illumination changeantes au cours de l'acquisition des données. Par conséquent, l'assemblage des images pour le champ 2 présentait certains défauts dus à un faible recouvrement des images. Il a ainsi fallu retirer de l'analyse des données certaines zones qui n'ont pas été correctement mosaïquées.

7.3.3. De la pertinence d'un indice de végétation

Les études visant à mesurer la vigueur de la végétation se servent abondamment des indices de végétation, notamment l'indice NDVI. L'arrivée des drones agricoles ne fait qu'accentuer cette utilisation massive des indices de végétation, comme l'a révélé la revue de littérature faite dans la Partie I.

Dans la plupart des travaux, la THRS obtenue avec les images droniques n'est pas exploitée puisque les pixels sont regroupés et leurs valeurs moyennées à des résolutions plus grossières (comme nous l'avons fait dans cette expérience), à la fois pour corriger les effets liés à la finesse du pixel et pour comparer avec des vérités terrain mesurées sur des superficies plus grandes. De ce fait, non seulement la résolution spatiale de l'imagerie dronique devient une « futilité » mais les mixels reconstitués s'en trouvent affectés par les effets du sol et de la présence des mauvaises herbes. C'est sans doute ce qui explique les mauvais résultats obtenus à la section 7.3.2.

Une stratégie simple serait de segmenter l'image et de séparer les pixels « végétation » (c'est-à-dire la culture d'intérêt) des autres pixels (sol et mauvaises herbes). C'est ce que nous avons tenté de faire en extrayant seulement les pixels correspondant aux rangs pour mesurer le $NDVI_{UAV_{rows}}$. Cette extraction a été faite manuellement. Son automatisation serait relativement facile dans un cas simple où il ne s'agirait que de discriminer le sol de la végétation à partir d'un indice de végétation. Cela devient plus complexe à faire entre la culture et les mauvaises herbes : elles présentent toutes les mêmes propriétés spectrales d'une plante verte. Il faut alors recourir à des techniques de reconnaissance de forme (Hlaing et Khaing, 2014), de texture (Kamath *et al.*, 2020) ou, dans le cas des cultures en rang (ou en grille), identifier les mauvaises herbes comme la végétation se trouvant entre les rangs (Onyango et Marchant, 2003). On peut également utiliser l'imagerie hyperspectrale (Suzuki *et al.*, 2008) et des méthodes d'apprentissage profond (Andrea *et al.*, 2017; Gao *et al.*, 2020).

Une fois, la segmentation de l'image faite, les pixels « végétation » sont à nouveau moyennés à une échelle d'interprétation plus grossière (par mètre carré ou par micro-parcelle) pour donner un indice NDVI moyen, à partir des pixels purs seulement. Or, comme la simulation PROSPECT le montre, le NDVI pour des pixels purs est corrélé avec la teneur en chlorophylle ; le NDVI moyen révèle donc la concentration moyenne en chlorophylle : la quantité de pixels « végétation » dans chaque zone d'observation n'a plus d'importance. À la limite, une zone contenant peu de pixels « végétation » mais avec des NDVI élevés aura un NDVI moyen plus élevé qu'une zone comportant beaucoup de pixels « végétation » mais avec des NDVI faibles. Ainsi l'utilisation de l'indice NDVI avec des images THRS est compromise : pour l'utiliser, il faut dégrader l'image !

Par ailleurs, comme nous l'avons constaté lors de cette expérience sur des champs commerciaux, le temps de vol peut être assez long en contexte opérationnel, où les champs de maïs ont une grande superficie. Le risque que les conditions d'acquisition soient différentes entre le début et la fin de l'opération est grand : d'un point de vue de la calibration radiométrique, cela complexifie encore plus l'estimation correcte de la réflectance ; ce qui est un énorme désavantage, peu importe l'indice de végétation considéré. Enfin, cette complexité dans la calibration radiométrique est d'autant plus exacerbée que les corrections effectuées par le logiciel Pix4DMapper Pro ne sont pas clairement décrites par le développeur. Comme l'ont souligné Assmann *et al.* (2018), les algorithmes de correction utilisés par le logiciel restent une boîte noire et susceptibles de changer d'une version à l'autre (comme nous l'avons appris à nos dépens pour la caméra Multispec 4C, à la section 7.2.2).

7.4. Conclusion

En comparant les indices NDVI obtenus avec le drone et le GreenSeeker, nous avons pu mettre en rapport la capacité des deux technologies à faire ressortir la variabilité spatiale de la vigueur de la culture. Si le drone permet clairement d'obtenir des images de meilleure résolution et donc de mieux appréhender la variabilité spatiale, le GreenSeeker offre une meilleure précision dans la mesure du NDVI. Cependant, ces deux technologies étaient piètrement performantes lorsqu'il s'agissait d'estimer la biomasse, le drone étant le moins performant des deux.

Ainsi le drone présentait des résultats comparables sinon pires que le GreenSeeker, avec des traitements plus complexes pour estimer correctement la réflectance. L'agriculteur n'a donc aucun avantage à adopter cette nouvelle technologie. Les résultats que nous avons obtenus, combinés à ceux provenant de notre étude théorique, nous ont convaincu de la non pertinence de l'indice NDVI pour la mesure de la vigueur des cultures. Il est désormais nécessaire de trouver d'autres façons d'exploiter la THRS dronique.

PARTIE III : DÉVELOPPEMENT D'UNE MÉTHODE POUR QUANTIFIER LA VIGUEUR DE LA VÉGÉTATION

Le but de cette partie est de présenter une série d'études visant à développer une méthode qui exploite mieux la très haute résolution spatiale des images droniques. Les chapitres 8 à 10 présentent les 3 expériences qui ont été menées, avec leur méthodologie et leurs résultats. Enfin, le chapitre 11 ouvre les perspectives liées à la nouvelle méthode de quantification de la vigueur.

Chapitre 8. Estimation de la vigueur individuelle : expérience en serre

8.1. Introduction

L'estimation de la vigueur tôt dans la saison permet de suivre la croissance de la culture afin de moduler l'apport en engrais azotés. Beaucoup d'algorithmes de recommandation de dose d'azote prennent en compte la vigueur à travers un indice de végétation, principalement le NDVI. Or, nous avons vu, dans la partie I, que cette méthode n'exploitait pas vraiment la THRS des images et fournissait un résultat mitigé. Comment alors mieux mettre à contribution l'imagerie dronique ?

Nous avons posé le postulat que la biomasse doit être le paramètre de référence de la vigueur du maïs (section 5.2.3). Ce caractère, que nous définirons comme « primaire », se résume au poids de la plante. Il ne saurait être directement quantifié par la télédétection qui, selon la Commission interministérielle de terminologie de la télédétection aérospatiale (1988), vise à effectuer des mesures à distance, sans contact matériel avec la cible. Il nous faudra donc passer par un caractère « secondaire », mesurable par télédétection et qui aura une corrélation suffisamment forte avec notre variable non mesurable – par télédétection – qu'est la biomasse. Ce caractère secondaire constituera donc une bonne variable *proxy* (Upton et Cook, 2014).

Sur une image de télédétection, les principales caractéristiques physiques que l'on peut mesurer sont les dimensions spatiales (longueurs, surfaces et volumes) ainsi que les propriétés spectrales (couleurs, dans le spectre visible et non visible). À cette étape de nos recherches, nous excluons les indices de végétation, basés sur les propriétés spectrales et qui nécessitent une estimation correcte de la réflectance. Nous préférons donc nous tourner vers la mesure des dimensions de la plante. Parmi celles-ci, citons :

- les longueurs (1 dimension) : hauteur de la plante, largeur et longueur des feuilles,
- les surfaces (2 dimensions) : surface foliaire, surface totale de la plante,
- les volumes (3 dimensions) : volume de la canopée.

Les longueurs et les surfaces peuvent être directement extraites d'une image en deux dimensions, mais ne concernent évidemment que les parties visibles, c'est-à-dire apparentes, de la plante. Ainsi sur une image prise au nadir (directement au-dessus de la canopée), seules les feuilles supérieures sont entièrement apparentes, tandis que les autres feuilles sont partiellement masquées et la tige complètement occultée. Pour voir la tige et également estimer la hauteur de la plante, une image oblique (prise avec un angle non nul par rapport à la verticale) sera nécessaire. En ce qui concerne les volumes, le drone a l'avantage de pouvoir survoler une scène selon des lignes de vol qui permettent d'obtenir suffisamment d'images pour reconstituer un modèle 3D (figure 8.1). En effet, la technique de photogrammétrie *Structure from Motion* (Ullman, 1979) permet d'estimer les structures tridimensionnelles à partir d'une séquence d'image 2D. Les logiciels de photogrammétrie destinés au traitement d'images droniques – dont les plus connus sont Pix4Dmapper Pro, Correlator 3D ou Agisoft Metashape (anciennement Agisoft Photoscan) – sont capables de générer un nuage de points de la scène, pour peu que le recouvrement des images soit suffisamment important et que les objets observés présentent assez de points caractéristiques (*key features*).



Figure 8.1 – Vue 3D d'une portion d'un champ de maïs, à la ferme de L'Acadie, été 2016. L'image a été produite à l'aide du logiciel Pix4Dmapper Pro à partir d'images droniques acquises avec le Phantom 3 Professional.

Un des objectifs de cette thèse est de développer une procédure automatique d'extraction d'information sur la biomasse du maïs, basée sur l'analyse d'imagerie ultra-fine (< 5 mm). Pour cela, il est nécessaire de déterminer, au préalable, le ou les paramètres secondaires qui serviront de proxys à la biomasse. Nous partons de l'hypothèse que la surface apparente, mesurée à partir

d'images prises au nadir et en oblique, constituerait un bon proxy. Pour confirmer cette hypothèse, nous avons réalisé une expérience en serre, au printemps 2017. Les mesures ont été effectuées sur des plantes individuelles, pour faciliter la recherche du lien entre la biomasse et la surface apparente. Ce chapitre décrit cette expérience et en donne les résultats.

8.2. Méthodologie

8.2.1. Description du protocole

Entre les mois de mars et mai 2017, le CRD de Saint-Jean-sur-Richelieu a mis à notre disposition une serre pour faire pousser le maïs en pots, et une salle de photographie pour acquérir des images des plants de maïs.

En plus de la lumière naturelle du soleil, la serre disposait de sources de lumière artificielle permettant d'assurer une quantité suffisante de lumière reçue par les plants de maïs. La température était contrôlée par un thermostat tandis que l'arrosage se faisait au goutte-à-goutte pour chaque pot (figure 8.2).



Figure 8.2 – Aperçu du dispositif en serre, CRD de Saint-Jean-sur-Richelieu, printemps 2017.

Chaque semaine, du 10 mars au 28 avril 2017, des graines de maïs étaient mises en pots (3 graines par pot). Chaque pot était identifié par la date de semis et un numéro séquentiel. Lorsque les graines ont germé, un seul plant de maïs par pot a été aléatoirement choisi pour être

gardé, tandis que les autres étaient coupés. Les pots étaient régulièrement pivotés pour éviter l'effet de tropisme, c'est-à-dire une croissance de la plante dans une direction donnée. Aucun engrais n'a été ajouté à part la dose présente initialement dans le terreau (de type Pro-Mix).

Les mesures ont commencé 35 jours après le premier semis. Du 14 avril au 12 mai, un échantillon de 4 plants était prélevé chaque semaine de telle sorte à avoir un plant par date de semis : 14 das, 21 das, 28 das et 35 das (das : *days after sowing*, nombre de jours après le semis). À cet échantillon de 4 plants s'ajoutait un autre lot de 4 plants qui représentaient tous la même date de semis (tableau 8.1) pour un total de 8 plants par date de mesure, sauf pour le 14 avril. Ces plants étaient choisis de façon à être le plus hétérogènes possibles pour offrir le plus d'individus avec des biomasses différentes.

Tableau 8.1 – Nombre de plants échantillonnés, pour l'expérience en serre (printemps 201).

Date des mesures	Nombre de plants par échantillon				Total
	selon le nombre de jours après semis (das)				
	14 das	21 das	28 das	35 das	
2017-04-14	1	1	1	1	4
2017-04-21	5	1	1	1	8
2017-04-28	1	5	1	1	8
2017-05-05	1	1	5	1	8
2017-05-12	1	1	1	5	8
Total	9	9	9	9	36

8.2.2. Mesures effectuées

Lors de chaque date d'échantillonnage, des mesures destructives et non destructives ont été effectuées sur chaque plant de maïs.

8.2.2.1. Photographie en salle

Avant les mesures destructives, chaque plant de maïs sélectionné était amené dans une salle spécialement aménagée pour acquérir des images sous (presque) tous les angles. Les murs et le plancher étaient tapissés d'un drap noir afin d'augmenter le contraste avec les plants photographiés. L'éclairage était fourni par quatre paires de lampes émettant de la lumière blanche et de la lumière PIR. Chaque paire de lampes était placée à un coin de la pièce de sorte à éclairer le plus uniformément possible les plants de maïs. La caméra Micasense RedEdge fut choisie et installée sur un dispositif sur rails (figure 8.3).



Figure 8.3 – Dispositif sur rails portant la caméra Micasense RedEdge.

Le dispositif sur rails permettait de translater la caméra dans un repère cartésien (x, y) , à une altitude h constante. Un système de pivot permettait également de modifier l'angle de visée de la caméra à $\alpha = 0^\circ, 15^\circ$ et 30° par rapport à la verticale – il s'agit ici de l'angle zénithal (figure 8.4b).

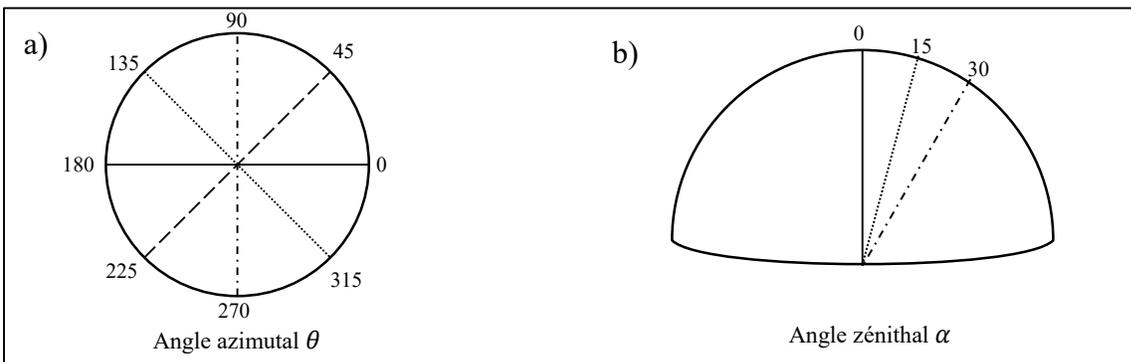


Figure 8.4 – Différents angles d'observation d'un plant de maïs : a) angle azimutal = angle d'orientation du plant ; b) angle zénithal = angle de visée de la caméra.

Le pot de maïs était placé à l'origine du repère $(0, 0)$, directement en-dessous de la caméra pour prendre les photos au nadir ($\alpha = 0^\circ$ par rapport à la verticale). Dans cette configuration, la caméra était située à une distance $d = h = 2,36 \text{ m}$ du dessus du pot et à une distance $r = 0$ sur l'axe y (figure 8.5). Puis la caméra était pivotée à l'angle zénithal $\alpha = 15^\circ$ et déplacée sur l'axe y jusqu'à ce que l'axe de la caméra soit dirigé vers le pied du maïs au centre du pot, ce qui marquait la position r pour cet angle de visée. Enfin, la caméra était pivotée à l'angle zénithal $\alpha = 30^\circ$ et éloignée de nouveau sur l'axe y . Cependant, à cause de la taille réduite de la salle,

pour cette dernière situation, il n’était pas possible de reculer suffisamment loin du pot : la caméra ne pointait donc pas exactement vers le centre du pot mais légèrement au-dessus.

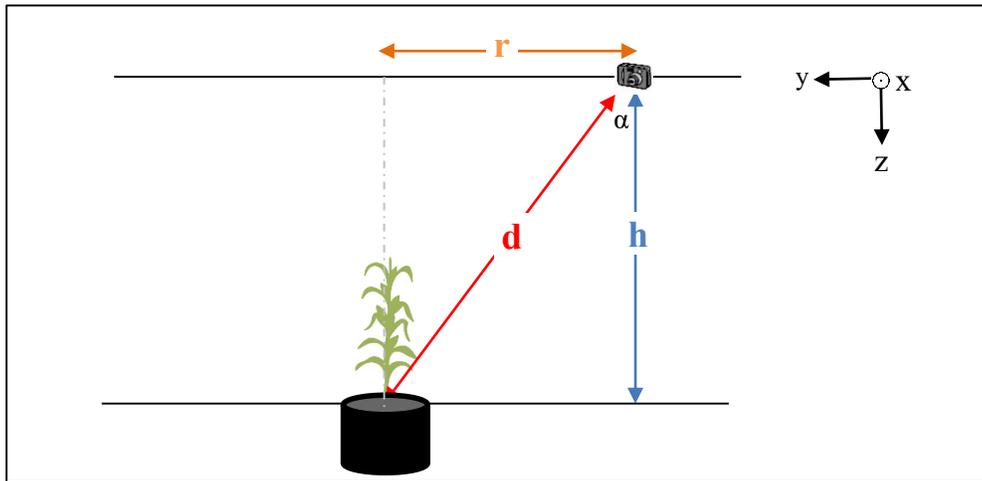


Figure 8.5 – Position de la caméra par rapport au plant de maïs photographié (vue de profil).

Selon l’angle de visée α , la distance d entre la caméra et le centre du pot, mesurée avec un télémètre laser, variait entre 2,36 m et 2,58 m, pour une résolution spatiale de 1,61 mm à 1,76 mm (tableau 8.2). La résolution nominale en millimètre (mm) et la superficie en millimètre carré (mm²) étaient calculées pour un pixel situé sur le plan de projection orthogonal à l’axe de la caméra et passant par le centre du pot de maïs (figure 8.6).

Tableau 8.2 – Caractéristiques des pixels d’une image, selon la position et l’angle de visée de la caméra Micasense RedEdge.

Angle zenithal α (degrés)	Distance d caméra-pot (m)	Résolution spatiale nominale (mm)	Taille d’un pixel (mm ²)
0	2,36	1,61	2,59
15	2,41	1,64	2,70
30	2,58	1,76	3,09

La résolution nominale ne tient pas compte de l’effet de perspective (les pixels éloignés du centre de l’image représentent normalement des superficies plus élevées), ni de la proximité des objets photographiés (un objet d’une superficie donnée occupera d’autant plus de pixels qu’il est proche).

Le pot de maïs était placé sur un plateau tournant : on pouvait ainsi présenter la plante avec différentes orientations – ou angles azimutaux – par rapport à la caméra (figure 8.3a). Les feuilles de maïs poussant de façon quasi symétrique de part et d’autre de la tige, la plante était d’abord présentée de « face », ce qui déterminait l’angle azimutal $\theta = 0^\circ$, puis elle était pivotée par incrément de 45° . En combinant les angles zénithaux (3 possibilités) et azimutaux (8 possibilités), un total de 24 combinaisons étaient possibles pour l’acquisition des images.

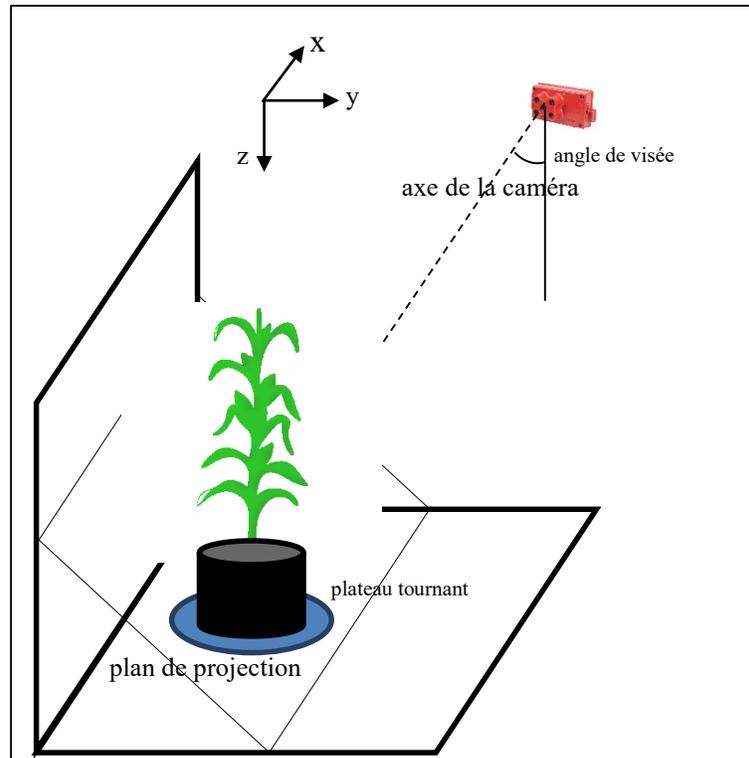


Figure 8.6 – Schéma du dispositif d’acquisition d’images en salle de photographie.

8.2.2.2. Mesures des plants de maïs

Diverses mesures biophysiques de chaque plant de maïs ont été prises :

- hauteur,
- stade de croissance,
- poids frais et sec de chaque feuille,
- longueur de chaque feuille,
- surface de chaque feuille,
- poids frais et sec de la tige.

La hauteur de la plante était mesurée du pied, sans les racines, jusqu'au cornet, partie la plus touffue d'où sortaient les nouvelles feuilles. Le stade de croissance était défini par le nombre de feuilles recourbées : on ne comptait que les feuilles suffisamment développées dont l'extrémité tombait vers le sol. Chaque feuille était ensuite détachée de la tige au niveau du collet, mesurée en longueur et en surface, et pesée (poids frais). La longueur a été mesurée à l'aide d'une règle graduée rigide, tandis que la surface a été mesurée avec un planimètre LI-3100C (LI-COR, Lincoln, Nebraska) ressemblant à celui montré à la figure 8.7. Après séchage dans un four à 65°C pendant 4 à 5 jours, les feuilles étaient à nouveau pesées individuellement (poids sec). Le pesage de la tige était effectué de la même manière, séparément des feuilles.



Figure 8.7 – Planimètre LI-3100C pour mesurer la surface des feuilles de maïs (source : LI-COR).

Pour chaque plant de maïs, le poids de toutes les feuilles était additionné pour obtenir le poids du feuillage, auquel on ajoutait le poids de la tige pour obtenir le poids du plant. Le tableau B.1 à la page 160 reprend toutes les mesures effectuées.

8.2.3. Traitement des images

La caméra Micasense RedEdge avait été choisie au départ pour pouvoir exploiter les valeurs de réflectance. Cependant, chaque cliché acquis par cette caméra produisait en fait 5 images distinctes correspondant à ce que voyait chacun des capteurs de la caméra dans sa bande spectrale. Ces images étaient légèrement décalées. À cause de la proximité entre la caméra et la cible, ainsi que la hauteur des plants, l'effet de parallaxe était trop important pour être corrigé. L'impossibilité de correctement aligner les bandes spectrales nous obligeait à traiter chaque bande individuellement. Comme notre objectif final était de mesurer la surface apparente, une

seule bande était nécessaire et suffisante. Nous avons choisi la bande du PIR (et parfois le *red edge*) où la réflexion du rayonnement incident par la plante était à son maximum, contrairement aux bandes du visible où la lumière était fortement absorbée. La plante se détachait ainsi parfaitement du fond noir de la salle.

Pour segmenter les images et identifier seulement les pixels « végétation », nous avons utilisé l’algorithme *watershed* (segmentation par ligne de partage des eaux) implanté par le module OpenCV en Python (Bradski, 2000). Cette méthode semi-automatique permettait de segmenter une image et d’en séparer les pixels en différentes classes. Dans notre cas, nous considérons seulement deux classes : « végétation » et « arrière-plan ».

Chaque semaine, 8 plants étaient photographiés sous 24 combinaisons d’angles différents, cela faisait donc un total de 192 clichés. Comme pour chaque combinaison d’angle, nous prenions 2 à 3 photos, le nombre total d’images à traiter pouvait dépasser 400 par semaine (tableau 8.3) pour un total de 1820 images pour toute l’expérience.

Tableau 8.3 – Nombre de plants photographiés et d’images traitées (expérience en serre, printemps 2017).

Date des mesures	Nombre de plants	Nombre d’images traitées
2017-04-14	4	190
2017-04-21	8	386
2017-04-28	8	413
2017-05-05	8	442
2017-05-12	8	389
Total	36	1820

Nous avons spécialement développé une interface en Python pour faciliter cette étape de segmentation : une image était présentée à l’écran et l’utilisateur y traçait, à la souris, quelques polygones d’entraînement pour désigner les pixels « végétation » et « arrière-plan », puis l’algorithme *watershed* segmentait le reste des pixels en ces deux classes. L’utilisateur corrigeait ensuite les erreurs de classification en les étiquetant correctement, et l’algorithme segmentait à nouveau l’image. La phase de correction était répétée jusqu’à ce que la classification soit satisfaisante.

Une fois chaque image segmentée, un script dénombreait ensuite le nombre N_v de pixels « végétation » et le convertissait en surface dite apparente, parce que seules les superficies visibles dans l'image étaient prises en compte.

Par ailleurs, comme l'ensemble des pixels de la plante (feuilles et tige) était dénombré, cette surface apparente représentait donc celle de la plante. C'est pourquoi le terme « surface apparente de la plante » (S_{ap}) a été privilégié par rapport à celui de « surface foliaire apparente » (S_{fa}). Théoriquement, cette différence est à faire uniquement dans le cas des visées obliques, puisque la tige est partiellement visible dans l'image et on aura donc : $S_{ap} > S_{fa}$; tandis que ces deux termes sont équivalents ($S_{ap} = S_{fa}$) pour les images au nadir, car la tige est complètement obstruée par les feuilles. Dans la suite du texte, le terme « surface apparente » fera spécifiquement référence à la surface apparente de la plante (S_{ap}).

La surface apparente S_{ap} est calculée selon la formule :

$$S_{ap}(\alpha, \theta) = N_v(\alpha, \theta) \cdot \rho(\alpha)^2 \quad (8.1)$$

où N_v est le nombre de pixels « végétation » visibles dans l'image et ρ la résolution nominale de l'image. Pour un même plant de maïs, le terme N_v varie théoriquement en fonction de la géométrie de visée (c'est-à-dire l'angle zénithal α et l'angle azimutal θ), tandis que la taille d'un pixel ρ augmente avec l'angle de visée α . Par conséquent, la surface apparente est *a priori* fonction des angles α et θ . Dans la suite du texte, nous omettrons les dépendances angulaires pour simplifier les notations.

8.3. Résultats et discussion

8.3.1. Corrélations entre paramètres de la plante

Le tableau 8.4 montre les coefficients de corrélation (Pearson) entre les paramètres biophysiques mesurés. De prime abord, nous pouvons constater que le stade de croissance n'est corrélé avec aucun autre paramètre : ce qui est rassurant, puisque nous avons sélectionné les plants de maïs pour qu'ils soient le plus hétérogènes possible même en ayant la même date de semis, donc à peu près le même stade.

Tableau 8.4 – Moyennes, écarts-types et matrice de corrélation de Pearson pour les paramètres biophysiques mesurés. Taille de l'échantillon : N=36.

	Moyenne	Écart-type	1	2	3	4	5	6	7	8	9	10
1. Hauteur (cm)	37,26	21,45	1,00									
2. Surface foliaire (cm ²)	1090,60	1150,62	0,97	1,00								
3. Plant, poids frais (g)	60,95	70,34	0,95	0,99	1,00							
4. Plant, poids sec (g)	9,60	16,78	0,69	0,77	0,82	1,00						
5. Tige, poids frais (g)	34,14	42,67	0,94	0,98	1,00	0,84	1,00					
6. Tige, poids sec (g)	6,08	14,04	0,55	0,64	0,70	0,98	0,73	1,00				
7. Feuillage, poids frais (g)	26,81	28,05	0,96	0,99	0,99	0,78	0,98	0,65	1,00			
8. Feuillage, poids sec (g)	3,52	3,97	0,96	0,99	0,99	0,75	0,98	0,61	0,99	1,00		
9. Longueur feuille max. (cm)	62,46	29,44	0,94	0,91	0,89	0,65	0,86	0,52	0,93	0,90	1,00	
10. Stade V	4,60	1,70	-0,01	0,03	0,06	0,11	0,05	0,12	0,07	0,04	0,11	1,00

Toutes les valeurs en gras sont significatives ($p < 0,01$).

Par ailleurs, le feuillage présente une très forte corrélation ($r = 0,99$) entre son poids frais et son poids sec. Cette corrélation diminue pour le plant en entier ($r = 0,82$), à cause d'une moins forte corrélation entre les poids frais et sec de la tige ($r = 0,73$). On peut supposer que la plante privilégie un taux d'humidité stable pour son feuillage : en cas de stress hydrique, elle aura tendance à rediriger l'eau contenue dans sa tige vers les feuilles. La tige sert donc de réserve d'eau pour maintenir un taux d'humidité constant au niveau du feuillage, ce qui peut supposer qu'un stress hydrique ne sera pas immédiatement perceptible en considérant seulement la teneur en eau au niveau de la feuille.

La hauteur et la surface foliaire sont fortement corrélées ($r = 0,97$). Ces deux paramètres sont également bien corrélés au poids frais des différentes parties de la plante et à la longueur maximale des feuilles ($r > 0,90$). Mais ils le sont dans une moindre mesure avec le poids sec de la tige et du plant entier ($0,55 \leq r \leq 0,77$). Par conséquent, l'un ou l'autre paramètre pourraient être utilisés comme proxys pour la biomasse fraîche, mais seraient de moins bons proxys pour la biomasse sèche. D'ailleurs, beaucoup d'auteurs ont utilisé la hauteur de la plante comme proxy de la biomasse, bien que ce soit directement en champ et non pour des plantes individuelles.

Dans une moindre mesure, la longueur de la plus grande feuille pourrait être utilisée comme proxy également. Cependant, nous pouvons déjà anticiper la difficulté à extraire cette information d'une image. Il en serait de même pour la hauteur, qui ne pourrait être correctement estimée qu'avec une image oblique. À l'inverse, il semble plus facile d'extraire la surface foliaire à partir d'une image de télédétection.

Nous n'avons pu trouver de littérature qui puisse confirmer nos résultats par rapport aux corrélations entre les différents phénotypes du maïs. Il est certain que des études de phénotypage existent mais, à notre avis, elles restent confidentielles et jalousement gardées par les producteurs de semences. Par ailleurs, comme le rendement est le but principal, sinon ultime, de toute culture, les études que nous avons trouvées concernaient plutôt les épis de maïs à maturité que la plante elle-même dans les premiers stades de croissance (Alves *et al.*, 2017; Buso *et al.*, 2019). Ces données pourraient varier grandement entre cultivars, selon les traits recherchés.

La forte relation entre la surface foliaire et le poids des feuilles est confirmée par plusieurs études : Huang, Su, *et al.* (2019) pour le bambou ; Huang, Ratkowsky, *et al.* (2019) pour 15 espèces de plantes à larges feuilles, réparties en 3 familles ; Najla *et al.* (2012) pour le persil. Ces auteurs ont trouvé que la surface foliaire était mieux corrélée à la biomasse fraîche qu'à la biomasse sèche. Cependant, ces relations ne sont pas forcément linéaires (Huang, Su, *et al.*, 2019; Milla et Reich, 2007).

8.3.2. Analyse de la surface apparente de la plante

Commençons par analyser comment se comporte la surface apparente de la plante (S_{ap}) en fonction de l'angle azimutal θ , c'est-à-dire l'orientation de la plante par rapport à la caméra. Pour chaque plant et chaque angle de visée α , on trace ainsi la S_{ap} en fonction de θ dans un diagramme en radar (figure 8.8).

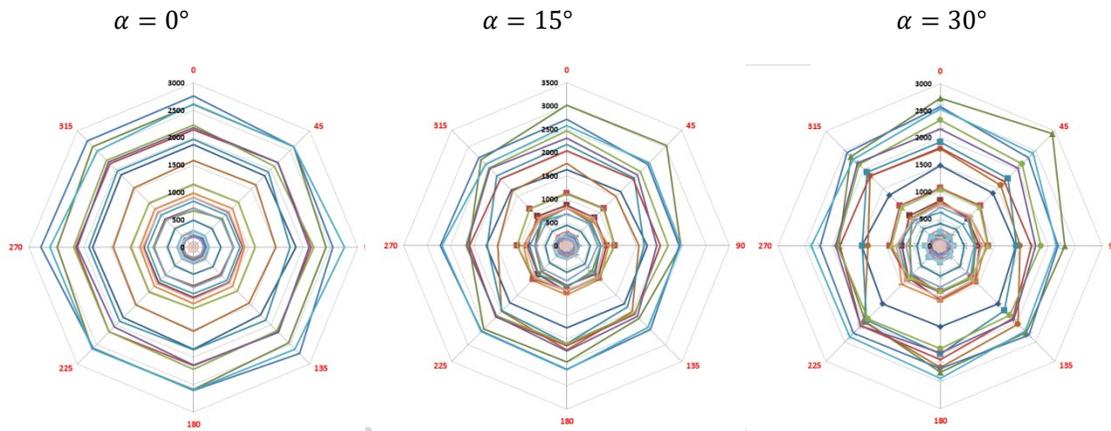


Figure 8.8 – Diagramme en radar représentant la surface apparente (en cm^2) en fonction de l'angle azimutal θ (en degrés), pour un angle de visée $\alpha = 0^\circ, 15^\circ, 30^\circ$. Chaque couleur représente une plante différente (N=36).

Dans la figure 8.8 (pour une meilleure lisibilité, ces trois graphiques ont été reproduits dans un plus grand format, à l'Annexe B aux figures B.1, B.2 et B.3, pages 161 à 163), il apparaît clairement que la surface apparente est quasiment constante peu importe l'orientation de la plante, pour $\alpha = 0^\circ$ (visée au nadir). Lorsque la caméra est directement au-dessus de la plante, l'orientation de celle-ci n'a logiquement aucune influence. Pour $\alpha = 15^\circ$ et $\alpha = 30^\circ$, on voit un léger déséquilibre pour certains angles θ , surtout en ce qui concerne les plus grandes plantes. Cela est certainement dû à l'effet de tropisme lié aux sources de lumière artificielle, malgré nos efforts pour l'atténuer. Mais dans l'ensemble, on peut considérer que l'effet de l'orientation est peu important.

En traçant la surface apparente en fonction de l'angle zénithal α pour chaque plante (figure 8.9), orientée « de face » ($\theta = 0^\circ$), on remarque également que l'angle zénithal ne joue pas un rôle perturbateur dans la détermination de la surface apparente. On admettra que ceci reste valable pour tous les angles θ (courbes non montrées).

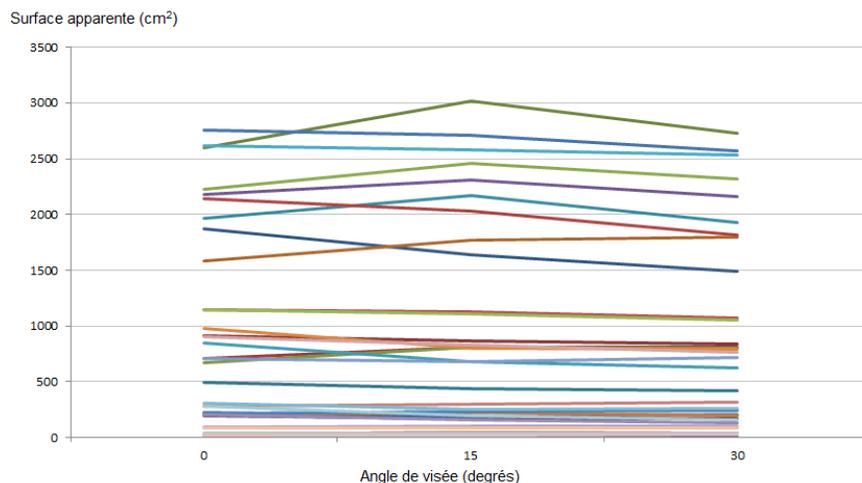


Figure 8.9 – Évolution de la surface apparente en fonction de l’angle de visée, l’angle azimutal est fixé à $\theta = 0^\circ$. Chaque couleur représente une plante différente (N=36).

En bref, ni l’angle de visée α ni l’orientation θ de la plante ne semblent influencer la valeur de la surface apparente de la plante. Examinons maintenant comment cette surface apparente rend compte de la biomasse de la plante.

L’expérience que nous avons menée, quoiqu’avec des moyens moins sophistiqués et moins coûteux, s’apparente au phénotypage à haut débit (*high throughput phenotyping*) qui consiste à mesurer différents traits caractéristiques de la plante par des méthodes non-destructives à l’aide de différents types de caméras (Fahlgren *et al.*, 2015). Le *leader* du marché est Lemnatec qui fournit des instruments et plateformes de phénotypage en laboratoire et sur le terrain (<https://www.lemnatec.com/plant-phenotyping/>). Ainsi, Ge *et al.* (2016) ont utilisé le système LemnaTec 3D Scanalyzer, équipé de 4 chambres d’acquisition d’images, pour prendre des photos de côté – ce qui correspond à un angle zénithal $\alpha = 90^\circ$ – sur des plants de maïs ($6 \leq \text{das} \leq 26$). Ils en ont calculé la surface projetée, moyennée pour 2 angles azimutaux ($\theta = 0^\circ$ et $\theta = 90^\circ$). Ils n’ont cependant pas considéré les images au nadir, car les gros plants étaient trop proches de la caméra (hauteur de la chambre expérimentale limitée 2,5 m).

8.3.3. Corrélations entre paramètres de la plante et sa surface apparente

Tout d'abord, on peut constater qu'il existe une corrélation forte entre la surface apparente de la plante et sa surface foliaire totale (figure 8.10), et ce quel que soit l'angle de visée. Par ailleurs, les droites de régression pour les angles $\alpha = 0^\circ$ et $\alpha = 15^\circ$ se superposent nettement : leurs pentes sont quasi identiques. En revanche, la droite de régression pour l'angle $\alpha = 30^\circ$ se situe légèrement en-dessous des deux précédentes : la surface apparente sous-estime la surface foliaire totale. Nous avons indiqué à la section 8.2.2.1 que la petitesse de la salle avait pour conséquence que les photographies ne pouvaient être prises dans de bonnes conditions géométriques pour $\alpha = 30^\circ$. Cela pourrait expliquer la sous-estimation des valeurs.

En fait, les 3 pentes ne sont pas significativement différentes puisque leurs intervalles de confiance à 95 % se chevauchent. Nous pouvons donc dire d'une part, que la surface apparente est un bon prédicteur de la surface foliaire totale, avec des R^2 supérieurs à 97 %. D'autre part, peu importe l'angle de visée, la caméra voit à peu près la même proportion de la surface foliaire totale (environ 76 %).

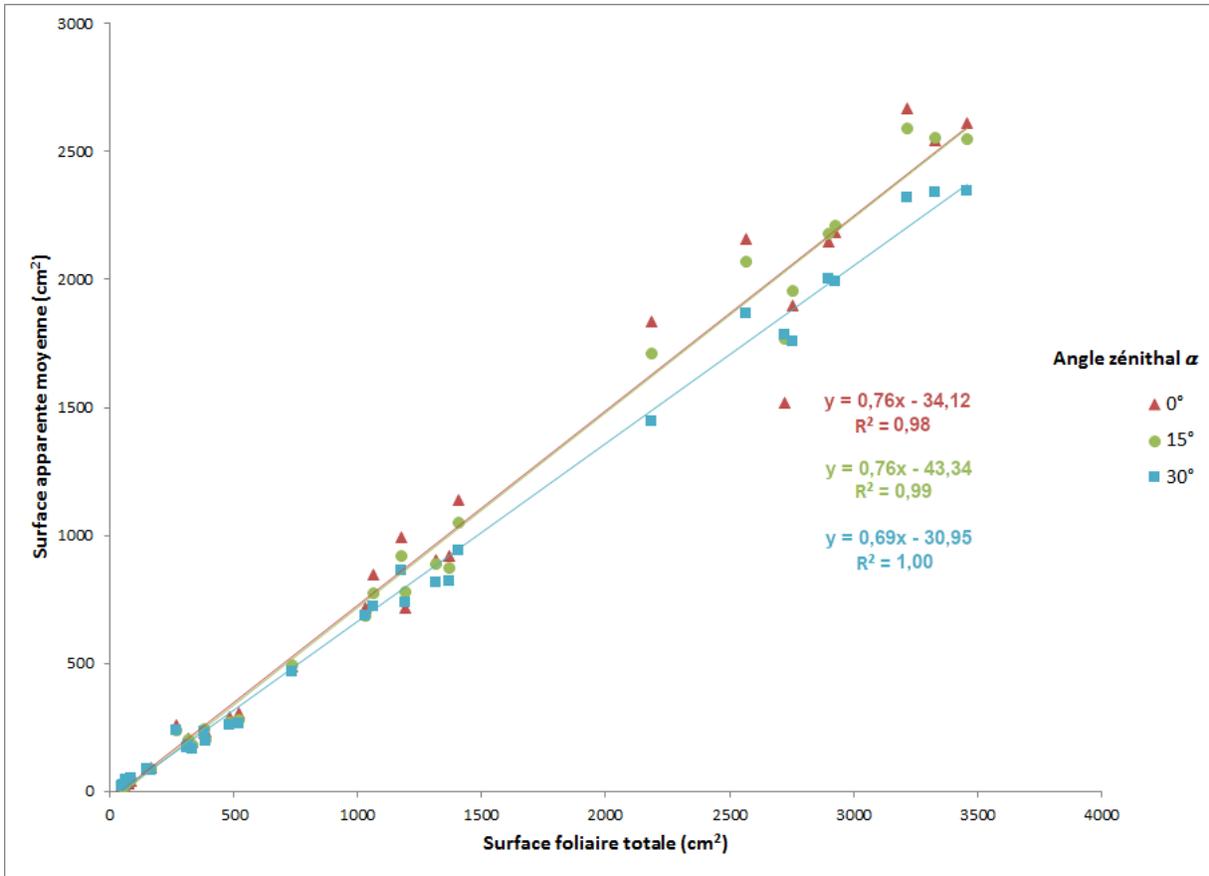


Figure 8.10 – Relation entre surface apparente et surface foliaire totale, en fonction de l'angle zénithal α . Pour les 3 équations de régression, les ordonnées à l'origine ne sont pas significatives ($p > 0,1$) et les intervalles de confiance à 95 % des 3 pentes se chevauchent.

Puisque nous avons déjà vu que la surface foliaire et le poids frais du plant en entier était fortement corrélés, il n'est donc pas surprenant que ce soit également le cas entre la surface apparente et le poids frais (figure 8.11).

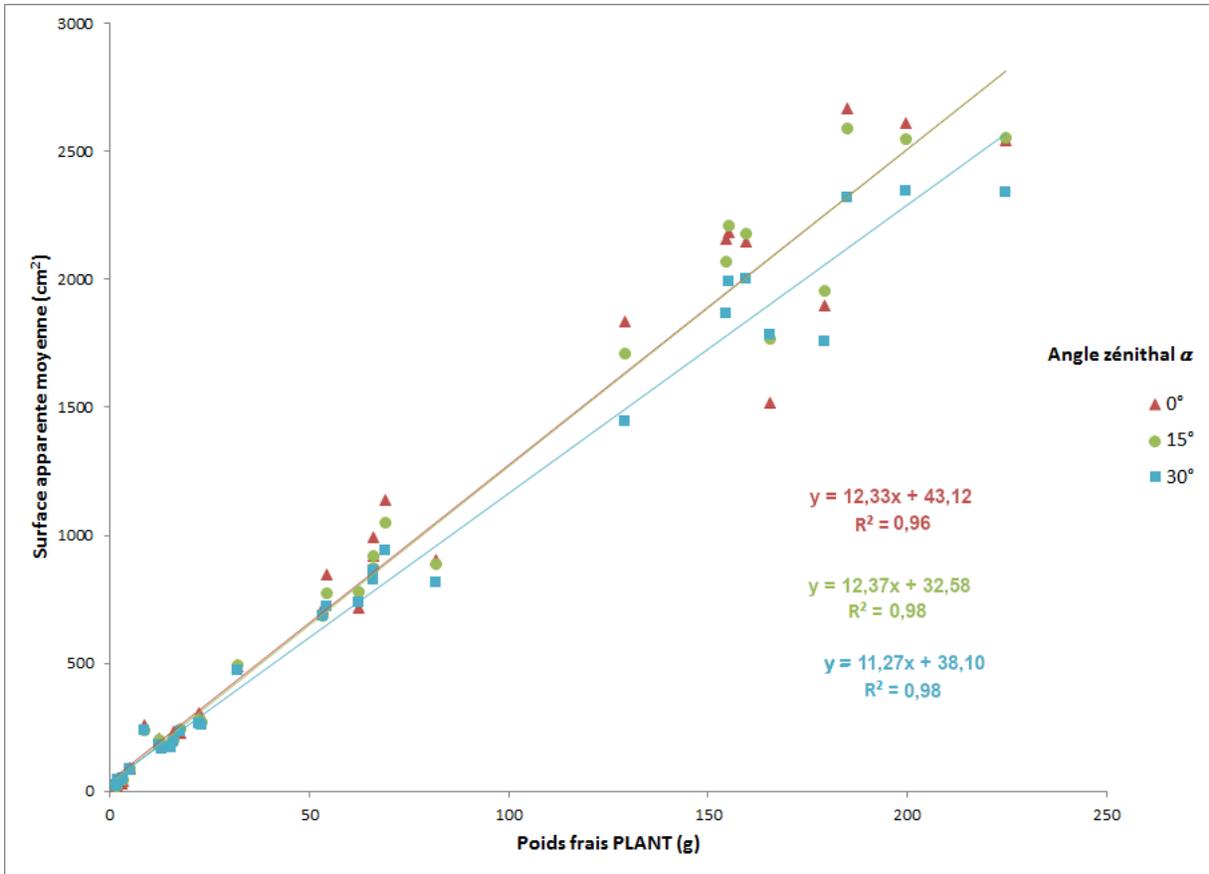


Figure 8.11 – Relation entre surface apparente et poids frais du plant de maïs, en fonction de l'angle zénithal α . Les ordonnées à l'origine ne sont pas significatives ($p > 0,1$). Les intervalles de confiance à 95 % des 3 pentes se chevauchent.

Pour le poids sec du plant et la surface apparente, la régression linéaire donne des R^2 plus faibles, proches de 0,60 pour les 3 angles de visée (figure 8.12). Graphiquement, on peut constater que les plants dont le poids sec dépasse 30 grammes présentent des valeurs aberrantes pour la surface apparente. D'ailleurs, en ne gardant que les individus dont le poids sec est inférieur à 30 g, nous obtenons des R^2 beaucoup plus élevés entre 0,95 et 0,99 (voir figure b.4 en annexe). D'après notre compréhension, cela peut être dû à un séchage au four insuffisant : il peut rester encore de l'humidité, surtout pour les plus grands plants.

En effectuant une régression de puissance, on constate que le R^2 reste élevé (figure 8.13) mais les grands plants continuent à être mal estimés.

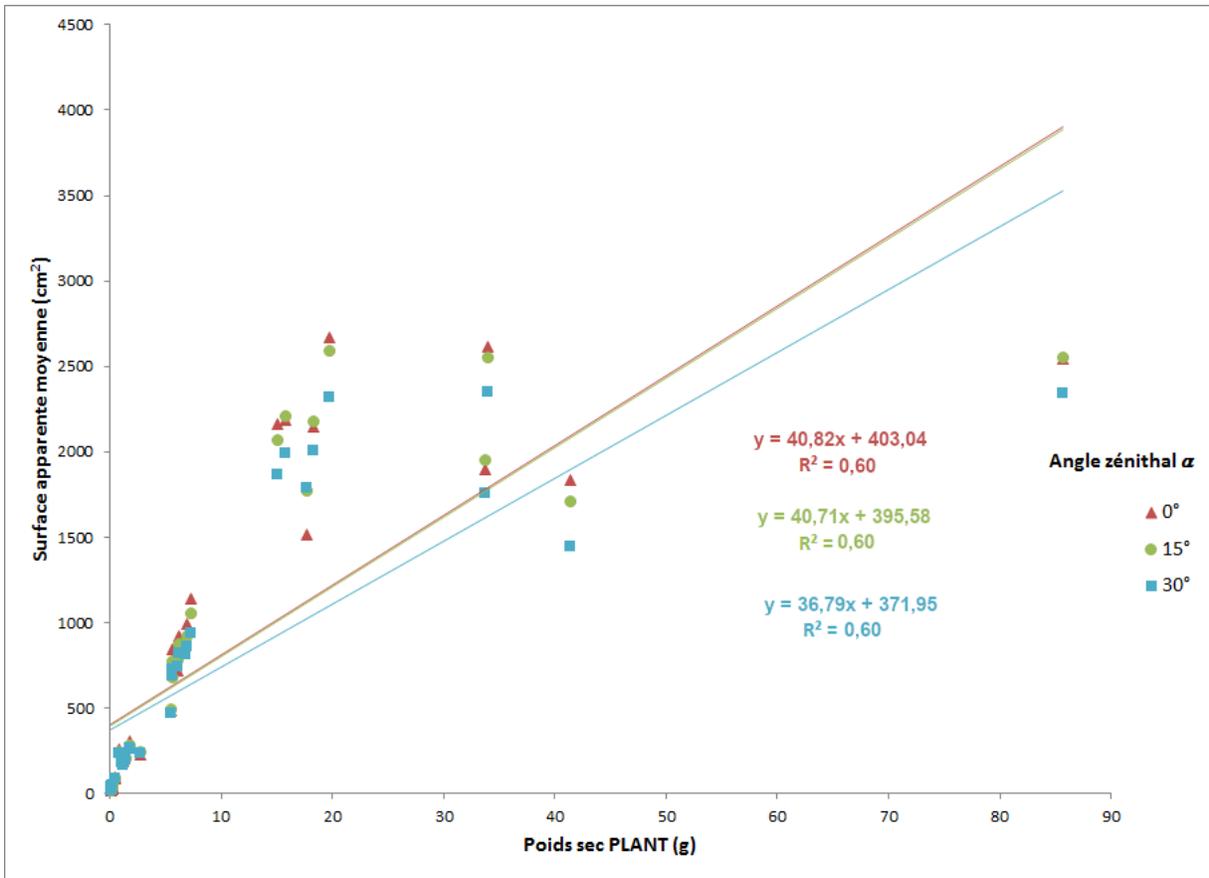


Figure 8.12 – Relation entre surface apparente et poids sec du plant de maïs, en fonction de l'angle zénithal α , régression linéaire (expérience en serre, printemps 2017).

Ge *et al.* (2016) ont comparé la surface projetée (comme décrite à la section 8.3.2, p.100) à la surface foliaire ($R^2 = 0,99$), au poids frais ($R^2 = 0,99$) et au poids sec ($R^2 = 0,95$, régression polynomiale d'ordre 2) du maïs. La surface projetée étant donnée directement en nombre de pixels, il n'était pas possible de comparer avec nos résultats et valider l'effet de l'angle de visée. Cependant, leurs résultats ont également montré une grande corrélation entre la surface projetée et le poids des plants de maïs.

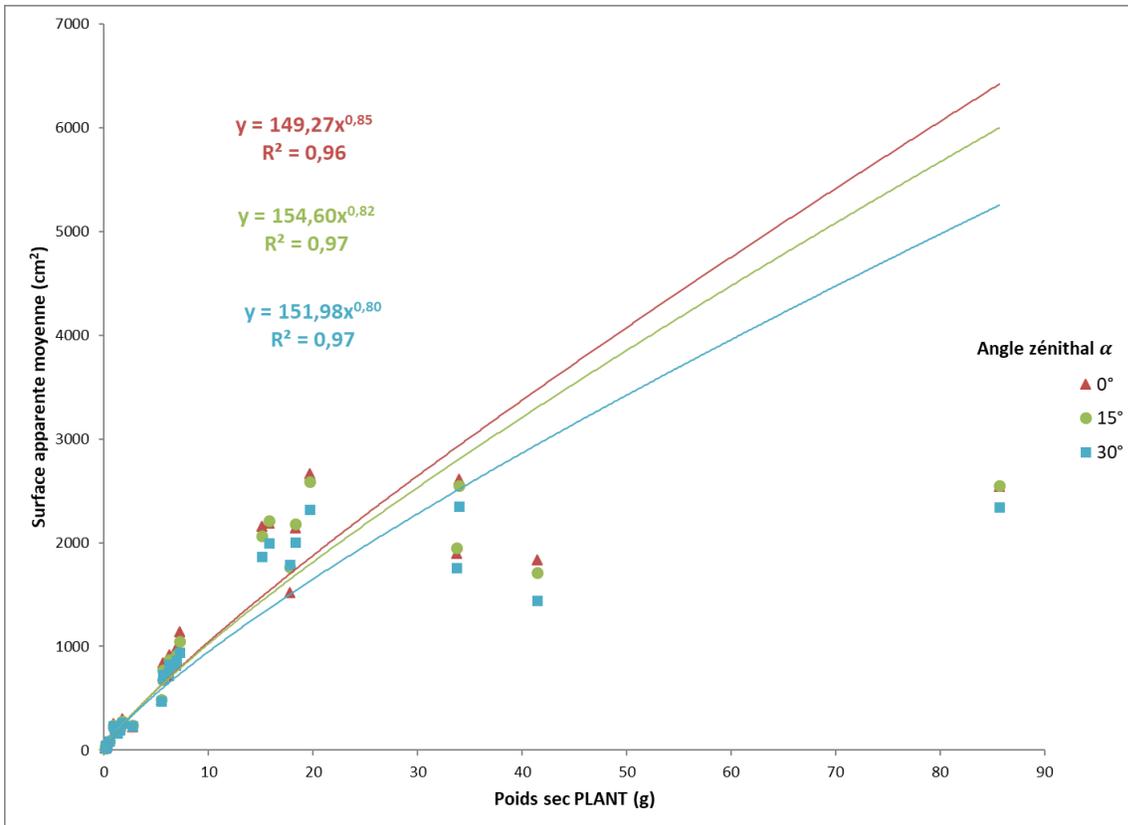


Figure 8.13 – Relation entre surface apparente et poids sec du plant de maïs, en fonction de l’angle zénithal. La relation est linéaire entre les logarithmes des deux variables, avec une ordonnée à l’origine significativement non nulle, et une pente non significativement différente pour les angles zénithaux.

8.4. Conclusion

Les résultats précédents montrent que la plupart des paramètres physiques d’un plant de maïs sont corrélés entre eux. Notamment, il existe une corrélation forte entre la biomasse et la surface foliaire d’une part, et entre la surface foliaire et la surface apparente d’autre part. Il existe également une forte corrélation entre la surface apparente et la biomasse, notamment la biomasse fraîche. De ces résultats, on peut en déduire que :

- 1) le maïs croît de façon assez prévisible : les traits structuraux d’un plant individuel sont fortement corrélés ;
- 2) la vigueur du maïs, exprimée par la biomasse, est mesurable à travers l’information structurale dont la superficie foliaire ;

- 3) la surface apparente mesurée par un capteur de télédétection est un bon indicateur de la surface foliaire et un bon proxy de la biomasse du maïs
- 4) les conditions géométriques d'acquisition de l'image (orientation du plant de maïs et angle de visée de la caméra) ont peu d'impact sur l'estimation de la surface apparente et donc de la biomasse.

Ces résultats ont été obtenus à partir d'une expérience particulière : les plants ont poussé en serre, et l'observation a été faite sur des plantes individuelles. Dans des conditions extérieures d'un champ, où les plants sont plus rapprochés, est-ce que ces résultats s'appliquent encore ? Nous verrons cela dans le chapitre suivant.

Chapitre 9. Extraction de la vigueur zonale à travers la fraction du couvert végétal

9.1. Introduction

L'expérience en serre a montré que la surface apparente était un bon proxy de la biomasse pour une plante individuelle (chapitre 8). Nous allons maintenant transposer cette expérience dans le contexte d'un champ, avec une plateforme dronique pour acquérir les images. L'objectif de cette étude est donc de voir comment la vigueur peut être extraite à partir des images droniques pour effectuer le suivi de la culture dans le temps et dans l'espace, et ce dans les premiers stades de croissance du maïs.

Pour mesurer la surface apparente, il fallait s'assurer qu'il était possible de discriminer le maïs du sol. Des tests avec des procédures classiques de segmentation d'images nous ont permis de constater qu'il était relativement aisé de séparer la végétation du reste sur des images droniques à très haute résolution. De la germination (VE) au stade V3, les plants de maïs sont suffisamment petits, pour qu'ils puissent être discernés individuellement. Cependant, à partir d'un certain stade (autour de V4), les feuilles des plants situés sur un même rang commencent à se recouvrir. Puis, dès V6, les rangs commencent à se refermer : les feuilles sont suffisamment longues pour que les plants sur deux rangs voisins voient leurs feuilles se superposer.

Dès lors, nous pouvons faire deux constats :

- il ne sera pas possible de mesurer la surface apparente de chaque plante, comme nous l'avons fait à l'expérience précédente ;
- dès que les plants commencent à se toucher, la surface apparente mesurée sera forcément sous-estimée.

En nous basant sur ces constats, nous avons privilégié une approche zonale dans la mesure de la surface apparente : plutôt que de chercher à estimer le paramètre pour chaque plante, nous allons mesurer le paramètre par unité de surface au sol. Cette définition correspond à celle de la fraction du couvert végétal (FCV), telle que vue à la section 3.3.4.1. Dans ce chapitre, nous avons testé notre idée de faire intervenir l'indice FCV comme proxy de la biomasse du maïs. La

corrélation de ce paramètre avec la biomasse et par ricochet avec la vigueur nous permettra de développer une méthode simple et efficace pour l'utilisation des images droniques pour effectuer le suivi de la vigueur au cours des premiers stades de croissance.

9.2. Méthodologie

9.2.1. Site à l'étude

L'expérience a été menée en juillet et août 2016 à la ferme expérimentale de L'Acadie, au CRD de St-Jean-sur-Richelieu, AAC (45°17'40,092" N, 73°20'45,0168" O). Un champ de maïs d'environ 0,5 ha (100 m x 50 m) a été choisi pour l'expérience. À la fin du mois de juillet, le maïs de grande culture (*Zea mays* L., cultivar Pioneer P9623, 2850 UTM) a été semé en rangs, avec un intervalle de 75 cm entre chaque rang. Aucun plan de traitement en azote n'a été suivi. Des campagnes de mesure ont été effectuées à un rythme d'une par semaine environ, afin de suivre la croissance du maïs dans le temps.

9.2.2. Données de vérité terrain

Les campagnes de mesure consistaient à recueillir la biomasse du maïs en des points d'échantillonnage choisis au hasard, 12 par campagne. Chaque zone d'échantillonnage était délimitée par un quadrat (1 m x 1,5 m) couvrant deux rangs. Les quadrats étaient peints en rouge, facilitant leur repérage dans les images – ce qui permettait de résoudre le problème de la localisation des zones d'échantillonnage soulevé lors de la première étude en 2015 (Partie II). Après le vol de drone, tous les plants de chaque point d'échantillonnage étaient dénombrés, mesurés, et pesés pour en obtenir la biomasse fraîche et la biomasse sèche. Les campagnes ont eu lieu les 4, 10, 19 et 24 août 2016.

9.2.3. Images droniques et prétraitements

Un drone multicoptère, le Phantom 3 Professional (DJI, Shenzhen, Chine) a été privilégié puisqu'il permet un survol à une altitude plus basse et une meilleure stabilité de la plateforme que le drone eBee utilisé précédemment. La caméra utilisée était alors celle attachée au drone (*built-in*), ses caractéristiques techniques sont fournies dans le tableau 9.1. La faible autonomie de ce type de drone était compensée par la faible superficie des zones survolées.

Tableau 9.1 – Spécifications techniques de la caméra attachée au drone Phantom 3 Professional, pour l'acquisition des images, à L'Acadie, été 2016.

Camera UAV (built-in camera)	
Capteur	1/2,3" CMOS
Largeur du capteur	6,3 mm
Hauteur du capteur	4,73 mm
Taille de l'image	4000 x 3000
Longueur focale	3,6 mm
Taille d'un pixel	1,58 µm
Altitude de la plateforme	10 m AGL (pour le mosaïquage) 3 m et 5 AGL (vol stationnaire)
Résolution spatiale nominale	4,4 mm (orthomosaïque) 1,3 mm et 2,2, mm (vol stationnaire)

Deux modes d'acquisition des images ont été expérimentés. Le premier mode consistait à survoler le champ à une altitude de 10 m au-dessus du sol, selon une trajectoire en grille. Ce mode permettait de créer des mosaïques orthorectifiées, à une résolution de 4,4 mm. Afin d'augmenter le succès de l'assemblage des images, les trajectoires de vol ont été planifiées avec un chevauchement minimal de 70 % (recouvrement latéral et frontal). Ensuite, les images acquises ont été importées dans le logiciel Pix4Dmapper Pro (Pix4D SA, Lausanne, Suisse) et une orthomosaïque a été générée à l'aide de points de contrôle au sol situés dans les champs et positionnés avec un récepteur GNSS RTK (SXBlue III-L, Geneq Inc., Montréal, Québec, Canada). Pour 4 dates de survol, 4 orthomosaïques ont donc été générées.

Un deuxième mode d'acquisition, dit stationnaire, consistait à garder le drone au-dessus d'un même point d'échantillonnage et à prendre des clichés à différentes altitudes : 3 m et 5 m²⁴, générant des images à une résolution de 1,3 mm et 2,2 mm respectivement. Chaque cliché est ensuite traité individuellement pour en extraire le paramètre FCV. Les altitudes fournies par la

²⁴ Lors d'une première mission préparatoire, plusieurs autres altitudes ont été testées : 1 m, 10 m et 15 m. L'acquisition des clichés à plusieurs altitudes étant chronophage, nous avons abandonné les altitudes les plus élevées (perte de temps pour atteindre l'altitude requise et faible résolution spatiale) et l'altitude de 1 m (cadre difficile de l'image associé à la dérive de la plateforme).

téléométrie du drone posaient un problème : le baromètre du drone perdait de sa précision et avait tendance à dériver au fur et à mesure de l'utilisation de l'appareil. Par conséquent, les altitudes affichées étaient fausses. Il était cependant possible d'estimer l'altitude réelle grâce aux dimensions connues du quadrat présent dans l'image.

9.2.4. Extraction d'information

La détection d'un quadrat dans chaque cliché a été automatisée par un script écrit en Python, qui permettait ainsi de délimiter le rectangle formé par le quadrat. L'indice *Excess Green* était utilisé pour servir de base à la segmentation. La méthode d'Otsu permettait ensuite de choisir automatiquement la valeur du seuil qui discriminait le mieux la végétation du sol. Enfin, les pixels classés comme « végétation » étaient dénombrés et leur ratio par rapport au nombre total de pixels contenus dans le quadrat fournissait la FCV, fraction du couvert végétal (figure 9.1).

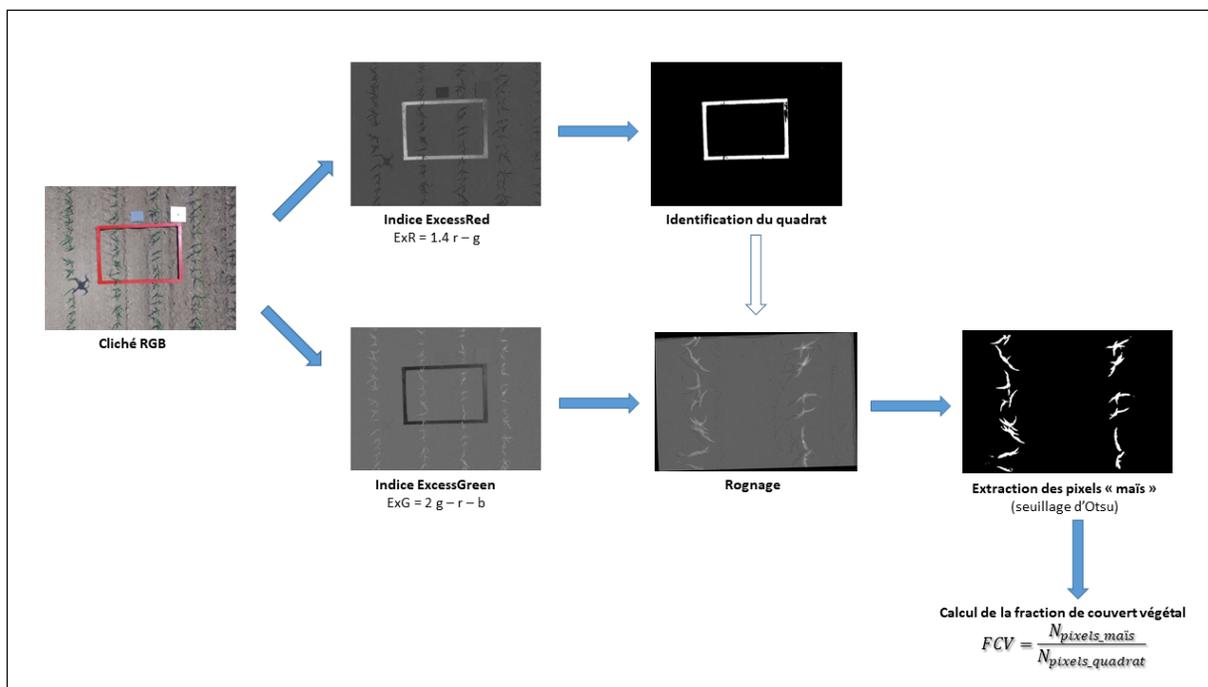


Figure 9.1 – Traitement d'un cliché RGB pour obtenir la fraction du couvert végétal. Les variables r, g, b sont les valeurs normalisées des bandes rouge (R), verte (G) et bleue (B) d'une image RGB, où chaque bande est divisée par la somme de toutes les bandes.

En ce qui concernait les mosaïques, une opération préalable consistait à les découper autour de chaque point d'échantillonnage. Ces portions d'image étaient ensuite traitées de la même manière que les clichés individuels (figure 9.2).

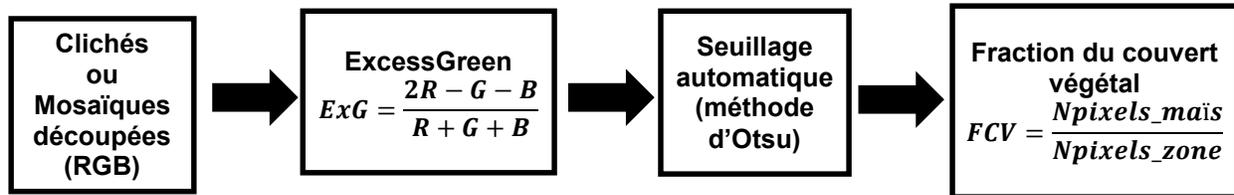


Figure 9.2 – Chaîne de traitements de l’imagerie dronique RGB pour extraire la fraction de couvert végétal.

Il est à remarquer que la FCV s’exprime comme le rapport entre la superficie de la végétation et la superficie de la zone d’échantillonnage. Cette définition n’est valide que pour des images acquises au nadir. Elle perd son sens pour les images obliques, où la perspective 3D dénature l’expression des superficies. En effet, la zone d’échantillonnage est matérialisée par un rectangle (en 2D) de dimensions constantes, déterminées à l’avance : par exemple, la FCV est calculée pour chaque zone d’échantillonnage de 1,5 m x 1 m, soit 1,5 m². Seule est prise en compte la végétation incluse dans les limites de ce rectangle, telle que vue directement au-dessus de la canopée (au nadir) : la surface apparente de la végétation. La valeur de FCV plafonne ainsi à 100 %, lorsque la totalité de la zone d’échantillonnage est recouverte par la végétation.

Dans une image oblique, la surface de la végétation prise en considération n’est plus limitée par la zone d’échantillonnage. D’une part, la hauteur de la canopée (en 3D) n’est nullement restreinte par les dimensions du rectangle d’échantillonnage (en 2D). D’autre part, dans la direction de l’axe de visée, les limites de la zone d’échantillonnage ne sont pas discernables, tout comme la délimitation de la végétation incluse dedans. Par conséquent, il est possible que, pour les grosses plantes, la surface de la végétation soit supérieure à la superficie de la zone d’échantillonnage, engendrant une valeur de FCV supérieure à 100 %.

À noter également que si le calcul de la FCV fait théoriquement intervenir des valeurs de superficie, en pratique, son expression peut se simplifier en un rapport entre nombre de pixels « végétation » et nombre de pixels circonscrits dans la zone d’échantillonnage. En effet, la surface de la végétation S_v et la superficie de la zone d’échantillonnage S_z peuvent se calculer respectivement par :

$$S_v = N_v \cdot \rho^2 \quad (9.1)$$

$$S_z = N_z \cdot \rho^2 \quad (9.2)$$

où N_v et N_z sont, respectivement, le nombre de pixels « végétation » et le nombre de pixels dans la zone d'échantillonnage, et ρ la résolution de l'image. L'expression de la FCV :

$$FCV = \frac{S_v}{S_z} = \frac{N_v \cdot \rho^2}{N_z \cdot \rho^2} \quad (9.3)$$

se simplifie ainsi, par élimination du terme ρ^2 au numérateur et au dénominateur, en :

$$FCV = \frac{N_v}{N_z} \quad (9.4)$$

9.3. Résultats et discussion

9.3.1. Comparaison entre les deux modes d'acquisition

D'un point de vue coût et efforts, il convient de dire que le mode d'acquisition d'images pour réaliser une mosaïque nécessitait beaucoup plus de temps lors de l'acquisition et lors du traitement des données. De plus, le résultat final n'était pas forcément satisfaisant : certaines mosaïques comportaient des erreurs (trous dans la mosaïque, mauvais raccordements, artéfacts, flous, etc.). Ces problèmes provenaient d'une part du nombre insuffisant d'images acquises : l'objectif visé de 70 % de taux recouvrement n'était pas toujours atteint dû au fait que la carte mémoire de la caméra n'était pas capable d'enregistrer les images suffisamment vite, et la légèreté du drone le rendait plus vulnérable face aux bourrasques de vent. D'autre part, l'architecture de la canopée faisait en sorte que le logiciel Pix4Dmapper Pro ne détectait pas suffisamment de points caractéristiques dans les images pour pouvoir les calibrer géométriquement. Ces deux aspects mis ensemble aboutissent parfois à un mosaïquage imprécis voire erroné.

En comparant la FCV extraite à partir des deux types d'images (mosaïques et clichés individuels) avec la biomasse fraîche, nous constatons que la relation entre ces paramètres est de type polynômial d'ordre 2 (figure 9.3) dont les équations ne sont pas significativement différentes. Le R^2 obtenu pour la régression entre la FCV et la biomasse semble légèrement meilleur dans le cas de la FCV calculée à partir des clichés ($R^2 = 0,96$) que celle calculée à partir des orthomosaïques ($R^2 = 0,87$). Il apparaît donc que le mosaïquage a une influence légèrement

négative sur la qualité des images et donc sur l'estimation de la FCV. Nous pouvons également constater que la FCV sature à partir d'une biomasse fraîche équivalant à 12 t ha⁻¹.

Comme pour l'expérience en serre avec la surface apparente, la FCV est un bon indicateur proxy pour la biomasse. La seule différence est que la relation n'est plus linéaire mais polynomiale d'ordre 2, avec une tendance de la FCV à plafonner pour les valeurs élevées de la biomasse ; ce qui traduirait qu'au fur et à mesure que les feuilles des plantes voisines se touchent, la FCV sous-estime de plus en plus la biomasse.

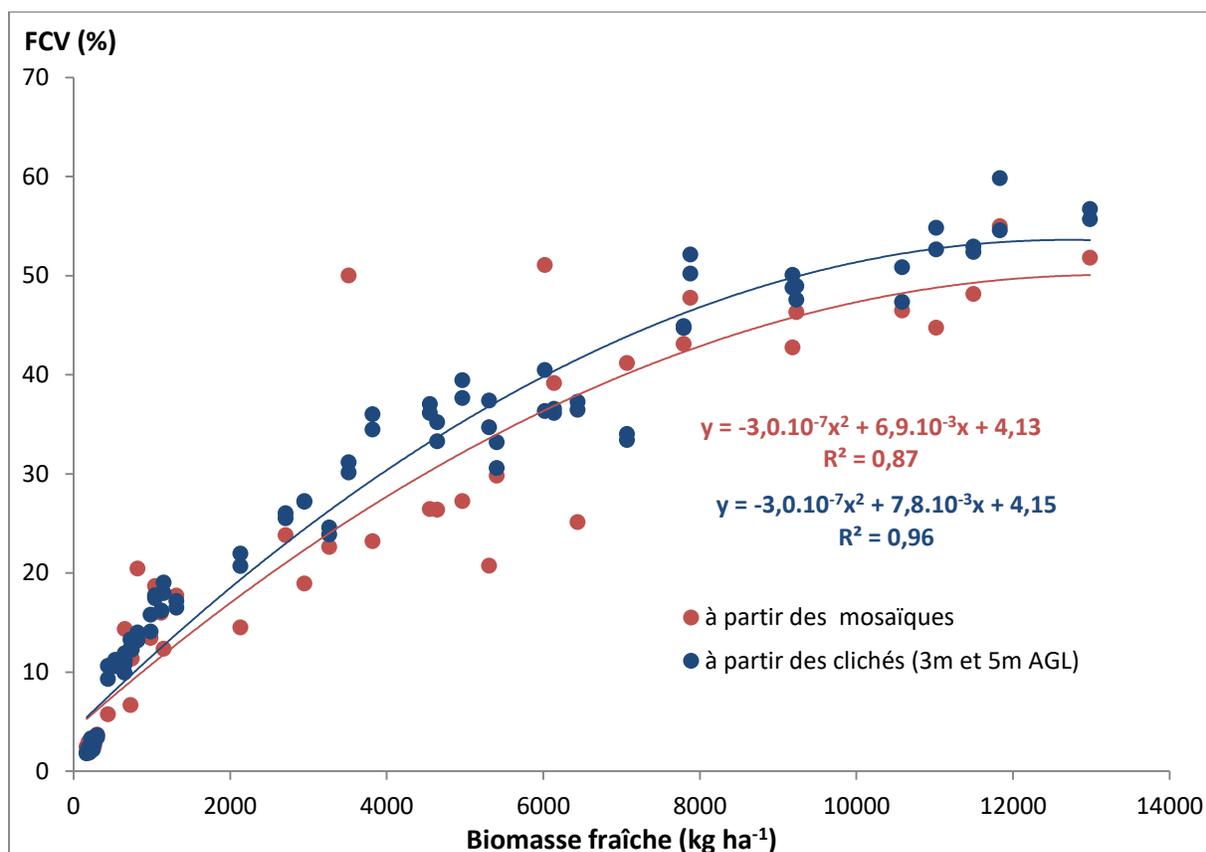


Figure 9.3 – Relation entre la fraction de couvert végétal extraite des images droniques et la biomasse fraîche : en bleu, la FCV extraite des clichés pris à 3m et 5m AGL (N=96) ; en rouge, la FCV extraite de l'orthomosaïque à 10m AGL (N=48). Tous les coefficients sont significatifs. Les intervalles de confiance à 95 % pour chacun des coefficients se chevauchent.

Il est à remarquer que les deux altitudes utilisées ne créent pas une différence notable dans l'estimation de la FCV. La régression linéaire entre la FCV obtenue à 3 m et celle obtenue à 5 m donne une droite de pente égale à 0,95 avec un R²=1,00.

9.3.2. Mesurer la vigueur dans l'espace

Bien que les mosaïques engendrent des défis dans leur traitement, elles ont l'avantage de représenter la variabilité spatiale de façon continue. Pour avoir une estimation de la vigueur dans le champ, nous avons converti la mosaïque RGB en carte de FCV. Pour cela, nous faisons le constat que :

- la FCV peut être calculée pour n'importe quelle taille de zone d'échantillonnage,
- pour rendre compte de la variabilité de la vigueur le long des rangs, la taille caractéristique de la zone pour le calcul de la FCV doit être inférieure à l'entre-rang (75 cm). De cette manière, le calcul de la FCV ne se portera que sur un seul rang à la fois.

Par conséquent, nous avons utilisé la méthode de filtrage spatial, avec un noyau de convolution de 60 cm. En chaque point de la mosaïque, nous délimitons une fenêtre de 60 cm x 60 cm centrée en ce point, puis nous effectuons la procédure décrite à la section 9.2.4 pour estimer la FCV. La carte du 4 août, ainsi obtenue (figure 9.4), permet de visualiser plus facilement la vigueur de la culture dans le champ, et notamment le long des rangs.

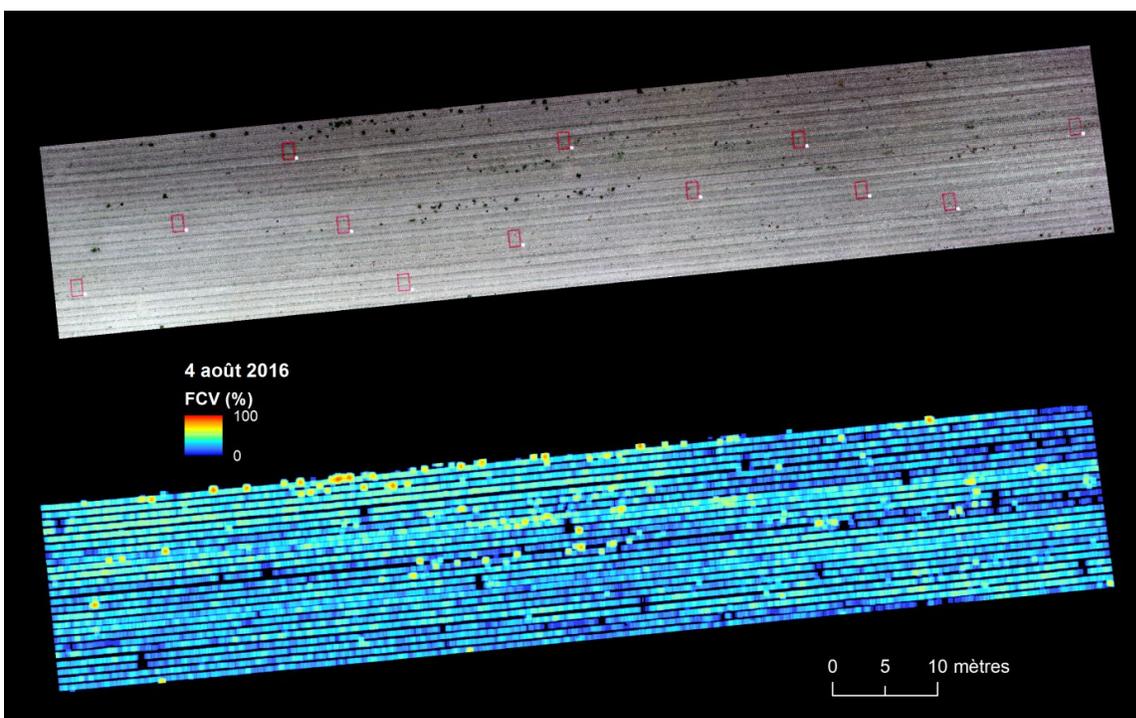


Figure 9.4 – Mosaïque RGB (en haut) convertie en carte de FCV, du 4 août 2016 (stade V3).

Les zones qui ont été échantillonnées lors de la campagne précédente présentent un sol nu, sans végétation, et apparaissent sous forme de rectangles noirs dans la carte (FCV = 0 %). Les taches jaunes et rouges situées entre les rangs révèlent la présence de mauvaises herbes. Les plants de maïs étant au stade V3, leurs feuilles sont encore petites et la FCV reste donc faible le long des rangs.

Vingt jours plus tard, le 24 août, le maïs est au stade V7. Les feuilles sont beaucoup plus grandes et la canopée commence à se refermer. Nous pouvons constater le phénomène sur la carte de FCV de la figure 9.5 : la FCV le long des rangs devient plus élevée. On constate l'apparition de nombreuses zones bleu foncé correspondant aux endroits échantillonnés, ainsi que la disparition des zones rouges correspondant aux mauvaises herbes suite au désherbage. L'hétérogénéité spatiale de la vigueur dans le champ peut également être remarquée : la vigueur est plus faible dans le milieu du champ et dans la partie nord-est.

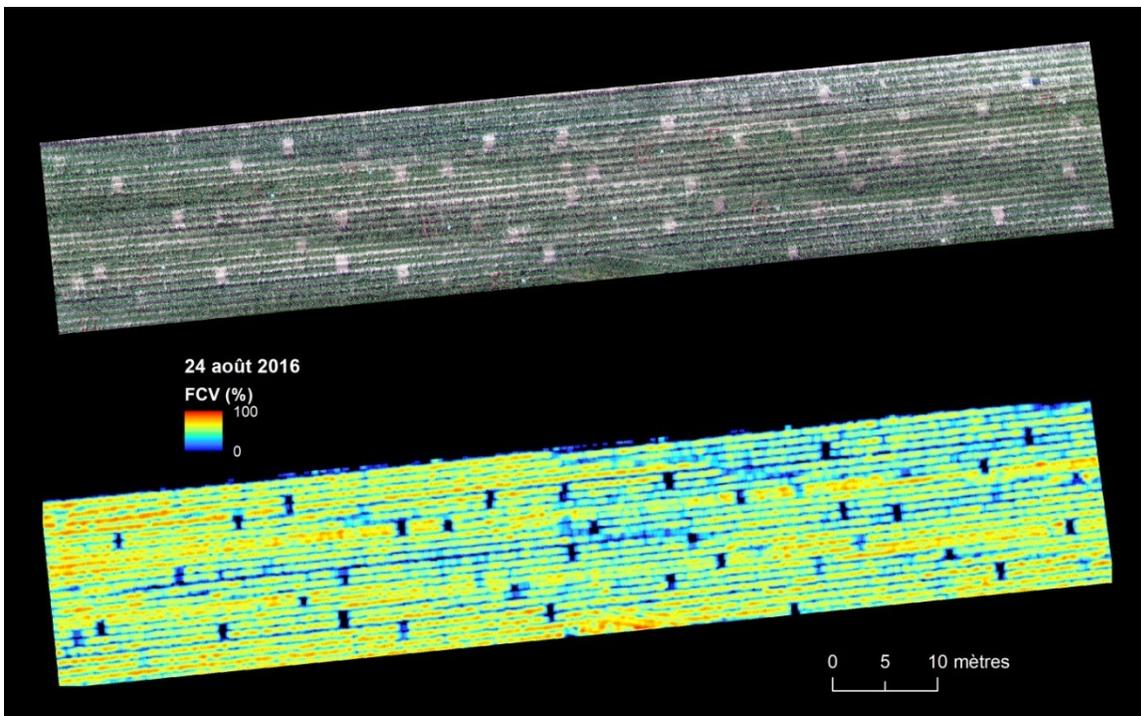


Figure 9.5 – Mosaïque RGB (en haut) convertie en carte de FCV, du 24 août 2016 (stades V6–V7).

La carte de FCV pour les quatre dates de campagne est présentée à la figure 9.6. On y constate l'augmentation de la vigueur à travers une FCV de plus en plus élevée au fur et à mesure que la saison avance. La carte du 19 août 2016 fait ressortir des erreurs de mosaïquage au centre de

l'image (franges noires) et vers la droite de l'image (saturation de la FCV due à une mauvaise superposition des portions de la mosaïque). Ces erreurs apparaissent lorsqu'il n'y a pas assez d'images correctement calibrées géométriquement à cet endroit : le logiciel de photogrammétrie n'a pas pu appairer suffisamment de points caractéristiques (images acquises pas assez nombreuses, mauvaise qualité des images, scène présentant peu de coins détectables).

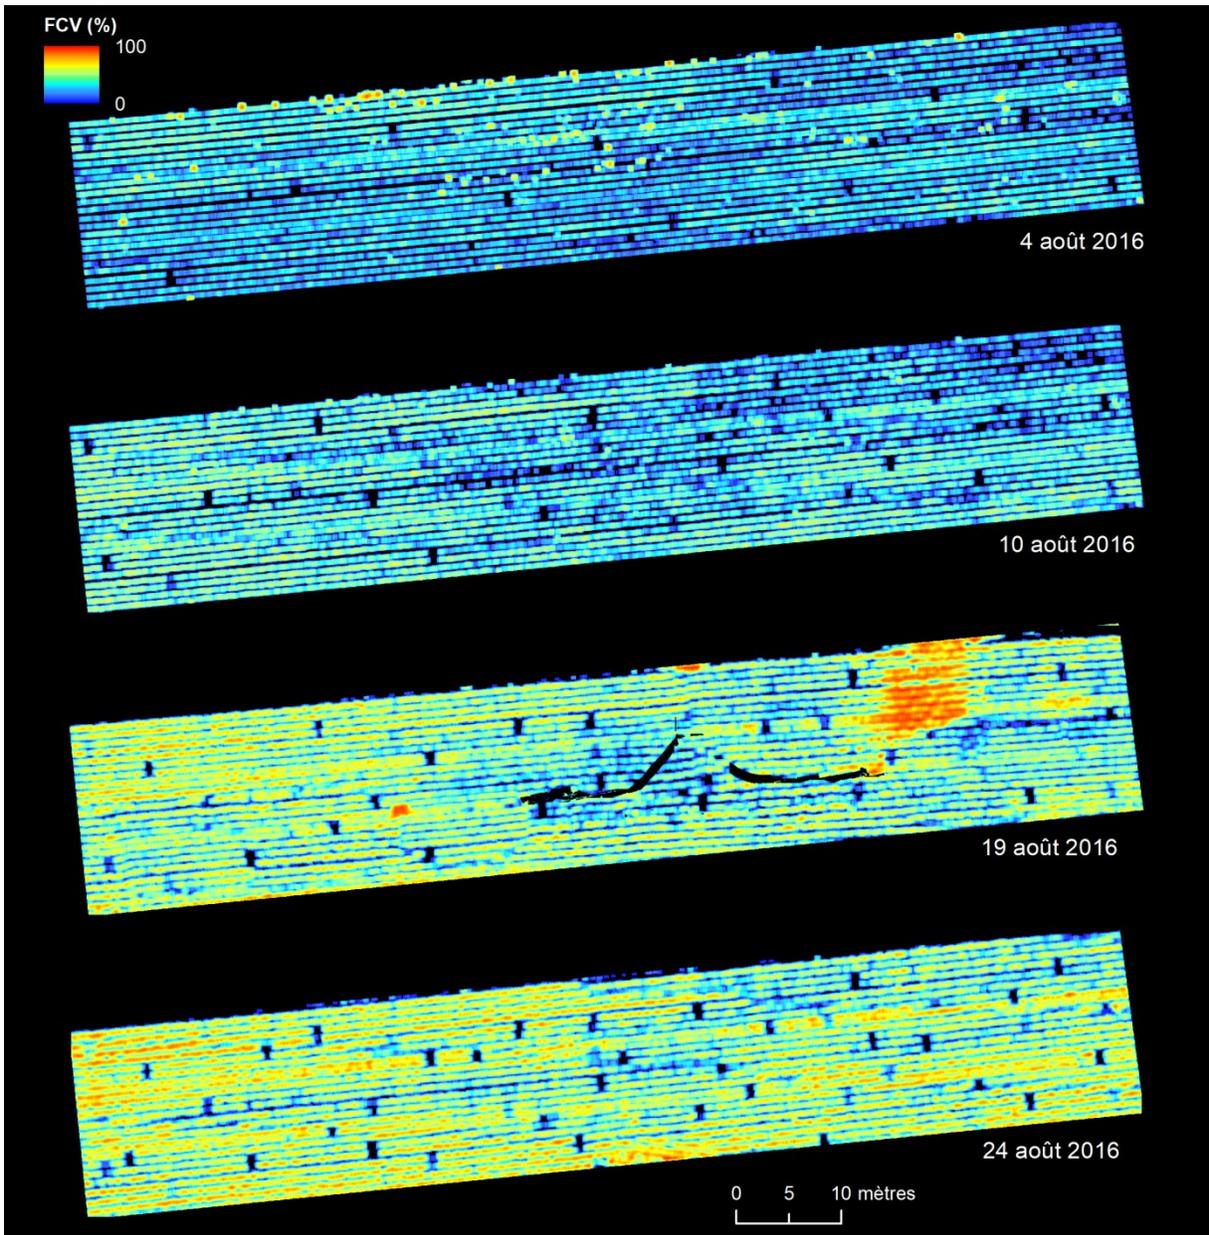


Figure 9.6 – Évolution de la vigueur, exprimée à travers la FCV, dans l'espace et le temps (expérience à L'Acadie, été 2016). Les stades atteints par le maïs pour ces dates sont : V3 (4 août), V4 (10 août), V5–V6 (19 août) et V6–V7 (24 août). On constate la mauvaise qualité du mosaïquage pour la date du 19 août 2016.

9.3.3. Mesurer la vigueur dans l'espace et dans le temps

Le choix de la taille de la fenêtre de filtrage nous a assuré que la vigueur estimée à travers la FCV, n'était pas influencée par les rangs voisins. Ces cartes de FCV produites mettent ainsi en avant la vigueur le long de chaque rang individuellement. En traçant la FCV le long d'un rang donné, on peut donc suivre son évolution dans le temps (figure 9.7).

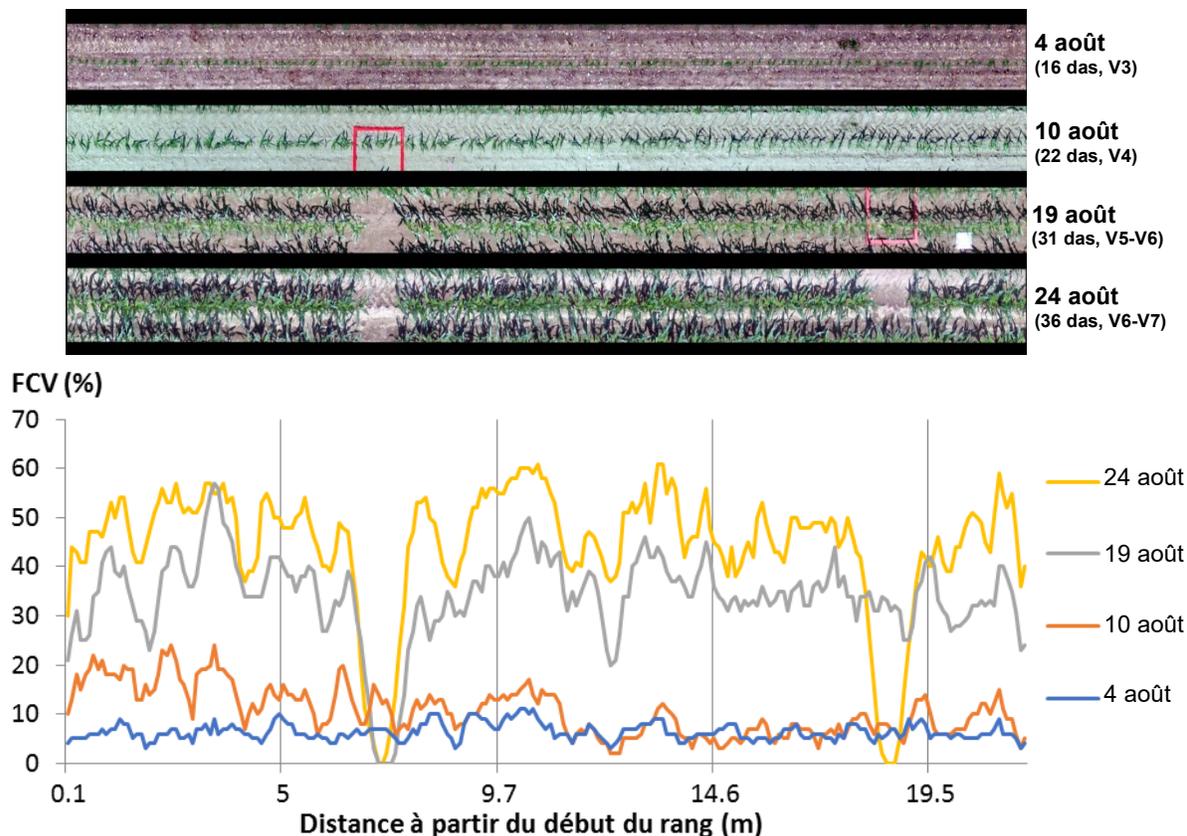


Figure 9.7 – Évolution de la fraction de couvert végétal (FCV) le long du rang 6, ferme expérimentale de L'Acadie, été 2016 ; das : *days after sowing* (nombre de jours après le semis).

Dans la figure 9.7, la croissance de la végétation au fil des semaines se remarque bien avec la FCV qui augmente dans son ensemble (déplacement de la courbe de la FCV vers le haut). Le quadrat rouge présent en date du 10 août indique que la zone sera échantillonnée à la suite de la prise d'image, ce que montrent ensuite les deux courbes du 19 et 24 août avec un creux à l'abscisse 7 m (idem pour le quadrat présent le 19 août à l'abscisse 19 m).

9.1. Discussion

Notre expérience a montré la capacité d'un proxy tel que la surface apparente, mesurée à travers la FCV, à estimer correctement la biomasse du maïs. Cependant, nous n'avons pu comparer ces résultats avec des indices de végétation, faute d'acquisitions multispectrales lors de l'étude. Notre démarche peut s'apparenter à celle empruntée par Tilly *et al.* (2015) dans leur expérience sur des parcelles d'orge. Dans leur cas, le paramètre primaire était également la biomasse. Cette dernière était estimée à partir de la hauteur de canopée PH (trait physique utilisé comme paramètre secondaire), mesuré avec un lidar terrestre. Le recours à la hauteur de canopée comme proxy se comprend dans le cas de l'orge qui, contrairement au maïs, ne se caractérise pas par ses grandes feuilles. Les auteurs ont pu calculer six indices de végétation, dont le NDVI, grâce à des mesures de réflectance obtenues au spectroradiomètre ASD Fieldspec3. Cela a permis de montrer la bonne performance du paramètre PH à représenter la biomasse, tandis que les performances des indices de végétation étaient mitigées (Tableau 9.2).

Tableau 9.2 – Coefficients de détermination R^2 obtenus par Tilly *et al.* (2015), selon le type de régression, entre la biomasse et la hauteur de la canopée (PH) d'un part ; et entre la biomasse et les indices de végétation d'autre part (adapté de Tilly *et al.* (2015)).

	Régression	PH	NDVI	Autres indices de végétation
Biomasse sèche	linéaire	0,76	0,34	0,26–0,70
	exponentielle	0,84	0,61	0,48–0,87
Biomasse fraîche	linéaire	0,60	0,42	0,37–0,62
	exponentielle	0,68	0,65	0,55–0,77

Dans une étude ultérieure, toujours avec l'orge, Tilly et Bareth (2019) ont encore comparé la hauteur de la canopée PH avec les indices de végétation (VI), cette fois-ci pour estimer la teneur en azote N. Le coefficient de détermination R^2 trouvé pour les relations entre N et PH variait entre 0,40 et 0,81 selon que N était mesuré au niveau de la tige, de l'épi ou de la feuille ; tandis que les relations entre N et VI produisaient des R^2 entre 0,18 et 0,68. Ils ont ainsi conclu à la meilleure performance des données structurales (en l'occurrence la hauteur de la canopée) par

rapport aux paramètres spectraux (les indices de végétation) à estimer un paramètre primaire tel que la teneur en azote.

La hauteur de la canopée aurait pu également être utilisée dans notre cas : nous avons vu au chapitre 8 qu'il y avait une bonne corrélation entre la hauteur de la plante et sa biomasse. Nous jugeons, cependant, que la mesure de la hauteur nécessite des techniques plus complexes (SfM, lidar) et plus imprécises que la mesure de la surface apparente.

9.2. Conclusion

La FCV calculée à partir d'une caméra RGB présente l'avantage d'être facile à obtenir (traitement simple, pas de réflectance à calculer) et donne une bonne estimation de la vigueur du maïs dans le temps et dans l'espace. Par ailleurs, cette méthode permet désormais d'estimer la vigueur de façon continue à l'échelle d'un rang : il est ainsi théoriquement possible de faire de la gestion par zone et par rangs (cf. figure 3.3).

La FCV peut être extraite rapidement d'un cliché ou d'une mosaïque. Cependant, nous avons constaté que les mosaïques, non seulement imposaient un effort important dans l'acquisition des images, mais engendraient également des artéfacts dans l'image à cause de la dégradation de la qualité radiométrique. La plateforme en elle-même – le drone – présente également des instabilités et génère des imprécisions dans l'acquisition des images.

Dans ce chapitre, la FCV exploitait uniquement l'imagerie acquise au nadir et faisait ressortir la vigueur par superficie ou par rang. L'objectif du chapitre suivant sera de faire le lien entre la vigueur et la plante individuelle, et de déterminer si l'imagerie oblique est également porteuse d'information pour permettre de mieux estimer la vigueur de la végétation.

Chapitre 10. Mesure de la vigueur linéaire à travers l'imagerie nadir et oblique

10.1. Introduction

Tout comme la plupart des études avec l'imagerie dronique, l'expérience précédente se basait sur des images acquises au nadir (avec une visée perpendiculaire au sol). Puisque le drone permet d'acquérir des images selon une visée oblique, nous nous posons alors la question de savoir quel impact aurait l'angle de visée dans l'estimation de la vigueur du maïs dans le contexte d'un champ. Nous avons déjà vu que pour une plante seule, l'angle de visée n'avait pas d'impact sur l'estimation de la biomasse.

Dans ce chapitre, nous nous intéressons encore à la surface apparente de la plante et à la comparaison avec la biomasse mesurée *in situ*. Nous chercherons à améliorer l'échelle d'observation en essayant de mesurer la vigueur de façon linéaire et non plus de façon surfacique comme à l'expérience précédente. Cette échelle d'observation est cohérente avec une culture en rangs comme le maïs. Elle permettra également la même échelle d'intervention, c'est-à-dire selon les rangs.

Dans nos tests préliminaires, nous avons constaté que l'acquisition et le traitement des images obliques acquises par drone présentaient certaines difficultés opérationnelles. Tout d'abord, le logiciel Pix4DMapper Pro étaient incapable de produire une mosaïque avec des images obliques. Le traitement échouait à la première étape de calibration géométrique : la visée inhabituelle et la structure complexe de la canopée faisait que peu de points caractéristiques étaient détectés et appariés. De plus, lorsque le drone était opéré en mode manuel afin d'acquérir des images ponctuellement, il était difficile de le stabiliser à la bonne altitude et à la bonne distance des cibles visées. Les clichés obtenus étaient alors mal cadrés, avec une distance ou un angle difficilement contrôlables.

C'est pourquoi nous avons décidé d'avoir recours, dans cette étude, à une plateforme sur tyrolienne afin de mieux contrôler les paramètres d'acquisition des images. Comme la visée oblique permet de « voir » sous la canopée, nous estimons qu'elle fournira des détails sur les feuilles cachées lors d'une visée au nadir. Partant, l'estimation de la biomasse serait beaucoup

plus juste. Dans cette expérience, la culture a été étudiée selon plusieurs angles de visée, dans des conditions de croissance en champs.

10.2. Méthodologie

10.2.1. Terrain à l'étude

L'expérience a été menée en juillet et août 2017 à la ferme expérimentale de L'Acadie, au Centre de recherche et de développement de St-Jean-sur-Richelieu, Agriculture et Agroalimentaire Canada (45°17'40,092'' N, 73°20'45,0168'' O). Un champ de maïs de 0,5 ha (100 m x 50 m) a été choisi pour l'expérience. Le maïs de grande culture (*Zea mays* L., cultivar Pioneer P9623, 2850 UTM) a été planté en bandes de quatre rangs, chaque rang étant distant de 0,75 m et chaque bande espacée de 3 m. Au total, 15 bandes ont été utilisées, avec des dates de semis différentes, de sorte qu'une variété de stades – entre V2 et V8 – soit présente lors de chaque campagne d'acquisition des données.

10.2.2. Mesure de biomasse

Au cours de l'expérience, une campagne hebdomadaire de vérification au sol a été menée pour recueillir la biomasse et d'autres paramètres biophysiques du maïs. Chaque point d'échantillonnage a été choisi au hasard et consistait en une zone couvrant deux rangs de dix plants de maïs consécutifs chacune (ci-après zone d'échantillonnage). Après l'acquisition de l'image, chaque plant de maïs a été mesuré individuellement : son poids frais et son poids sec ont été déterminés à l'aide d'une balance de haute précision et utilisés comme vérité de terrain pour établir une corrélation avec les informations extraites des images de télédétection à basse altitude.

10.2.3. Plateformes d'acquisition et prétraitement des images

Deux plateformes ont été utilisées pour cette expérience : un drone et une plateforme sur tyrolienne, chacune collectant différents types d'images et nécessitant différents prétraitements.

10.2.3.1. Plateforme dronique

Tout d’abord, un drone commercial, le Phantom 3 Professional (DJI, Shenzhen, Chine), doté d’une caméra intégrée (ci-après caméra UAV, voir les caractéristiques techniques au tableau 10.1), a été utilisé pour acquérir des images à très haute résolution spatiale, en mode quadrillage. Le drone a volé à une altitude de 10 m au-dessus du sol, ce qui a produit une résolution de 4,4 mm pour les images acquises. Afin d’augmenter le succès de mosaïquage des images, les trajectoires de vol ont été planifiées avec un chevauchement minimal de 70 % (recouvrement latéral et frontal). Pour chaque date d’acquisition, les images brutes ont été importées dans le logiciel Pix4Dmapper Pro (Pix4D SA, Lausanne, Suisse) et une orthomosaïque a été générée à l’aide de GCP situés dans les champs et positionnés avec un récepteur GNSS RTK (SXBlue III-L, Geneq Inc., Montréal, Québec, Canada).

10.2.3.2. Tyrolienne

Un mode stationnaire a également été prévu où chaque zone échantillonnée serait photographiée avec le drone en vol stationnaire au-dessus. Cependant, pour des raisons de stabilité et de facilité de manipulation (suite au retour d’expérience de l’été précédent), une plateforme basse altitude a été spécialement conçue pour porter une caméra RGB standard (Canon SX230 HS, Canon Inc., Tokyo, Japon – ci-après caméra Canon) le long d’un câble situé à 2,90 m de hauteur (figure 10.1). La caméra était télécommandée et pouvait prendre des images (ci-après clichés, pour éviter la confusion avec les mosaïques) avec des angles de visée de 0° (clichés au nadir), 30° et 45° par rapport à la verticale (clichés obliques). Les distorsions géométriques dues à la lentille de la caméra ont été corrigées grossièrement par le logiciel interne de la caméra et aucun autre prétraitement n’a été effectué.



Figure 10.1 – Caméra RGB accrochée à une tyrolienne (caméra Canon).

Les caractéristiques techniques des deux caméras sont présentées au tableau 10.1. Les deux caméras avaient le même type de capteur, mais la distance focale de la caméra UAV était plus

courte (3,6 mm vs 5 mm), ce qui signifie qu'une image de la caméra Canon présentait une résolution plus fine, pour une même distance à la cible. La résolution spatiale dite « nominale » a été calculée pour le pixel au centre de l'image, situé sur le plan orthogonal à l'axe optique de la caméra et contenant les pieds des plants de maïs, comme pour l'expérience en serre (figure 8.6). La distance entre la caméra et la cible devait être ajustée en fonction de l'angle de visée α , puisque la hauteur de la plateforme était constante.

Tableau 10.1 – Spécifications techniques des caméras utilisées pour l'acquisition des images, à L'Acadie, été 2017.

	Camera UAV (built-in camera)	Camera Canon SX230 HS
Capteur	1/2,3" CMOS	1/2,3" CMOS
Largeur du capteur	6,3 mm	6,16 mm
Hauteur du capteur	4,73 mm	4,62 mm
Taille de l'image	4000 x 3000	4000 x 3000
Longueur focale	3,6 mm	5 mm
Taille d'un pixel	1,58 μm	1,54 μm
Altitude de la plateforme	10 m AGL	2,9 m AGL
Résolution spatiale nominale	4,4 mm (orthomosaïque)	0,89mm (angle de visée = 0°) 1,03mm (angle de visée = 30°) 1,26mm (angle de visée = 45°)

10.2.4. Traitement des images

Afin de comparer les deux plateformes et leurs résultats avec la vérité terrain, les zones d'échantillonnage devaient être repérées et délimitées manuellement dans les images (mosaïques et clichés). Cette tâche a été effectuée à l'aide d'une interface utilisateur graphique (GUI) personnalisée, développée dans le langage de programmation Python à l'aide du kit d'outils graphique Tkinter²⁵. Les images ont ensuite été segmentées afin de distinguer la

²⁵ <https://wiki.python.org/moin/TkInter>

végétation et l'arrière-plan. Enfin, la superficie apparente des plantes a été calculée et corrélée aux mesures *in situ* de la biomasse.

10.2.4.1. Délimitation des zones d'échantillonnage

Pour la caméra UAV, les orthomosaiques générées à partir d'images droniques ont d'abord été découpées en imagerie d'environ 800 x 800 pixels (environ 3,5 m x 3,5 m), chacune centrée sur une zone d'échantillonnage. Dans chaque imagerie, les 2 rangs échantillonnés ont été localisés²⁶. Puis chaque rang a été délimité, en traçant manuellement un rectangle autour des 10 plants y appartenant ; le rectangle étant orienté dans la direction du rang (figure 10.2a) – ci-après quadrat.

²⁶ Chaque zone d'échantillonnage est repérée par une plaque d'identification numérotée, qui a également servi de point de contrôle (GCP). Puis, les premier et dernier plants de chaque rang sont repérés grâce à un support de golf posé à proximité, légèrement décalé pour être visible dans les photos. Par ailleurs, la distance entre chaque plant a été mesurée pour mieux aider à identifier chaque plant échantillonné.

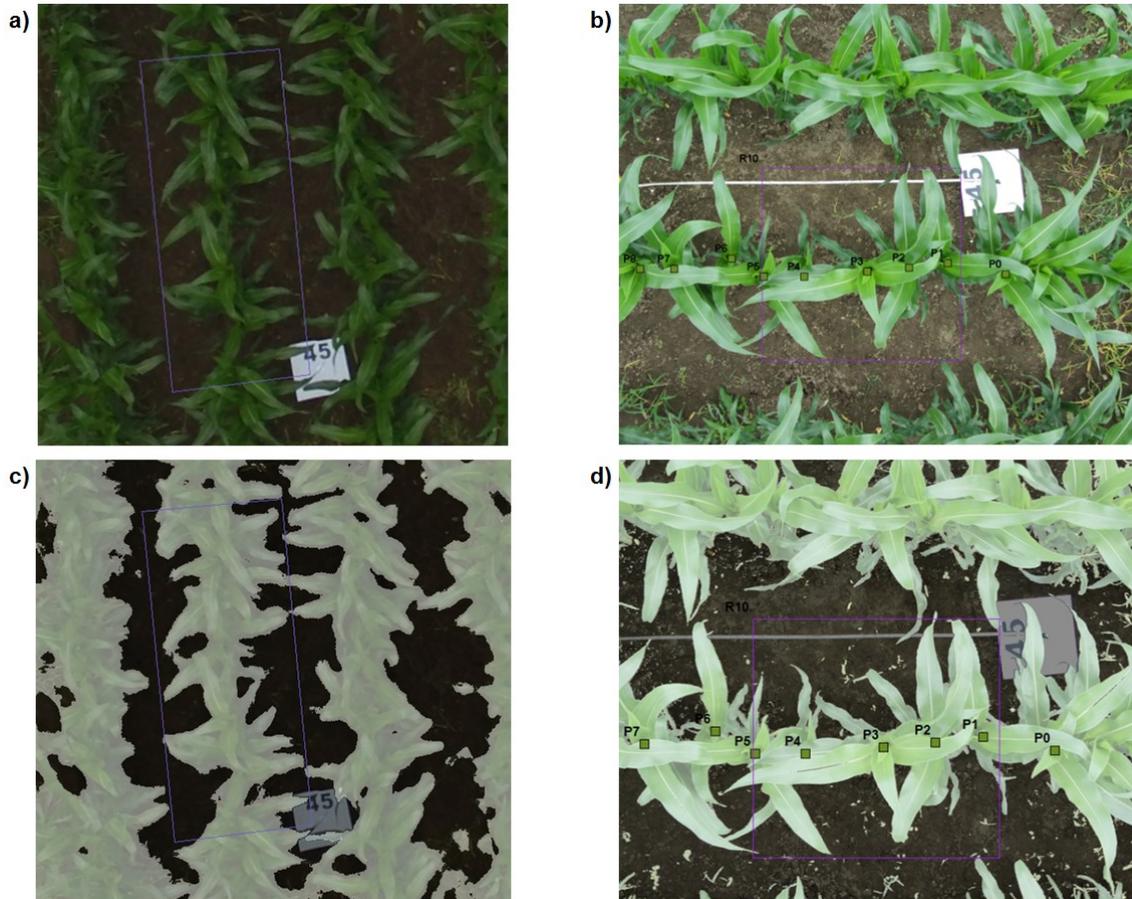


Figure 10.2 – Captures-écran extraites de l’interface utilisateur montrant un quadrat dans une image au nadir : (a) orthomosaïque clippée, produite à partir d’images acquises avec la caméra UAV et (b) cliché RGB acquis avec la caméra Canon, et leurs images segmentées superposées sur les photos originales (respectivement, c and d). Le point de contrôle (GCP) numéro 45 est visible dans cette scène, ce qui permet de localiser la zone d’échantillonnage. Les numéros P0 à P9 identifient les plants échantillonnés dans le rang, inclus dans le quadrat R10.

Pour la caméra Canon, chaque cliché a été traité séquentiellement. Les plants d’intérêt, dont le poids a été mesuré, y étaient identifiés à la main. Ensuite un quadrat, mesurant 1 m de long, a été positionné aléatoirement sur le rang échantillonné et seuls les plants contenus dans ce rectangle étaient utilisés comme vérité terrain (figure 10.2b). Le nombre de plants dans chaque quadrat variait entre 5 et 8 individus, selon la densité du rang. Dans les clichés au nadir, la largeur du quadrat correspondait à l’espacement entre les rangs, à savoir 0,75 m. Pour les clichés obliques, le quadrat était plus large pour englober toute la hauteur des plants de maïs (figure 10.3).

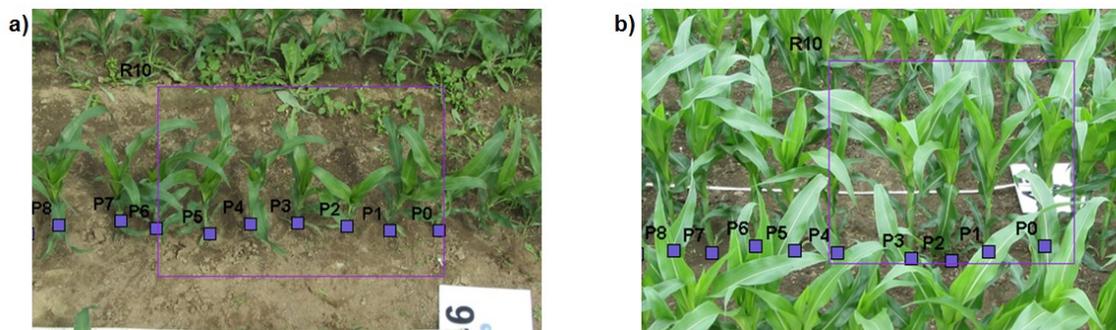


Figure 10.3 – Images obliques d’une zone d’échantillonnage photographiée avec la caméra Canon selon des angles de visée de (a) 30° et (b) 45° par rapport à la verticale. Les numéros P0 à P9 identifient les plants échantillonnés dans le rang, inclus à l’intérieur du rectangle R10.

À la fin de cette étape, nous obtenions un jeu de données avec 50 quadrats pour lesquels une opération de segmentation a été effectuée pour extraire les pixels « maïs » (voir section suivante). Pour augmenter la taille de l’échantillon, nous avons utilisé les mêmes clichés que précédemment mais en décalant les quadrats tracés afin de couvrir une portion légèrement différente du rang. L’échantillon a ainsi été doublé en taille (N = 100).

10.2.4.2. Segmentation des images

La segmentation d’image a été entièrement réalisée avec un script que nous avons développé en Python, en utilisant les modules OpenCV²⁷ et NumPy²⁸. Pour chaque image RGB (imagette ou cliché), un indice de couleur a été généré. L’utilisation d’un indice de couleur avait l’avantage de combiner les informations contenues dans les trois bandes (rouge, vert et bleu) en une seule bande synthétique qui accentuait une couleur spécifique, telle que la verdure des plantes. En se basant sur les valeurs de cet indice, on pouvait binariser l’image, c’est-à-dire séparer les pixels en deux classes distinctes par une méthode de seuillage : une valeur de l’indice, dite valeur-seuil, a été déterminée et les pixels de valeurs supérieures ont été affectés dans une classe tandis que les pixels de valeurs inférieures ont été affectés dans l’autre classe. La binarisation a ainsi permis de discriminer intuitivement une classe d’intérêt, la végétation, de l’arrière-plan (le sol nu et les résidus principalement, et parfois les mauvaises herbes, même si le désherbage était

²⁷ <https://opencv-python-tutroals.readthedocs.io/en/latest/>

²⁸ <http://www.numpy.org/>

toujours effectué avant l'acquisition des données²⁹). L'indice de couleur choisi était l'indice $ExG - ExR$ proposé par Meyer et Neto (2008). Il s'est avéré particulièrement efficace et plus précis que les autres indices de couleur que nous avons testés.

L'indice Excess Green (ExG) était l'un des cinq indices de couleur testés à l'origine par Woebbecke *et al.* (1995) pour distinguer la matière vivante du sol nu et des résidus, alors que l'indice Excess Red (ExR) a été proposé par Meyer *et al.* (1999), voir les équations 10.1 et 10.2 pour leur expression respective.

$$ExG = 2g - r - b \quad (10.1)$$

$$ExR = 1,4r - g \quad (10.2)$$

où r , g et b sont les valeurs RGB normalisées définies comme suit :

$$r = \frac{R}{R + G + B} \quad (10.3)$$

$$g = \frac{G}{R + G + B} \quad (10.4)$$

$$b = \frac{B}{R + G + B} \quad (10.5)$$

et R , G et B sont des matrices 2D des valeurs de pixels dans les canaux rouge, vert et bleu respectivement.

L'indice $ExG - ExR$ est donc la différence entre les deux indices de couleur précédents :

$$ExG - ExR = 3g - 2,4r - b \quad (10.6)$$

Contrairement à la plupart des indices de couleur nécessitant le calcul d'une valeur-seuil (méthode d'Otsu, par exemple) qui varie d'une image à l'autre, $ExG - ExR$ a un seuil constant qui vaut zéro : les pixels de végétation sont censés avoir des valeurs positives et les pixels d'arrière-plan des valeurs négatives.

²⁹ Des opérations de désherbage chimique et manuel ont été réalisées avant chaque acquisition d'images. Ainsi avons-nous pu constater la faible présence de mauvaises herbes. Par conséquent, nous admettons que la végétation correspond ici uniquement au maïs.

10.2.5. Traitement statistique

L'information extraite des images était la surface apparente des plantes et le paramètre terrain utilisé comme référence était la biomasse. Pour confirmer que la surface apparente pouvait être un bon proxy de la biomasse, nous avons choisi un modèle de régression linéaire pour définir la relation entre ces deux mesures.

10.2.5.1. Surface apparente des plantes

Pour chaque image RGB, l'étape de segmentation a généré une image binarisée où les pixels correspondant à la végétation avaient une valeur de 1 et les pixels d'arrière-plan valaient 0. En sommant la valeur de tous les pixels d'un quadrat Q donné, on obtenait ainsi le nombre N_v de pixels « végétation » dans ce quadrat :

$$N_v(\alpha) = \sum_{i \in Q} p_i \quad (10.7)$$

où N_v est le nombre de pixels « végétation » dans le quadrat Q ,

α l'angle azimutal (angle de visée),

$p_i = 1$ si le pixel i appartient à la classe « végétation », $p_i = 0$ sinon.

Une valeur de surface apparente des plantes pouvait alors être calculée comme suit :

$$S_{ap} = N_v(\alpha) \cdot \rho(\alpha)^2 \quad (10.8)$$

où $\rho(\alpha)$ est la résolution spatiale « nominale », fonction de l'angle de visée α .

Il convient de noter que les pixels dénombrés comprenaient aussi bien les feuilles que les tiges des plantes, en particulier lors de la visualisation sous un angle oblique ($\alpha > 0^\circ$). En outre, la surface calculée était dite apparente car seuls les pixels « végétation » visibles dans l'image étaient pris en compte. La taille des objets représentés par ces pixels était considérée constante et égale à la résolution nominale, quelle que soit leur distance réelle par rapport à la caméra : la position 3D de chaque pixel était inconnue.

Enfin, pour contourner le défi (soulevé au chapitre précédent) lié à la visée oblique dans le calcul de la FCV, les valeurs de S_{ap} ont été divisées par la longueur du quadrat, pour obtenir des

valeurs de surface apparente normalisée \widehat{S}_{ap} pouvant être comparées entre elles, indépendamment de la longueur du rectangle tracé. La mesure \widehat{S}_{ap} se calcule de la manière suivante :

$$\widehat{S}_{ap} = \frac{S_{ap}}{L} = \frac{N\rho^2}{L} \quad (10.9)$$

où L correspond à la longueur du quadrat. Il s'agit donc d'une surface mesurée par unité de longueur le long d'un rang ; \widehat{S}_{ap} s'exprime alors en $\text{m}^2 \text{m}^{-1}$.

10.2.5.2. Régression linéaire

À partir des quadrats obtenus suivant la procédure indiquée à la section 10.2.4.1, un jeu de données d'entraînement et un jeu de données de validation ont été constitués en répartissant arbitrairement l'échantillon initial en deux groupes de même taille ($N = 50$).

Le modèle de régression linéaire a été établi à partir du jeu de données d'entraînement, pour expliquer le comportement de la variable dépendante \widehat{S}_{ap} comme une fonction affine de la variable indépendante X représentant la biomasse. L'équation de la droite de régression, déterminée sous la forme $\widehat{S}_{ap} = aX + b$, a été estimée par la méthode des moindres carrés.

Nous avons ensuite validé notre modèle sur le jeu de données de validation. En y appliquant le modèle linéaire trouvé, nous avons calculé la biomasse prédite \hat{X} pour chaque quadrat de validation et l'avons comparée avec la biomasse réelle.

10.3. Résultats et discussion

10.3.1. Comparaison entre les plateformes d'acquisition

Il y a une relation linéaire entre la surface apparente normalisée (\widehat{S}_{ap}) calculée à partir des deux plateformes (figure 10.4) que sont le drone et la tyrolienne, avec un coefficient de détermination élevé ($R^2 = 0,94$). Bien que les images acquises avec la caméra UAV soient censées être moins précises à cause d'une résolution plus grossière (cinq fois celui de la caméra Canon, soit une résolution spatiale plus faible pour la caméra UAV), les deux caméras ont abouti pratiquement aux mêmes résultats. La segmentation des images droniques a produit des informations

cohérentes parce que la résolution spatiale était suffisamment élevée. Rasmussen *et al.* (2013) ont également constaté que la discrimination des cultures par rapport au sol nu aux premiers stades de croissance de l'orge nécessitait des images de résolution ultrafines (GSD < 5 mm). Dans cette expérience, la résolution maximale était de 4,4 mm pour la caméra UAV et de 1,26 mm pour la caméra Canon.

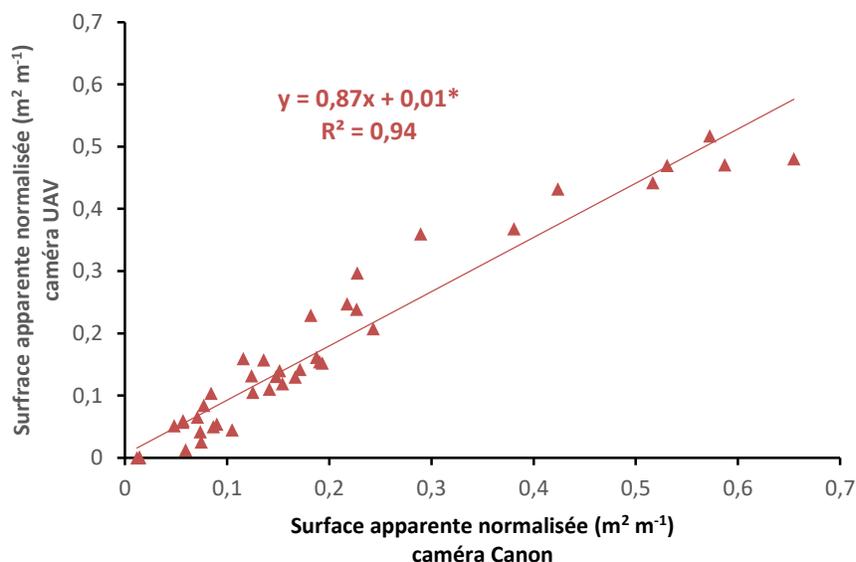


Figure 10.4 – Relation entre les surfaces apparentes normalisées calculées à partir de la caméra Canon et celles calculées à partir de la caméra à bord du drone. Taille de l'échantillon : N=42.

*Ordonnée à l'origine non significative.

En comparant les valeurs \widehat{S}_{ap} avec les données de vérité terrain, la figure 10.5 montre qu'il y a généralement une bonne corrélation entre \widehat{S}_{ap} et la biomasse (R^2 variant de 0,85 à 0,94 pour les deux plateformes). Plus précisément, pour les deux caméras, le coefficient R^2 est plus élevé dans le cas de la biomasse fraîche que la biomasse sèche. La caméra Canon a donné une meilleure corrélation que la caméra UAV ($R^2 = 0,94$ vs $R^2 = 0,91$ pour la biomasse fraîche, $R^2 = 0,91$ contre $R^2 = 0,85$ pour la biomasse sèche). En regardant les coefficients de régression, qui sont significativement différents à 95 %, la caméra UAV a également sous-estimé la biomasse par rapport à la caméra Canon (ce que l'on pouvait également voir sur la figure 10.4).

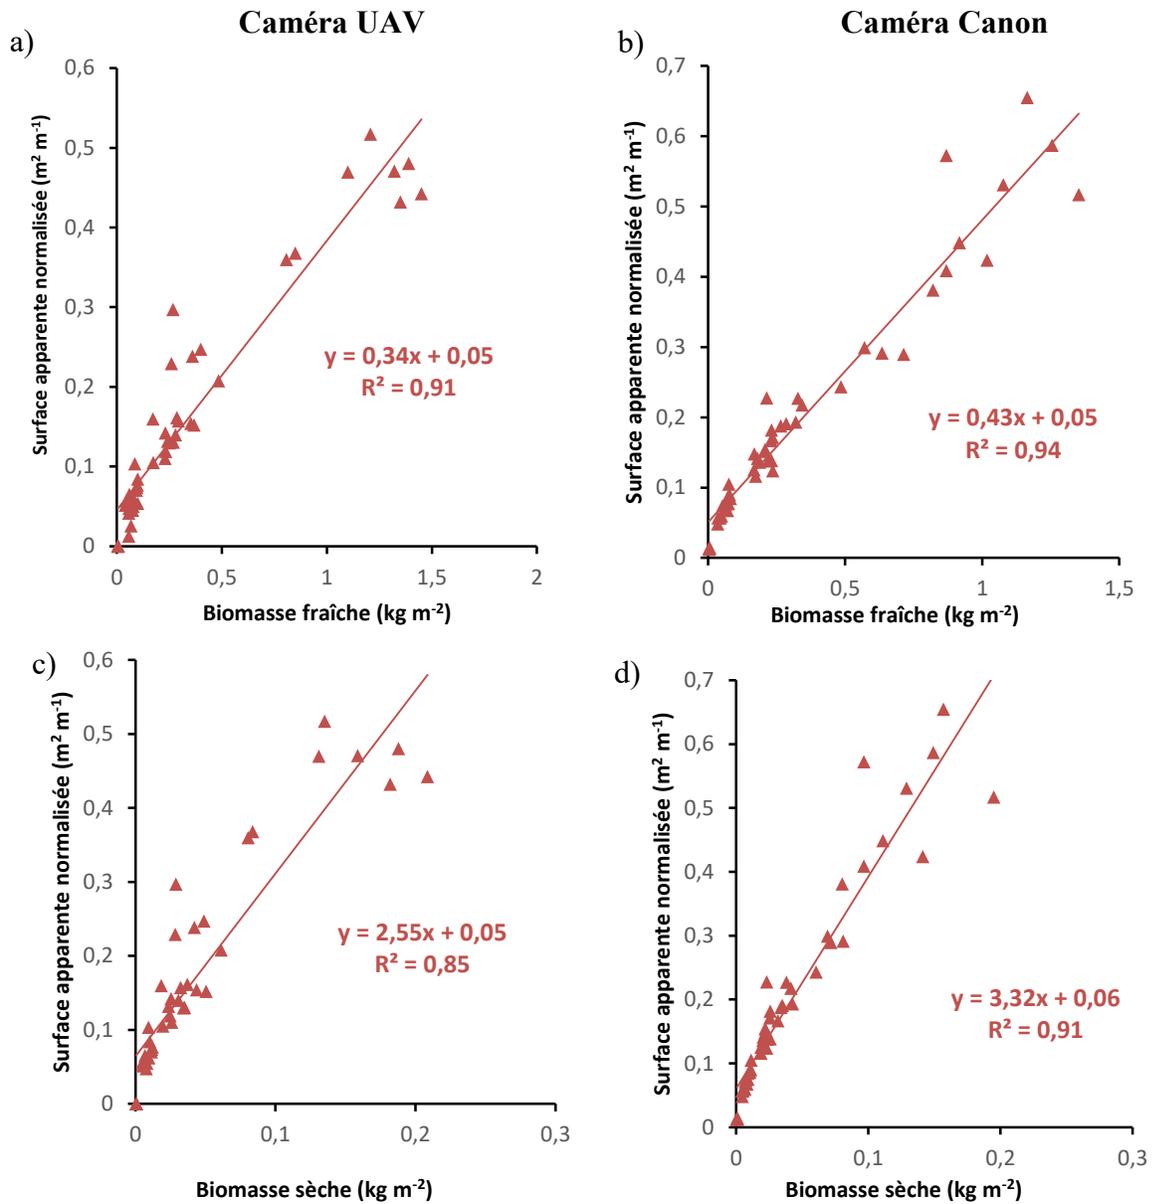


Figure 10.5 – Relation entre la biomasse fraîche (respectivement sèche) du maïs et la surface apparente normalisée pour les caméras UAV (a, c) et Canon (b, d), à partir d'images acquises au nadir. Taille des échantillons : N=48 (caméra UAV) et N=50 (caméra Canon).

Les moins bons résultats de la caméra UAV par rapport à ceux de la caméra Canon sont certainement dû à la résolution plus faible de la caméra UAV et à la dégradation radiométrique liée au mosaïquage des images droniques.

10.3.2. Comparaison entre l'imagerie nadir et oblique

La figure 10.5 (b, d) et la figure 10.6 comparent l'effet de l'angle de visée pour évaluer la surface apparente normalisée extraite de la caméra Canon, en utilisant la biomasse mesurée comme vérité terrain. Les paramètres du modèle de régression linéaire pour les différents angles de visée sont également repris au tableau 10.2. On peut en conclure que la surface apparente normalisée \widehat{S}_{ap} pourrait être un bon indicateur de la biomasse, indépendamment des angles de visée (R^2 variant de 0,94 à 0,97 pour la biomasse fraîche, R^2 variant de 0,91 à 0,95 pour la biomasse sèche).

Tableau 10.2 – Paramètres de la régression linéaire, pour estimer la surface apparente normalisée \widehat{S}_{ap} en fonction de la biomasse fraîche ou sèche ; \widehat{S}_{ap} est extraite des images acquises par la caméra Canon à différents angles de visée (N=50).

Angle de visée	Équation de la droite de régression	Coefficient de détermination R^2
Surface apparente normalisée en fonction de la biomasse fraîche		
0°	$\widehat{S}_{ap} = 0,43 * X + 0,05$	0,94
30°	$\widehat{S}_{ap} = 0,44 * X + 0,04$	0,97
45°	$\widehat{S}_{ap} = 0,47 * X + 0,03$	0,96
Surface apparente normalisée en fonction de la biomasse sèche		
0°	$\widehat{S}_{ap} = 3,32 * X + 0,06$	0,91
30°	$\widehat{S}_{ap} = 3,46 * X + 0,05$	0,95
45°	$\widehat{S}_{ap} = 3,72 * X + 0,04$	0,94

Que ce soit pour la biomasse fraîche ou la biomasse sèche, le coefficient de régression est presque constant pour les 3 angles de visée (les pentes des droites de régression ne sont pas significativement différentes à 95 %). Comme pour l'expérience en laboratoire (chapitre 8), l'angle de visée a peu d'influence dans l'estimation de la biomasse.

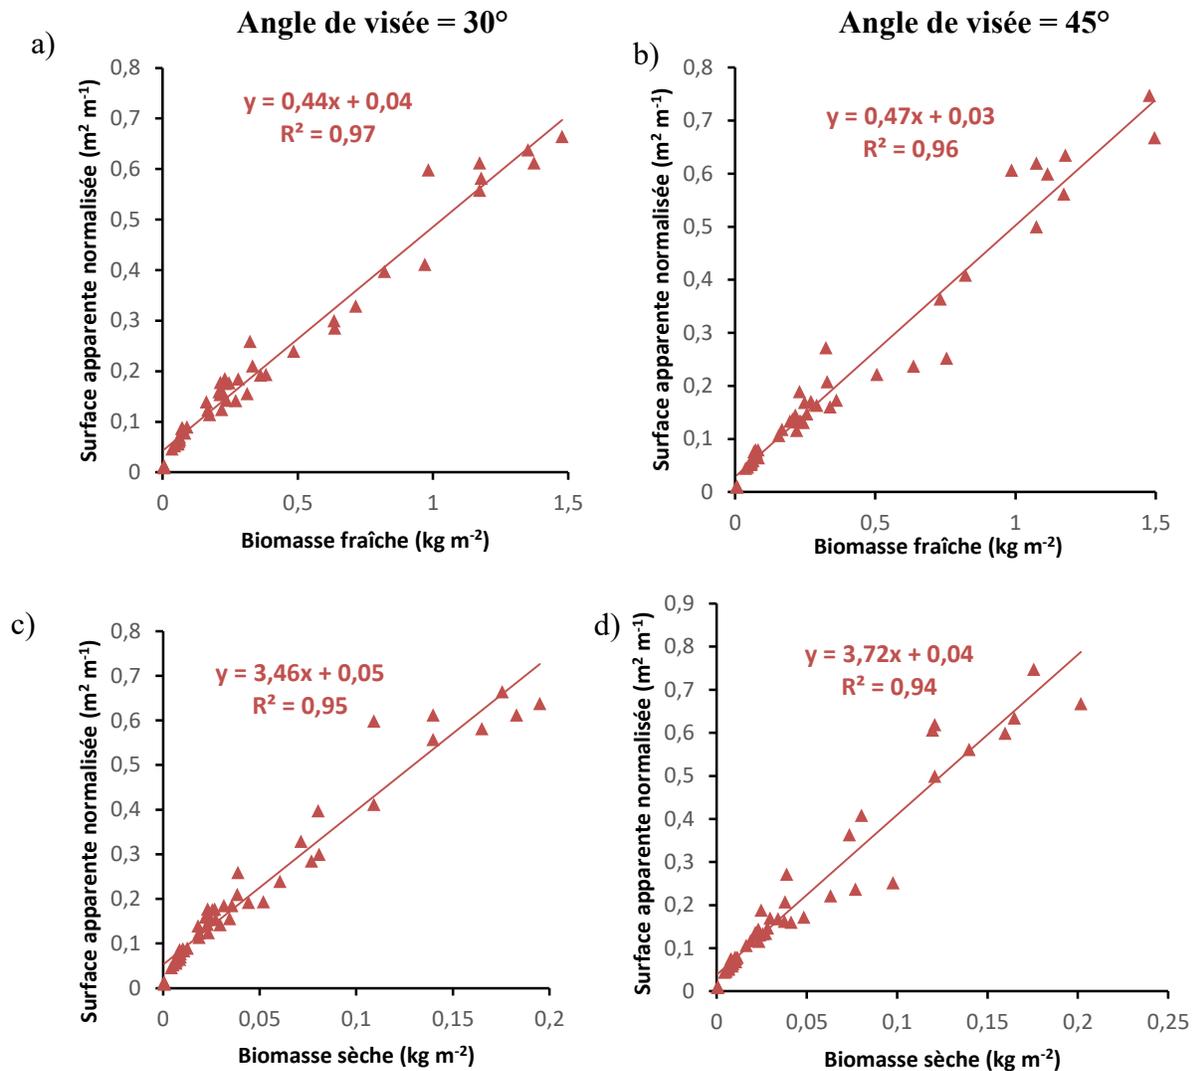


Figure 10.6 – Relation entre la biomasse fraîche (respectivement sèche) du maïs et la surface foliaire projetée extraite à partir de la caméra P, selon les angles de visée de 30° (a, c) et 45° (b, d). Taille de l'échantillon : N=50.

Tant pour la biomasse fraîche que pour la biomasse sèche, le coefficient R^2 est légèrement supérieur quand les images sont acquises avec un angle oblique par rapport aux images prises au nadir : cela laisse supposer que l'imagerie oblique génère une meilleure « vision » de la structure du rang de maïs que l'imagerie nadir. Cependant, la différence des R^2 est assez faible pour donner l'avantage à un mode d'acquisition par rapport à l'autre. Nous retiendrons surtout que l'imagerie à THRS permet une bonne estimation de la biomasse à travers la surface apparente, peu importe l'angle de visée.

10.4. Conclusion

Le NDVI a été largement utilisé et reste un choix populaire dans la télédétection de la végétation. Cette étude a exploré une autre façon d'extraire la biomasse à partir d'images avec une résolution spatiale très élevée. En segmentant les images et en calculant la surface apparente, il était possible d'évaluer la biomasse du maïs avec une précision acceptable. Les valeurs de surface normalisée \widehat{S}_{ap} étaient légèrement plus corrélées avec la biomasse fraîche que la biomasse sèche; lors de l'utilisation d'une caméra fixe au lieu d'une caméra sur un drone en mouvement ; et avec des images obliques à la place des images nadir. Malgré la nécessité du mosaïquage et malgré l'instabilité de la plateforme, les images droniques ont quand même produit un résultat convenable tant que la résolution spatiale était suffisante.

Dans cette étude, l'indice de couleur $ExG - ExR$ a été utilisé pour la segmentation de l'image, ce qui a donné une image binarisée distinguant les plantes de l'arrière-plan. Ainsi, les pixels verts comprenaient également des mauvaises herbes encore présentes sur le terrain malgré le désherbage. Cependant, le recours aux images obliques a l'avantage de minimiser l'importance des mauvaises herbes puisque ces dernières sont souvent de faible hauteur comparées aux plants de maïs.

Notre algorithme de segmentation a donné de bons résultats à cause de la faible présence de mauvaises herbes. Son efficacité peut être mise en doute pour un environnement hétéroclite ; bien que l'impact des mauvaises herbes puisse être amoindri en exploitant les images obliques. Dans le cas problématique où une parcelle est envahie par des mauvaises herbes, celles-ci fausseraient l'estimation de la surface apparente si elles ne sont pas exclues du calcul. Pour aller plus loin et distinguer ainsi les deux types de pixels verts (le maïs et les mauvaises herbes), un algorithme d'apprentissage en profondeur (*deep learning*) pourrait être un bon moyen de discriminer ces classes de végétation (Andrea *et al.*, 2017; Gao *et al.*, 2020). Une fois cette discrimination faite, l'utilisation de la surface apparente, appliquée seulement aux pixels correspondant à la culture, reste pertinente pour déterminer sa biomasse.

Chapitre 11. Perspectives

Le suivi de la vigueur est crucial en début de saison d'autant plus que de nombreuses décisions liées à la gestion des cultures sont prises à ce moment-là alors que la plante est encore dans les premiers stades de croissance. L'évaluation de l'état de santé des cultures se fait souvent par des capteurs proximaux installés à bord d'un tracteur, recourant à un indice comme le NDVI pour estimer la vigueur de la végétation. Bien que l'on ait constaté que les indices de végétation présentaient une corrélation avec certaines caractéristiques biophysiques telles que le LAI ou la biomasse, leur utilisation dans le contexte d'images à haute résolution spatiale acquises par drone devient un défi.

Les expériences que nous avons réalisées montrent qu'il est possible d'exploiter la très haute résolution pour estimer la vigueur de la culture et ce, avec plus de précision que la méthode « classique » de télédétection. Comment les résultats de notre étude peuvent-ils s'intégrer dans un contexte opérationnel d'agriculture de précision ? Pour répondre à cette question, nous allons réfléchir à divers scénarios où l'application de ces résultats pourrait se montrer pertinente. Pour cela, nous allons partir de la méthode classique et en améliorer les composantes pour aboutir à des applications dans le futur proche ou à moyen terme.

Nous donnons ci-après quelques solutions possibles, recourant à la méthodologie que nous avons exposée dans les chapitres précédents : il s'agit d'exploiter la très haute résolution des images pour estimer la biomasse du maïs et l'intégrer à un algorithme de recommandation de dose optimale pour l'azote. Cependant, gardons à l'esprit que ces exemples pourraient s'appliquer à d'autres paramètres que la vigueur (texture du sol, matière organique résiduelle...), à d'autres contextes que la fertilisation (phytopathologie, malherbologie, prévision des rendements...), à d'autres intrants que l'azote (phosphore, eau d'irrigation, produits phytosanitaires...), à d'autres cultures que le maïs (essentiellement les cultures en rangs), etc.

11.1. Le drone en remplacement des plateformes classiques de télédétection

Les imageries acquises à partir d'un satellite ou d'un avion offrent une couverture étendue mais de résolution encore « grossière » spatialement et temporellement, quand on les compare à l'imagerie dronique. Ainsi pourrait-on imaginer une première application du drone, en remplacement de ces plateformes traditionnelles de télédétection.

En effet, grâce à la flexibilité du drone qui peut être déployé en temps et en heure voulus, cette acquisition d'images pourra se faire au moment et à la fréquence les plus opportuns. À l'inverse, le temps de revisite de la plupart des satellites d'observation de la Terre ne permet pas de choisir aisément le moment et la fréquence d'acquisition.

Par ailleurs, l'imagerie dronique offre une résolution spatiale aussi fine que voulue, dans la mesure où l'altitude des survols est peu élevée (comparée à celle des satellites ou avions) et la technologie des caméras RGB s'améliore.

Le scénario serait le suivant. Le drone survole le champ, une mosaïque est constituée et la mesure de la surface foliaire apparente permet d'estimer la vigueur du maïs (méthode appliquée aux mosaïques à la section 10.2.5.1) et de recommander une dose d'azote optimale. Ce survol aurait lieu au moment le plus opportun, c'est-à-dire idéalement lors de l'opération de fertilisation. Aucune imagerie satellitaire n'est donc nécessaire.

Cependant, là où une ou deux scènes satellitaires suffisent pour obtenir une couverture complète d'un champ agricole, la démarche privilégiée avec le drone est d'acquérir une quantité importante d'images pour reconstituer une mosaïque. Cette opération nécessite que les images soient prises avec un recouvrement supérieur à 70 %, ce qui alourdit les opérations d'acquisition et de traitement des données : augmentation du temps de vol, et par conséquent, augmentation des risques inhérents (financiers, sécuritaires, matériels, humains...), défis accrus de stockage et de transfert des données, allongement des délais de traitement, erreurs possibles dans le mosaïquage, etc.

11.2. Complémentarité des plateformes

Une solution alternative à la précédente serait de combiner la couverture spatiale offerte par l'imagerie satellitaire avec la haute résolution de l'imagerie dronique. La télédétection satellitaire ferait une surveillance étendue à petite échelle sur une vaste zone, tandis que la plateforme dronique servirait à la surveillance ponctuelle à grande échelle.

Le scénario se déroulerait comme suit. Un unique passage du satellite couvre d'abord la totalité de la superficie du champ lorsque le maïs s'approche du stade voulu³⁰. On détecte alors les zones potentiellement « à risque » : là où l'indice NDVI est anormalement bas (retard de croissance, pathologie...) ou anormalement élevé (présence possible de mauvaises herbes). Ensuite, le drone passe au-dessus de ces points préalablement repérés et prend des clichés de résolution millimétrique pour estimer plus précisément l'état de la végétation (méthode appliquée aux clichés à la section 10.2.5.1), la haute résolution spatiale permettant d'exclure l'effet du sol et des mauvaises herbes.

Dans ce scénario, l'opération de mosaïquage est abandonnée. Le traitement des clichés droniques peut ainsi se faire en temps réel, et même à bord du drone avec un processeur embarqué.

Cependant, les méthodes d'estimation de la vigueur diffèrent entre les deux plateformes : recours à l'indice NDVI pour le satellite, et à la surface foliaire pour le drone. Il faut donc calibrer les deux méthodes pour produire une recommandation cohérente de fertilisation. Il n'est pourtant pas exclu que les images satellitaires puissent un jour atteindre une résolution centimétrique voire sub-centimétrique : la même méthode d'estimation de la biomasse pourra alors être utilisée.

³⁰ Les contraintes liées au temps de revisite des satellites font que le moment d'acquisition pourra précéder de plusieurs jours la date voulue. Cependant, une constellation de mini-satellites comme PlanetScope (Planet Labs Inc., San Francisco, Californie) offre désormais une couverture journalière de n'importe quelle région du monde entre 52°S et 52°N de latitude. Il sera alors possible de choisir l'acquisition la plus proche possible de la date voulue et exempt de nuages.

11.3. Surveillance continue

La polyvalence des drones offre la possibilité non seulement de détecter via des capteurs visuels, mais également d'intervenir localement. En plus des drones de télédétection, il existe déjà des drones spécialisés dans l'application de l'engrais. On pourrait ainsi avoir recours aux deux types de drones : ces deux engins se suivraient, le premier indiquant au deuxième la quantité d'azote à mettre³¹.

Dans ce cas précis, l'intervention azotée pourrait se faire non pas à un moment unique mais au besoin. Comme la croissance de la végétation varie spatialement, on pourrait ainsi imaginer qu'au lieu de mener une seule opération de fertilisation pour l'ensemble du champ, chaque zone voire chaque plante dans le champ seraient traitées à un moment différent, en doses fractionnées, en fonction du stade phénologique.

Pour mettre cette stratégie en œuvre, une surveillance continue de la croissance est nécessaire. Plusieurs solutions peuvent être imaginées. Tout d'abord, un drone ou plusieurs drones pourraient être programmés pour survoler la totalité du champ à intervalle régulier (quotidiennement, voire plus fréquemment). Pour alléger la logistique, ces drones disposeraient d'une base fixe, installée directement dans le champ ou à ses alentours : chaque jour, les drones décollent de leur base, survolent le champ et puis reviennent à leur base.

Une deuxième solution est de remplacer le drone de télédétection par des capteurs (caméras RGB) disposés à des endroits fixes, judicieusement répartis dans le champ. Les plateformes envisageables se présentent sous formes de pylônes, câbles suspendus, ou drones stationnaires flottant au-dessus du champ. Sur chaque plateforme, le capteur aura une latitude dans l'angle de visée pour couvrir une large portion de l'espace. Nous avons démontré au chapitre 10 qu'une caméra RGB acquérant des images au nadir ou en oblique pouvait donner une bonne estimation de la biomasse du maïs. Il est ainsi plausible de concevoir un système distribué de capteurs permettant de couvrir l'ensemble du champ à très haute résolution spatiale, pour suivre en temps réel l'évolution de la vigueur.

Dans les deux cas, le traitement des images sera automatisé et pourra s'effectuer :

³¹ Le deuxième drone pourrait être remplacé par un robot terrestre chargé d'appliquer l'engrais.

- en temps réel, directement sur la plateforme d’acquisition à l’aide d’un processeur embarqué ;
- avec un serveur central, situé à proximité du champ : tous les capteurs transmettent leurs images au serveur qui se charge de traiter les images ;
- via un service infonuagique : les images sont transmises dans le nuage pour être traitées.

La transmission des données peut se faire à intervalle régulier, par exemple à la fin de la journée (pour les capteurs fixes) ou au retour des drones à leur base. Cela requiert une certaine capacité de stockage et engendre une latence dans le traitement des données. Avec la technologie actuelle, et encore plus avec l’arrivée imminente du 5G (cinquième génération des standards de téléphonie mobile), la transmission des images peut se faire en temps réel, ce qui accélère le traitement et l’obtention des informations nécessaires à la fertilisation.

À la réception des données de fertilisation, le deuxième drone décolle, se rend aux points ciblés et applique la quantité d’azote déterminée.

11.4. Solution à passage unique

Les solutions proposées précédemment nécessitent que la couverture du champ soit complétée du point de vue télédétection, avant que l’engrais puisse être appliqué. C’est l’approche à passages multiples (*repeat-pass*) : un premier passage pour évaluer la situation (déterminer la vigueur) et un second pour intervenir (appliquer l’azote).

Ne serait-il pas possible d’effectuer ses deux opérations en un seul passage (*one-pass*), c’est-à-dire recommander un certain taux d’azote dès l’acquisition d’une image ? Cette solution accélérerait la prise de décision, ce qui permettrait à l’agriculteur de finir cette phase de fertilisation dans les temps, la fenêtre d’opération étant assez étroite et les champs exploités souvent immenses. L’équipement pourra ensuite être consacré à d’autres tâches telles la surveillance des maladies et des mauvaises herbes, la prévision des récoltes, etc.

Cette solution permet le traitement des images en temps réel, l’estimation de la biomasse de la végétation servant à l’algorithme à déterminer immédiatement la quantité optimale d’azote à appliquer. Elle peut être mise en place par :

- un système embarqué de caméra et d'applicateur d'engrais sur le même drone ou, de façon plus classique, sur un tracteur ;
- un tandem de drones ou un duo drone/robot qui se suivent de façon rapprochée, le premier acquérant les images, le second appliquant l'azote.

Cette méthode nécessite une révision des algorithmes basés sur l'indice NSI. Rappelons-nous que la recommandation du taux d'azote repose sur l'indice relatif NSI, qui utilise une zone de référence. Tant que cette zone de référence n'a pas été déterminée, il est impossible de calculer l'indice NSI.

Le recours à des zones de référence fixes et connues serait une solution hybride : le drone survole d'abord ces zones pour en calculer la vigueur, puis il parcourrait le reste du champ. De cette manière, le NSI peut être calculé dès l'acquisition des images. Mais cette approche suppose de créer au préalable des zones artificiellement riches en engrais et ne tient pas compte des variations locales des conditions de croissance de chaque plante.

L'approche des « références locales naturelles », prônée par Bouroubi *et al.* (2013) et adoptée par l'algorithme SCAN, évite les écueils précités. Mais elle requiert la connaissance de la vigueur dans un voisinage défini : l'approche *one-pass* s'en trouve complexifiée. D'autres voies restent donc à explorer pour optimiser la solution à passage unique.

Il est à noter que la société Trimble (Sunnyvale, Californie) commercialise déjà un système de ce genre : le système Field-IQ³², couplé avec le système GreenSeeker embarqué sur tracteur, mesure la vigueur de la culture – à travers le NDVI – et module les doses de différents produits à appliquer en temps réel.

³² <https://agriculture.trimble.com/product/systeme-field-iq-pour-le-contrle-des-intrants-de-culture/?lang=fr>

Conclusion générale

Le drone agricole constitue un arsenal supplémentaire dans la course à la précision dans le domaine de l'agriculture. Précision dans le temps, offerte par la flexibilité de la plateforme ; et précision dans l'espace, appuyée par la résolution fine des images.

Les objectifs de notre thèse étaient d'évaluer la contribution de l'imagerie dronique dans l'estimation des paramètres de culture en rangs. Pour ce faire, nous nous sommes intéressés à la vigueur du maïs, représentée par sa biomasse, dans le contexte de la fertilisation azotée. Nos travaux ont d'abord permis de constater l'obsolescence de la méthode classique basée sur l'indice NDVI : cette approche annule les avantages liés à la haute résolution spatiale à cause, principalement, du moyennage des valeurs.

La résolution millimétrique de l'imagerie dronique peut être pleinement exploitée en se servant de la surface apparente comme proxy de la biomasse. La forte corrélation entre ces deux indicateurs permet de suivre l'évolution de la vigueur dans le temps et dans l'espace. Nous avons approfondi l'étude de cette corrélation en fonction des conditions d'acquisition des images. Il existe une invariance en direction : peu importe comment se présente la plante en azimut, sa surface apparente reste stable. De même, l'angle de visée par rapport à la verticale n'affecte pas outre mesure ces résultats.

Ces constats ont ensuite permis de mettre en œuvre une méthode de traitement, basée sur la vision par ordinateur : les images sont segmentées à l'aide d'un indice de couleur pour discriminer la végétation du sol, puis le nombre de pixels « végétation » est compté et converti en superficie équivalente.

Cette méthode est accessible aux utilisateurs grâce au recours à une simple caméra RGB (disponible sur la plupart des drones commerciaux) et non à un capteur multispectral, plus coûteux et disponible seulement en option pour les drones agricoles. Elle autorise aussi l'utilisation d'autres plateformes que le drone, dans la mesure où la plateforme importe peu et seule la résolution spatiale compte.

La technique de traitement, simple et rapide, permet d'envisager le calcul en temps réel à l'aide d'un processeur embarqué et d'obtenir immédiatement les informations nécessaires à la prise de décision (dose d'azote optimale).

Enfin, le lien entre les concepts de vigueur, biomasse, surface apparente et dénombrement de pixels est suffisamment cohérent et robuste pour que l'utilisateur final, c'est-à-dire l'agriculteur, se sente à l'aise d'adopter la technologie du drone.

Dans la trame de cette étude, une question récurrente – et fondamentale pour le géographe – revient également : quelle est l'échelle pertinente d'observation et d'intervention ? La haute résolution spatiale de l'imagerie dronique impose l'échelle d'observation, mais l'extraction des données peut se faire à diverses échelles : plante individuelle, section d'un rang ou zone statistique. En découle alors la possibilité d'intervenir à ces différentes échelles.

Par conséquent, de la même manière que la surveillance et l'acquisition des données s'effectuent à une résolution de plus en plus fine, les opérations de fertilisation pourront également s'adapter à cette résolution et traiter la plante au cas par cas : au lieu de faire de la « santé publique », en traitant la population de ses plantes de la même manière, le producteur ferait de la « médecine personnalisée » en adaptant ses remèdes en fonction des besoins et particularités de chaque individu.

La très haute résolution spatiale offerte par la télédétection basse altitude, amorcée par le déploiement des drones, permet ainsi désormais de mesurer et d'agir au plus près. Cette nouvelle capacité favorise une approche individualisée du traitement des plantes, ce qui fait avancer l'agriculture de précision encore plus loin. La méthode que nous avons développée a l'avantage de s'adapter aux différentes échelles d'intervention, dont le choix est laissé à l'arbitrage des agronomes et des agriculteurs, véritables spécialistes dans ce domaine.

Les stratégies décrites pour l'application de notre méthode ne se cantonnent pas qu'à la vigueur et à la fertilisation. Elles sont valables pour n'importe quel phénomène intéressant l'agriculteur et dont la variabilité spatiale et temporelle est suffisamment élevée. Ainsi il ne faut pas occulter le fait que, même dans le cadre général de la fertilisation, la vigueur n'est qu'un paramètre parmi

d'autres qui influencent la recommandation en doses d'azote. Les algorithmes de recommandation seraient aussi grandement améliorés en étant capable d'appréhender la variabilité de ces autres paramètres, notamment la texture du sol et la teneur en matière organique.

La très haute résolution issue de l'imagerie dronique peut être exploitée pour contribuer à une meilleure connaissance de l'état du champ et de la culture et ainsi participer à la « révolution » de l'agriculture de précision.

Références bibliographiques

- Adamchuk, V. I. (2013). *Theoretical basis for sensor-based in-season nitrogen management*. Communication présentée 9th European Conference on Precision Agriculture, Lleida, Catalonia.
- Agriculture et Agroalimentaire Canada. (s. d.). Moyenne du cumul des unités thermiques maïs (UTM). Période de référence : 1979-2008. http://www.agrometeo.org/pdf/MOY_Long_1979_2008.pdf
- Alves, B. M., Cargnelutti Filho, A., Burin, C. et Toebe, M. (2017). Linear associations among phenological, morphological, productive, and energetic-nutritional traits in corn. *Pesquisa Agropecuária Brasileira*, 52(1), 26-35. <https://doi.org/10.1590/s0100-204x2017000100004>
- Amaral, L., Molin, J., Portz, G., Finazzi, F. et Cortinove, L. (2015). Comparison of crop canopy reflectance sensors used to identify sugarcane biomass and nitrogen status. *Precision Agriculture*, 16. <https://doi.org/10.1007/s11119-014-9377-2>
- Andrea, C., Daniel, B. B. M. et Misael, J. B. J. (2017). *Precise weed and maize classification through convolutional neuronal networks*. Communication présentée 2017 IEEE Second Ecuador Technical Chapters Meeting (ETCM).
- Arai, K. (2013). Bi-Directional Reflectance Distribution Function: BRDF Effect on Un-mixing, Category Decomposition of the Mixed Pixel (MIXEL) of Remote Sensing Satellite Imagery Data. *International Journal of Advanced Research in Artificial Intelligence*, 2. <https://doi.org/10.14569/IJARAI.2013.020904>
- Asner, G. P., Jonathan, M. O. S. et Hicke, J. A. (2003). Global Synthesis of Leaf Area Index Observations: Implications for Ecological and Remote Sensing Studies. *Global Ecology and Biogeography*, 12(3), 191-205.
- Assmann, J. J., Kerby, J. T., Cunliffe, A. M. et Myers-Smith, I. H. (2018). Vegetation monitoring using multispectral sensors — best practices and lessons learned from high latitudes. *Journal of Unmanned Vehicle Systems*, 7(1), 54-75. <https://doi.org/10.1139/juvs-2018-0018>
- Barnes, E. M., Clarke, T. R., Richards, S. E., Colaizzi, P. D., Haberland, J., Kostrzewski, M., . . . Moran, M. S. (2000). *Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data*. Communication présentée Fifth International Conference on Precision Agriculture, Bloomington, Minnesota.
- Bendig, J., Bolten, A., Bennertz, S., Broscheit, J., Eichfuss, S. et Bareth, G. (2014). Estimating biomass of barley using crop surface models (CSMs) derived from UAV-based RGB imaging. *Remote Sensing*, 6(11), 10395-10412.
- Berni, J. A. J., Zarco-Tejada, P. J., Suárez, L. et Fereres, E. (2009). Thermal and narrowband multispectral remote sensing for vegetation monitoring from an unmanned aerial vehicle. *IEEE Transactions on Geoscience and Remote Sensing*, 47(3), 722-738. <https://doi.org/10.1109/TGRS.2008.2010457>
- Blackmer, T. M. et Schepers, J. S. (1995). Use of a chlorophyll meter to monitor nitrogen status and schedule fertigation for corn. *Journal of Production Agriculture*, 8(1), 56-60.
- Boiarskii, B. et Hasegawa, H. (2019). Comparison of NDVI and NDRE Indices to Detect Differences in Vegetation and Chlorophyll Content. *Journal of Mechanics of Continua*

- and *Mathematical Sciences*, (4), 20-29.
<https://doi.org/10.26782/jmcms.spl.4/2019.11.00003>
- Bouroubi, Y., Tremblay, N., Vigneault, P., Belec, C. et Adamchuk, V. (2013). *Estimating Nitrogen Sufficiency Index using a Natural Local Reference approach*. Communication présentée Second International Conference on Agro-Geoinformatics, Fairfax, VA.
<https://doi.org/10.1109/Argo-Geoinformatics.2013.6621882>
- Bousquet, L., Lachérade, S., Jacquemoud, S. et Moya, I. (2005). Leaf BRDF measurements and model for specular and diffuse components differentiation. *Remote Sensing of Environment*, 98(2–3), 201-211.
<https://doi.org/http://dx.doi.org/10.1016/j.rse.2005.07.005>
- Bradski, G. (2000). The OpenCV Library. *Dr. Dobb's Journal of Software Tools*.
- Breckenridge, R. P., Dakins, M., Bunting, S., Harbour, J. L. et Lee, R. D. (2012). Using Unmanned Helicopters to Assess Vegetation Cover in Sagebrush Steppe Ecosystems. *Rangeland Ecology and Management*, 65, 362-370. <https://doi.org/10.2111/REM-D-10-00031.1>
- Brocks, S., Bendig, J. et Bareth, G. (2016). Toward an automated low-cost three-dimensional crop surface monitoring system using oblique stereo imagery from consumer-grade smart cameras. *Journal of Applied Remote Sensing*, 10(4), 1-19.
<https://doi.org/10.1117/1.JRS.10.046021>
- Buso, W. H. D., Gomes, L. L., Ballesta, P. et Mora, F. (2019). A phenotypic comparison of yield and related traits in elite commercial corn hybrids resistant to pests. *IDESIA*, 37(2), 45-50.
- Caturegli, L., Corniglia, M., Gaetani, M., Grossi, N., Magni, S., Migliazzi, M., . . . Volterrani, M. (2016). Unmanned Aerial Vehicle to Estimate Nitrogen Status of Turfgrasses. *PLoS ONE*, 11(6). <https://doi.org/10.1371/journal.pone.0158268>
- Chan, C. W., Schueller, J. K., Miller, W. M., Whitney, J. D. et Cornell, J. A. (2004). Error Sources Affecting Variable Rate Application of Nitrogen Fertilizer. *Precision Agriculture*, 5(6), 601-616. <https://doi.org/10.1007/s11119-004-6345-2>
- Chen, J. M. (1999). Spatial Scaling of a Remotely Sensed Surface Parameter by Contexture. *Remote Sensing of Environment*, 69, 30-42.
- Comar, A., Baret, F., Viénot, F., Yan, L. et de Solan, B. (2012). Wheat leaf bidirectional reflectance measurements: Description and quantification of the volume, specular and hot-spot scattering features. *Remote Sensing of Environment*, 121, 26-35.
<https://doi.org/https://doi.org/10.1016/j.rse.2011.01.028>
- Commissariat à la protection de la vie privée du Canada. (2013). Les véhicules aériens sans pilote au Canada. https://www.priv.gc.ca/fr/mesures-et-decisions-prises-par-le-commissariat/recherche/consulter-les-travaux-de-recherche-sur-la-protection-de-la-vie-privee/2013/drones_201303/
- Commission interministérielle de terminologie de la télédétection aérospatiale. (1988). Glossaire des termes officiels de la teledetection aérospatiale. *Bulletin de la Société française de photogrammétrie et teledetection*, 112, 1-63.
- Conseil de l'Union européenne. (2012). Towards a European strategy for the development of civil applications of Remotely Piloted Aircraft Systems (RPAS). <https://register.consilium.europa.eu/doc/srv?l=EN&f=ST%2013438%202012%20INIT>

- Crain, J. L., Ortiz-Monasterio, I. et Raun, B. (2012). Evaluation of a Reduced Cost Active NDVI Sensor for Crop Nutrient Management. *Journal of Sensors*, 2012, 10. <https://doi.org/10.1155/2012/582028>
- Daughtry, C. S. T., Walthall, C. L., Kim, M. S., De Colstoun, E. B. et McMurtrey Iii, J. E. (2000). Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. *Remote Sensing of Environment*, 74(2), 229-239. [https://doi.org/10.1016/S0034-4257\(00\)00113-9](https://doi.org/10.1016/S0034-4257(00)00113-9)
- Du, H., Jiang, H., Zhang, L., Mao, D. et Wang, Z. (2016). Evaluation of spectral scale effects in estimation of vegetation leaf area index using spectral indices methods. *Chinese Geographical Science*, 26(6), 731-744. <https://doi.org/10.1007/s11769-016-0833-y>
- DuPont Pioneer. (2014). Écartement des rangs en production de maïs grain. https://www.pioneer.com/CMRoot/Pioneer/Canada_fr/agronomie/resume_recherche/2014_Ecartement_des_Rangs_en_Production_de_Mais_Grains.pdf
- Edmonds, D. E., Tubaña, B. S., Kelly, J. P., Crain, J. L. et Raun, W. R. (2013). Maize Grain Yield Response to Variable Row Nitrogen Fertilization. *Journal of Plant Nutrition*, 36, 1013-1024. <https://doi.org/10.1080/01904167.2011.585198>
- Fahlgren, N., Gehan, M. A. et Baxter, I. (2015). Lights, camera, action: high-throughput plant phenotyping is ready for a close-up. *Current Opinion in Plant Biology*, 24, 93-99. <https://doi.org/https://doi.org/10.1016/j.pbi.2015.02.006>
- Fang, Y. et Ramasamy, R. P. (2015). Current and Prospective Methods for Plant Disease Detection. *Biosensors*, 5(3), 537-561. <https://doi.org/10.3390/bios5030537>
- Fossi, A. P. (2016). *Miniaturisation d'une caméra hyperspectrale infrarouge*. (Doctorat en physique). <https://tel.archives-ouvertes.fr/tel-01511621>
- Freeman, K. W., Girma, K., Arnall, D. B., Mullen, R. W., Martin, K. L., Teal, R. K. et Raun, W. R. (2007). By-Plant Prediction of Corn Forage Biomass and Nitrogen Uptake at Various Growth Stages Using Remote Sensing and Plant Height. *Agron J*, 99(2), 530-536.
- Gabriel, J. L., Zarco-Tejada, P. J., López-Herrera, P. J., Pérez-Martín, E., Alonso-Ayuso, M. et Quemada, M. (2017). Airborne and ground level sensors for monitoring nitrogen status in a maize crop. *Biosystems Engineering*, 160, 124-133. <https://doi.org/https://doi.org/10.1016/j.biosystemseng.2017.06.003>
- Gao, J., French, A. P., Pound, M. P., He, Y., Pridmore, T. P. et Pieters, J. G. (2020). Deep convolutional neural networks for image-based *Convolvulus sepium* detection in sugar beet fields. *Plant Methods*, 16(1), 29. <https://doi.org/10.1186/s13007-020-00570-z>
- Ge, Y., Bai, G., Stoerger, V. et Schnable, J. C. (2016). Temporal dynamics of maize plant growth, water use, and leaf water content using automated high throughput RGB and hyperspectral imaging. *Computers and Electronics in Agriculture*, 127, 625-632. <https://doi.org/https://doi.org/10.1016/j.compag.2016.07.028>
- Geipel, J., Link, J. et Claupein, W. (2014). Combined Spectral and Spatial Modeling of Corn Yield Based on Aerial Images and Crop Surface Models Acquired with an Unmanned Aircraft System. *Remote Sensing*, 6(11), 10335-10355.
- Geipel, J., Link, J., Wirwahn, J. A. et Claupein, W. (2016). A programmable aerial multispectral camera system for in-season crop biomass and nitrogen content estimation. *Agriculture (Switzerland)*, 6(1). <https://doi.org/10.3390/agriculture6010004>
- Gitelson, A. A. (2004). Wide dynamic range vegetation index for remote quantification of biophysical characteristics of vegetation. *Journal of Plant Physiology*, 161(2), 165-173.

- Gitelson, A. A., Kaufman, Y. J., Stark, R. et Rundquist, D. (2002). Novel algorithms for remote estimation of vegetation fraction. *Remote Sensing of Environment*, 80(1), 76-87. [https://doi.org/http://dx.doi.org/10.1016/S0034-4257\(01\)00289-9](https://doi.org/http://dx.doi.org/10.1016/S0034-4257(01)00289-9)
- Gitelson, A. A. et Merzlyak, M. N. (1998). Remote Sensing of Chlorophyll Concentration in Higher Plant Leaves. *Advances in Space Research*, 22(5), 689-692.
- Gnädinger, F. et Schmidhalter, U. (2017). Digital counts of maize plants by Unmanned Aerial Vehicles (UAVs). *Remote Sensing*, 9(6). <https://doi.org/10.3390/rs9060544>
- Gu, Y., Wylie, B. K., Howard, D. M., Phuyal, K. P. et Ji, L. (2013). NDVI saturation adjustment: A new approach for improving cropland performance estimates in the Greater Platte River Basin, USA. *Ecological Indicators*, 30, 1-6. <https://doi.org/https://doi.org/10.1016/j.ecolind.2013.01.041>
- Guissard, V., Lucau-Danila, C. et Defourny, P. (2005). *Crop specific LAI retrieval using optical and radar satellite data for regional crop growth monitoring and modelling*. SPIE.
- Haboudane, D., Miller, J. R., Tremblay, N., Zarco-Tejada, P. J. et Dextraze, L. (2002). Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. *Remote Sensing of Environment*, 81(2-3), 416-426.
- Han, L., Yang, G., Dai, H., Xu, B., Yang, H., Feng, H., . . . Yang, X. (2019). Modeling maize above-ground biomass based on machine learning approaches using UAV remote-sensing data. *Plant Methods*, 15(1), 10. <https://doi.org/10.1186/s13007-019-0394-z>
- Henrich, V., Krauss, G., Götze, C. et Sandow, C. (2012). IDB - www.indexdatabase.de, Entwicklung einer Datenbank für Fernerkundungsindizes. http://www.lap.uni-bonn.de/publikationen/posterordner/henrich_et_al_2012
- Hlaing, S. H. et Khaing, A. S. (2014). Weed and Crop Segmentation and Classification Using Area Thresholding. *International Journal of Research in Engineering and Technology*, 3(3), 378-382.
- Holman, F. H., Riche, A. B., Michalski, A., Castle, M., Wooster, M. J. et Hawkesford, M. J. (2016). High Throughput Field Phenotyping of Wheat Plant Height and Growth Rate in Field Plot Trials Using UAV Based Remote Sensing. *Remote Sensing*, 8(12), 1031. <https://doi.org/10.3390/rs8121031>
- Hong, S.-D., Schepers, J. S., Francis, D. D. et Schlemmer, M. R. (2007). Comparison of Ground-Based Remote Sensors for Evaluation of Corn Biomass Affected by Nitrogen Stress. *Communications in Soil Science and Plant Analysis*, 38(15), 2209-2226.
- Hosgood, B., Jacquemoud, S., Andreoli, G., Verdebout, J., Pedrini, G. et Schmuck, G. (1993). Leaf Optical Properties EXperiment 93 (LOPEX93). <http://ecosis.org>
- Hu, P., Chapman, S. C., Wang, X., Potgieter, A., Duan, T., Jordan, D., . . . Zheng, B. (2018). Estimation of plant height using a high throughput phenotyping platform based on unmanned aerial vehicle and self-calibration: Example for sorghum breeding. *European Journal of Agronomy*, 95, 24-32. <https://doi.org/10.1016/j.eja.2018.02.004>
- Huang, W., Ratkowsky, D. A., Hui, C., Wang, P., Su, J. et Shi, P. (2019). Leaf Fresh Weight Versus Dry Weight: Which is Better for Describing the Scaling Relationship between Leaf Biomass and Leaf Area for Broad-Leaved Plants? *Forests*, 10(3). <https://doi.org/10.3390/f10030256>
- Huang, W., Su, X., Ratkowsky, D. A., Niklas, K. J., Gielis, J. et Shi, P. (2019). The scaling relationships of leaf biomass vs. leaf surface area of 12 bamboo species. *Global Ecology and Conservation*, 20, e00793. <https://doi.org/https://doi.org/10.1016/j.gecco.2019.e00793>

- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295-309.
- Hunt, E. R., Jr., Daughtry, C. S. T., Eitel, J. U. H. et Long, D. S. (2011). Remote Sensing Leaf Chlorophyll Content Using a Visible Band Index. *Agronomy Journal*, 103(4). <https://doi.org/10.2134/agronj2010.0395>
- Hunt, E. R., Jr., Daughtry, C. S. T., Mirsky, S. B. et Hively, W. D. (2013). *Remote sensing with unmanned aircraft systems for precision agriculture applications*. Communication présentée Second International Conference on Agro-Geoinformatics, Fairfax, VA. <https://doi.org/10.1109/Argo-Geoinformatics.2013.6621894>
- Hunt, E. R., Jr., Daughtry, C. S. T., Mirsky, S. B. et Hively, W. D. (2014). Remote sensing with simulated unmanned aircraft imagery for precision agriculture applications. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(11), 4566-4571.
- Hunt, E. R., Jr., Dean Hively, W., Fujikawa, S. J., Linden, D. S., Daughtry, C. S. T. et McCarty, G. W. (2010). Acquisition of NIR-green-blue digital photographs from unmanned aircraft for crop monitoring. *Remote Sensing*, 2(1), 290-305.
- Hunt, E. R., Jr., Hively, W. D., Daughtry, C. S. T., McCarty, G. W., Fujikawa, S. J., Ng, T. L., . . . Yoel, D. W. (2008). *Remote sensing of crop leaf area index using unmanned airborne vehicles*. Communication présentée 17th William T. Pecora Memorial Remote Sensing Symposium, Denver, Colorado. <https://www.asprs.org/a/publications/proceedings/pecora17/0018.pdf>
- Iglhaut, J., Cabo, C., Puliti, S., Piermattei, L., O'Connor, J. et Rosette, J. (2019). Structure from Motion Photogrammetry in Forestry: a Review. *Current Forestry Reports*, 5(3), 155-168. <https://doi.org/10.1007/s40725-019-00094-3>
- International Society of Precision Agriculture (2019). ISPA Official Definition of Precision Agriculture. *ISPA Newsletter*, 7. <https://ispag.org/site/newsletter/?id=90>
- Jacquemoud, S. et Baret, F. (1990). PROSPECT: a model of leaf optical properties spectra. *Remote Sensing of Environment*, 34(1), 75-91.
- Jacquemoud, S., Verhoef, W., Baret, F., Bacour, C., Zarco-Tejada, P. J., Asner, G. P., . . . Ustin, S. L. (2009). PROSPECT+SAIL models: A review of use for vegetation characterization. *Remote Sensing of Environment*, 113, S56-S66. <https://doi.org/https://doi.org/10.1016/j.rse.2008.01.026>
- Jay, S., Bendoula, R., Hadoux, X., Féret, J.-B. et Gorretta, N. (2016). A physically-based model for retrieving foliar biochemistry and leaf orientation using close-range imaging spectroscopy. *Remote Sensing of Environment*, 177, 220-236. <https://doi.org/10.1016/j.rse.2016.02.029>
- Kamath, R., Balachandra, M. et Prabhu, S. (2020). Crop and weed discrimination using Laws' texture masks. *International Journal of Agricultural and Biological Engineering* 13(1), 191-197.
- Kelly, J., Crain, J. L. et Raun, W. R. (2015). By-Plant Prediction of Corn (*Zea Mays* L.) Grain Yield using Height and Stalk Diameter. *Communications in Soil Science and Plant Analysis*, 46(5), 564-575. <https://doi.org/10.1080/00103624.2014.998340>
- Khaliq, A., Comba, L., Biglia, A., Ricauda Aimonino, D., Chiaberge, M. et Gay, P. (2019). Comparison of Satellite and UAV-Based Multispectral Imagery for Vineyard Variability Assessment. *Remote Sensing*, 11(4). <https://doi.org/10.3390/rs11040436>

- Khun, K., Vigneault, P., Tremblay, N., Bouroubi, M. Y., Cavayas, F. et Codjia, C. (2016). *Comparative Benefits of Drone Imagery for Nitrogen Status Determination in Corn*. Communication présentée 13e conférence internationale sur l'agriculture de précision (ICPA), St. Louis, Missouri. <https://ispag.org/proceedings/?action=abstract&id=2159>
- Krishna, K. R. (2018). *Agricultural Drones: A Peaceful Pursuit*. Oakville, ON: Apple Academic Press Inc.
- Laliberte, A. S., Goforth, M. A., Steele, C. M. et Rango, A. (2011). Multispectral remote sensing from unmanned aircraft: Image processing workflows and applications for rangeland environments. *Remote Sensing*, 3(11), 2529-2551. <https://doi.org/10.3390/rs3112529>
- Lang, Q., Zhiyong, Z., Longsheng, C., Hong, S., Minzan, L., Li, L. et Junyong, M. (2019). Detection of Chlorophyll Content in Maize Canopy from UAV Imagery. *IFAC-PapersOnLine*, 52(30), 330-335. <https://doi.org/https://doi.org/10.1016/j.ifacol.2019.12.561>
- Le Maire, G., François, C., Soudani, K., Berveiller, D., Pontailier, S., Bréda, N., . . . Dufrêne, E. (2008). Calibration and validation of hyperspectral indices for the estimation of broadleaved forest leaf chlorophyll content, leaf mass per area, leaf area index and leaf canopy biomass. *Remote Sensing of Environment*, 112(10), 3846-3864.
- Lebourgeois, V., Bégué, A., Labbé, S., Mallavan, B., Prévot, L. et Roux, B. (2008). Can Commercial Digital Cameras Be Used as Multispectral Sensors? A Crop Monitoring Test. *Sensors*, 8, 7300-7322. <https://doi.org/10.3390/s8117300>
- Lelong, C. C. D., Burger, P., Jubelin, G., Roux, B., Labbé, S. et Baret, F. (2008). Assessment of Unmanned Aerial Vehicles Imagery for Quantitative Monitoring of Wheat Crop in Small Plots. *Sensors*, 8(5), 3557-3585. <https://doi.org/10.3390/s8053557>
- Lepage, M.-P., Bourgeois, G. et Bélanger, G. (2012). Indices agrométéorologiques pour l'aide à la décision dans un contexte de climat variable et en évolution. http://www.agrometeo.org/atlas/display_guide/PAGR0103.pdf
- Link, J., Senner, D. et Claupein, W. (2013). Developing and evaluating an aerial sensor platform (ASP) to collect multispectral data for deriving management decisions in precision farming. *Computers and Electronics in Agriculture*, 94, 20-28.
- Liu, C.-a., Chen, Z.-x., Shao, Y., Chen, J.-s., Hasi, T. et Pan, H.-z. (2019). Research advances of SAR remote sensing for agriculture applications: A review. *Journal of Integrative Agriculture*, 18(3), 506-525. [https://doi.org/https://doi.org/10.1016/S2095-3119\(18\)62016-7](https://doi.org/https://doi.org/10.1016/S2095-3119(18)62016-7)
- Liu, L., Cao, R., Shen, M., Chen, J., Wang, J. et Zhang, X. (2019). How Does Scale Effect Influence Spring Vegetation Phenology Estimated from Satellite-Derived Vegetation Indexes? *Remote Sensing*, 11(18). <https://doi.org/10.3390/rs11182137>
- MAAARO (2017). *Guide agronomique des grandes cultures, Publication 811F*. <http://www.omafra.gov.on.ca/french/crops/pub811/pub811.pdf>
- Madec, S., Baret, F., de Solan, B., Thomas, S., Dutartre, D., Jezequel, S., . . . Comar, A. (2017). High-Throughput Phenotyping of Plant Height: Comparing Unmanned Aerial Vehicles and Ground LiDAR Estimates. *Frontiers in Plant Science*, 8(2002). <https://doi.org/10.3389/fpls.2017.02002>
- MAPAQ. (2015). Monographie de l'industrie des grains au Québec. <https://www.mapaq.gouv.qc.ca/fr/md/Publications/Pages/Details-Publication.aspx?guid=%7Bd96007f9-b0bf-4b1e-bf2b-07513d48924f%7D>

- Martin, K. L., Hodgen, P. J., Freeman, K. W., Melchiori, R., Arnall, D. B., Teal, R. K., . . . Raun, W. R. (2005). Plant-to-Plant Variability in Corn Production. *Agronomy Journal*, 97, 1603-1611.
- Matese, A., Toscano, P., Di Gennaro, S. F., Genesio, L., Vaccari, F. P., Primicerio, J., . . . Gioli, B. (2015). Intercomparison of UAV, aircraft and satellite remote sensing platforms for precision viticulture. *Remote Sensing*, 7(3), 2971-2990. <https://doi.org/10.3390/rs70302971>
- Mathan, J., Bhattacharya, J. et Ranjan, A. (2016). Enhancing crop yield by optimizing plant developmental features. *Development*, 143, 3238-3294. <https://doi.org/10.1242/dev.134072>
- Meyer, G. E., Hindman, T. W. et Lakshmi, K. (1998, 1-6 November 1998). *Machine Vision Detection Parameters for Plant Species Identification*. Communication présentée Photonics East (ISAM, VVDC, IEMB), Boston, MA. <https://doi.org/10.1117/12.336896>
- Meyer, G. E., Hindman, T. W. et Lakshmi, K. (1999). Machine vision detection parameters for plant species identification. Dans G. E. Meyer & J. A. DeShazer (dir.), *Precision Agriculture and Biological Quality 1998, Proceedings of Society of Photo-Optical Instrumentation Engineers* (p. 327-335). Bellingham, WA: SPIE.
- Meyer, G. E. et Neto, J. C. (2008). Verification of color vegetation indices for automated crop imaging applications. *Computers and Electronics in Agriculture*, 63, 282-293. <https://doi.org/10.1016/j.compag.2008.03.009>
- Milla, R. et Reich, P. (2007). The scaling of leaf area and mass: The cost of light interception increases with leaf size. *Proceedings. Biological sciences / The Royal Society*, 274, 2109-2114. <https://doi.org/10.1098/rspb.2007.0417>
- Ministère de la Justice du Canada. (2020). Règlement de l'aviation canadien. <https://laws-lois.justice.gc.ca/fra/reglements/DORS-96-433/>
- Mondo, V., Cicero, S., Dourado-Neto, D., Pupim, T. et Dias, M. (2013). Seed vigor and initial growth of corn crop. *Revista Brasileira de Sementes*, 35, 064-069. <https://doi.org/10.1590/S2317-15372013000100009>
- Morel, J., Jay, S., Féret, J.-B., Bakache, A., Bendoula, R., Carreel, F. et Gorretta, N. (2018). Exploring the potential of PROCOSINE and close-range hyperspectral imaging to study the effects of fungal diseases on leaf physiology. *Scientific Reports*, 8(1), 15933. <https://doi.org/10.1038/s41598-018-34429-0>
- Morisette, J. T. (2010). Toward a standard nomenclature for imagery spatial resolution. *International Journal of Remote Sensing*, 31(9), 2347-2349. <https://doi.org/10.1080/01431160902994457>
- 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>
- Muñoz-Huerta, R. F., Guevara-Gonzalez, R. G., Contreras-Medina, L. M., Torres-Pacheco, I., Prado-Olivarez, J. et Ocampo-Velazquez, R. V. (2013). A Review of Methods for Sensing the Nitrogen Status in Plants: Advantages, Disadvantages and Recent Advances. *Sensors*, 13, 10823-10843. <https://doi.org/10.3390/s130810823>
- Mutanga, O. et Skidmore, A. K. (2004). Narrow band vegetation indices overcome the saturation problem in biomass estimation. *International Journal of Remote Sensing*, 25(19), 3999-4014. <https://doi.org/10.1080/01431160310001654923>

- Najla, S., Sanoubar, R. et Murshed, R. (2012). Morphological and biochemical changes in two parsley varieties upon water stress. *Physiology and molecular biology of plants : an international journal of functional plant biology*, 18, 133-139. <https://doi.org/10.1007/s12298-012-0105-y>
- Niu, Y., Zhang, L., Zhang, H., Han, W. et Peng, X. (2019). Estimating Above-Ground Biomass of Maize Using Features Derived from UAV-Based RGB Imagery. *Remote Sensing*, 11(11). <https://doi.org/10.3390/rs11111261>
- Omara, P., Aula, L., Raun, B., Taylor, R., Koller, A., Lam, E., . . . Macnack, N. (2016). Hand planter for maize (*Zea may* L.) in the developing world. *Journal of Plant Nutrition*, 39(9), 1233-1239. <https://doi.org/10.1080/01904167.2015.1022186>
- Onyango, C. M. et Marchant, J. A. (2003). Segmentation of row crop plants from weeds using colour and morphology. *Computers and Electronics in Agriculture*, 39(3), 141-155. [https://doi.org/https://doi.org/10.1016/S0168-1699\(03\)00023-1](https://doi.org/https://doi.org/10.1016/S0168-1699(03)00023-1)
- P. Fulton, J., A. Shearer, S., F. Higgins, S., J. Darr, M. et S. Stombaugh, T. (2005). Rate Response Assessment from Various Granular VRT Applicators. *Transactions of the ASAE*, 48(6), 2095-2103. <https://doi.org/https://doi.org/10.13031/2013.20086>
- Perez, A. J., Lopez, F., Benlloch, J. V. et Christensen, S. (2000). Colour and Shape Analysis Techniques for Weed Detection in Cereal Fields. *Computers and Electronics in Agriculture*, 25, 197-212.
- Perreault, L., Denault, A., Lévesque-Dupont, M., Breton, M., Mercier, P. et Laberg, M. (2014). Projet de télédétection de problématiques agroenvironnementales, à basse altitude avec un drone https://www.mapaq.gouv.qc.ca/SiteCollectionDocuments/Regions/ChaudiereAppalaches/Agroenvironnement/Rapport_teledection_problemes_agroenvironnementaux_dron e.pdf
- Petit, J. et Jobin, P. (2005). *La fertilisation organique des cultures. Les bases*. Longueuil, Québec.
- Phelippeau, H. (2009). *Méthodes et algorithmes de dématricage et de filtrage du bruit pour la photographie numérique*. (Thèse de doctorat Université Paris-Est). https://pastel.archives-ouvertes.fr/file/index/docid/499252/filename/2009PEST1002_0_0.pdf
- Pierce, F. J. et Sadler, E. J. (1995). *The State of Site Specific Management for Agriculture*. Communication présentée The State of Site Specific Management for Agriculture, St. Louis, Missouri.
- Pix4D. (s. d.). Camera Requirements For Precision Agriculture. <https://support.pix4d.com/hc/en-us/articles/204894705-Camera-Requirements-for-Precision-Agriculture>
- Qi, J., Chehbouni, A., Huete, A. R., Kerr, Y. H. et Sorooshian, S. (1994). A modified soil adjusted vegetation index. *Remote Sensing of Environment*, 48(2), 119-126.
- Quemada, M., Gabriel, J. et Zarco-Tejada, P. (2014). Airborne Hyperspectral Images and Ground-Level Optical Sensors As Assessment Tools for Maize Nitrogen Fertilization. *Remote Sensing*, 6(4), 2940-2962.
- Rabatel, G., Gorretta, N. et Labbé, S. (2014). Getting simultaneous red and near-infrared band data from a single digital camera for plant monitoring applications: theoretical and practical study. *Biosystems Engineering*, 117(1), 2-14. <https://doi.org/10.1016/j.biosystemseng.2013.06.008>

- Rabatel, G. et Labbé, S. (2016). Registration of visible and near infrared unmanned aerial vehicle images based on Fourier-Mellin transform. *Precision Agriculture*, 17(5), 564-587. <https://doi.org/10.1007/s11119-016-9437-x>
- Rasmussen, J., Nielsen, J., Garcia-Ruiz, F., Christensen, S. et Streibig, J. C. (2013). Potential uses of small unmanned aircraft systems (UAS) in weed research. *Weed Research*, 53, 242-248.
- Rasmussen, J., Ntakos, G., Nielsen, J., Svensgaard, J., Poulsen, R. N. et Christensen, S. (2016). Are vegetation indices derived from consumer-grade cameras mounted on UAVs sufficiently reliable for assessing experimental plots? *European Journal of Agronomy*, 74, 75-92. <https://doi.org/10.1016/j.eja.2015.11.026>
- Robertson, G. P. (2008). *GS+: Geostatistics for the Environmental Sciences*. <https://geostatistics.com/files/GSPlusUserGuide.pdf>
- Rondeaux, G., Steven, M. et Baret, F. (1996). Optimization of Soil-Adjusted Vegetation Indices. *Remote Sensing of Environment*, 55(2), 95-107.
- Rouse, J. W., Haas, R. H., Schell, J. A. et Deering, D. W. (1974). *Monitoring vegetation systems in the Great Plains with ERTS*, United States. <https://doi.org/citeulike-article-id:12009708>
- Ryu, C., Suguri, M. et Umeda, M. (2011). Multivariate analysis of nitrogen content for rice at the heading stage using reflectance of airborne hyperspectral remote sensing. *Field Crops Research*, 122(3), 214-224. <https://doi.org/10.1016/j.fcr.2011.03.013>
- Sadeq, H. A. (2018). Accuracy assessment using different UAV imageoverlaps. *Journal of Unmanned Vehicle Systems*, 7(3), 175-193. <https://doi.org/10.1139/juvs-2018-0014>
- Seabold, S. et Perktold, J. (2010). *Statsmodels: Econometric and statistical modeling with python*. Communication présentée 9th Python in Science Conference.
- Shannon, D. K., Clay, D. E. et Sudduth, K. A. (2018). An Introduction to Precision Agriculture. Dans D. K. Shannon, D. E. Clay & N. R. Kitchen (dir.), *Precision Agriculture Basics*. <https://doi.org/10.2134/precisionagbasics>.
- Shi, Y., Thomasson, J. A., Murray, S. C., Pugh, N. A., Rooney, W. L., Shafian, S., . . . Yang, C. (2016). Unmanned Aerial Vehicles for High-Throughput Phenotyping and Agronomic Research. *PLoS ONE*, 11(7), e0159781. <https://doi.org/10.1371/journal.pone.0159781>
- Simic Milas, A., Romanko, M., Reil, P., Abeyasinghe, T. et Marambe, A. (2018). The importance of leaf area index in mapping chlorophyll content of corn under different agricultural treatments using UAV images. *International Journal of Remote Sensing*, 39(15-16), 5415-5431. <https://doi.org/10.1080/01431161.2018.1455244>
- Spectrum Technologies. (2009). SPAD 502 Plus Chlorophyll Meter. Product Manual. https://www.specmeters.com/assets/1/22/2900P_SPAD_502.pdf
- Suzuki, Y., Okamoto, H. et Kataoka, T. (2008). Image Segmentation between Crop and Weed using Hyperspectral Imaging for Weed Detection in Soybean Field. *Environmental Control in Biology*, 46(3), 163-173. <https://doi.org/10.2525/ecb.46.163>
- Tahir, M. N., Li, J., Liu, B., Zhao, G., Fuqi, Y. et Chengfeng, C. (2013). Hyperspectral estimation model for nitrogen contents of summer corn leaves under rainfed conditions. *Pakistan Journal of Botany*, 45(5), 1623-1630.
- Tahtirvanci, A. et Durdu, A. (2018). *Performance Analysis of Image Mosaicing Methods for Unmanned Aerial Vehicles*. Communication présentée 2018 10th International Conference on Electronics, Computers and Artificial Intelligence (ECAI), Iasi, Roumanie. <https://doi.org/10.1109/ECAI.2018.8679007>

- Tan, C.-W., Zhang, P.-P., Zhou, X.-X., Wang, Z.-X., Xu, Z.-Q., Mao, W., . . . Yun, F. (2020). Quantitative monitoring of leaf area index in wheat of different plant types by integrating NDVI and Beer-Lambert law. *Scientific Reports*, 10(1), 929. <https://doi.org/10.1038/s41598-020-57750-z>
- Tattaris, M., Reynolds, M. P. et Chapman, S. C. (2016). A Direct Comparison of Remote Sensing Approaches for High-Throughput Phenotyping in Plant Breeding. *Frontiers in Plant Science*, 7(1131). <https://doi.org/10.3389/fpls.2016.01131>
- Teal, R. K., Raun, W. R., Solie, J. B., Stone, M. L., Freeman, K. W., Johnson, G. V. et Martin, K. L. (2004). *By-Plant Precision Sensing for Variable Nitrogen Rate Application in Corn*. Communication présentée Precision Agriculture Conference, St Paul, Minnesota. http://nue.okstate.edu/Index_Publications.htm
- Tilly, N., Aasen, H. et Bareth, G. (2015). Fusion of Plant Height and Vegetation Indices for the Estimation of Barley Biomass. *Remote Sensing*, 7(9). <https://doi.org/10.3390/rs70911449>
- Tilly, N. et Bareth, G. (2019). Estimating Nitrogen from Structural Crop Traits at Field Scale—A Novel Approach Versus Spectral Vegetation Indices. *Remote Sensing*, 11(17). <https://doi.org/10.3390/rs11172066>
- Torres-Sánchez, J., López-Granados, F., Borra-Serrano, I. et Peña, J. M. (2018). Assessing UAV-collected image overlap influence on computation time and digital surface model accuracy in olive orchards. *Precision Agriculture*, 19(1), 115-133. <https://doi.org/10.1007/s11119-017-9502-0>
- Torres-Sánchez, J., Peña, J. M., de Castro, A. I. et López-Granados, F. (2014). Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV. *Computers and Electronics in Agriculture*, 103(0), 104-113. <https://doi.org/10.1016/j.compag.2014.02.009>
- Tremblay, G. (2018). Le choix de ses hybrides de maïs-grain. *Gestion et Technologie Agricoles*, 43, 43. <https://issuu.com/dbccommunications/docs/2018-08-23-gta>
- Tremblay, N. (2004). Determining nitrogen requirements from crops characteristics. Benefits and challenges. *Recent Res. Devel. Agronomy & Horticulture*, 1, 157-182.
- Tremblay, N., Bouroubi, Y. M., Bélec, C., Mullen, R. W., Kitchen, N. R., Thomason, W. E., . . . Ortiz-Monasterio, I. (2012). Corn Response to Nitrogen is Influenced by Soil Texture and Weather. *Agronomy Journal*, 104(6). <https://doi.org/10.2134/agronj2012.0184>
- Tremblay, N., Vigneault, P., Bélec, C., Fallon, E. et Bouroubi, M. Y. (2014). *A Comparison Of Performance Between UAV And Satellite Imagery For N Status Assessment In Corn*. Communication présentée 12th International Conference on Precision Agriculture, Sacramento, CA.
- Tremblay, N., Vigneault, P., Haboudane, D. et Miller, J. (2003). *Corn OSAVI as related to soil electrical conductivity and nitrogen fertilization rates*. Communication présentée Geoscience and Remote Sensing Symposium, 2003. IGARSS '03. Proceedings. 2003 IEEE International. <https://doi.org/10.1109/IGARSS.2003.1294398>
- Tremblay, N., Wang, Z., Ma, B. L., Bélec, C. et Vigneault, P. (2008). A comparison of crop data measured by two commercial sensors for variable-rate nitrogen application. *Precision Agriculture*, 10(2), 145-161.
- Tumbo, S. D., Salyani, M., Miller, W. M., Sweeb, R. et Buchanon, S. (2007). Evaluation of a variable rate controller for aldicarb application around buffer zones in citrus groves.

- Computers and Electronics in Agriculture*, 56(2), 147-160.
<https://doi.org/https://doi.org/10.1016/j.compag.2007.01.010>
- Ullman, S. (1979). The Interpretation of Structure from Motion. *Proceedings of the Royal Society of London. Series B, Biological Sciences*, 203(1153), 405-426.
- Upton, G. et Cook, I. (2014). Proxy variable (*A Dictionary of Statistics* (2 rev. ed.° éd.): Oxford University Press.
- Varela, S., Dhodda, P. R., Hsu, W. H., Prasad, P. V. V., Assefa, Y., Peralta, N. R., . . . Ciampitti, I. A. (2018). Early-season stand count determination in Corn via integration of imagery from unmanned aerial systems (UAS) and supervised learning techniques. *Remote Sensing*, 10(2). <https://doi.org/10.3390/rs10020343>
- Verhoef, W. (1984). Light scattering by leaf layers with application to canopy reflectance modelling: The SAIL model. *Remote Sensing of Environment*, 16(1), 125-161.
- Vigneau, N., Ecartot, M., Rabatel, G. et Roumet, P. (2011). Potential of field hyperspectral imaging as a non destructive method to assess leaf nitrogen content in Wheat. *Field Crops Research*, 122(1), 25-31. <https://doi.org/10.1016/j.fcr.2011.02.003>
- Woebbecke, D. M., Meyer, G. E., Von Bargen, K. et Mortensen, D. A. (1995). Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE*, 38(1), 259-269.
- Xing, C., Wang, J. et Xu, Y. (2010). *Overlap Analysis of the Images from Unmanned Aerial Vehicles*. Communication présentée 2010 International Conference on Electrical and Control Engineering.
- Yu, Z., Cao, Z., Wu, X., Bai, X., Qin, Y., Zhuo, W., . . . Xue, H. (2013). Automatic image-based detection technology for two critical growth stages of maize: Emergence and three-leaf stage. *Agricultural and Forest Meteorology*, 174-175, 65-84.
<https://doi.org/doi.org/10.1016/j.agrformet.2013.02.011>
- Yue, J., Yang, G., Tian, Q., Feng, H., Xu, K. et Zhou, C. (2019). Estimate of winter-wheat above-ground biomass based on UAV ultrahigh-ground-resolution image textures and vegetation indices. *ISPRS Journal of Photogrammetry and Remote Sensing*, 150, 226-244. <https://doi.org/https://doi.org/10.1016/j.isprsjprs.2019.02.022>
- Yun, H., Kim, H. J., Park, K. D., Lee, K. D. et Hong, S. Y. (2015). *Use of an UAV for biomass monitoring of hairy vetch*.
- Zhang, C. et Kovacs, J. M. (2012). The application of small unmanned aerial systems for precision agriculture: A review. *Precision Agriculture*, 13(6), 693-712.
<https://doi.org/10.1007/s11119-012-9274-5>
- Zhang, W., Guo, B., Li, M., Liao, X. et Li, W. (2018). Improved Seam-Line Searching Algorithm for UAV Image Mosaic with Optical Flow. *Sensors (Basel, Switzerland)*, 18(4), 1214. <https://doi.org/10.3390/s18041214>
- Zhang, X., Yan, G., Li, Q., Li, Z. L., Wan, H. et Guo, Z. (2006). Evaluating the fraction of vegetation cover based on NDVI spatial scale correction model. *International Journal of Remote Sensing*, 27(24), 5359-5372. <https://doi.org/10.1080/01431160600658107>
- Zhang, Y., Su, Z., Shen, W., Jia, R. et Luan, J. (2016). Remote monitoring of heading rice growing and nitrogen content based on UAV images. *International Journal of Smart Home*, 10(7), 103-114. <https://doi.org/10.14257/ijsh.2016.10.7.11>

- Zhou, L., Gu, X., Cheng, S., Yang, G., Shu, M. et Sun, Q. (2020). Analysis of Plant Height Changes of Lodged Maize Using UAV-LiDAR Data. *Agriculture*, 10(5). <https://doi.org/10.3390/agriculture10050146>
- Zhu, J., Tremblay, N. et Liang, Y. (2012). Comparing SPAD and atLEAF values for chlorophyll assessment in crop species. *Canadian Journal of Soil Science*, 92(4), 645-648. <https://doi.org/10.4141/cjss2011-100>
- Zhu, X. et Liu, D. (2015). Improving forest aboveground biomass estimation using seasonal Landsat NDVI time-series. *ISPRS Journal of Photogrammetry and Remote Sensing*, 102, 222-231. <https://doi.org/https://doi.org/10.1016/j.isprsjprs.2014.08.014>
- Ziglado, J. P., Holden, C. L., Schrader, M. E. et Vogel, R. M. (2001). Electronic color infrared camera. <https://patents.google.com/patent/US6292212B1/en>
- Zwaenepoel, P. et Le Bars, J. M. (1997). L'agriculture de précision. *Ingénieries - E A T*(12), p. 67 - p. 79.

Annexe A. Calculer le NDVI moyen

Dans une image à très haute résolution, une zone d'échantillonnage contient généralement plusieurs dizaines voire centaines de pixels. Lorsqu'il faut calculer l'indice de végétation NDVI moyen à l'intérieur de cette zone, il existe deux façons de le calculer : à travers les réflectances moyennes ou en moyennant directement les valeurs de NDVI.

1) $NDVI_{ref}$

Cette première façon de calculer consiste d'abord à moyennner les valeurs de réflectance de tous les N pixels à l'intérieur de la zone :

- réflectance moyenne pour le rouge : $\overline{\rho_R} = \frac{\sum_{k=1}^N \rho_{Rk}}{N}$, où ρ_{Rk} est la réflectance du pixel k dans la bande rouge;
- réflectance moyenne pour le PIR : $\overline{\rho_{NIR}} = \frac{\sum_{k=1}^N \rho_{NIRk}}{N}$, où ρ_{NIRk} est la réflectance du pixel k dans la bande PIR.

Puis le NDVI est calculé selon sa formule habituelle :

$$NDVI_{ref} = \frac{\overline{\rho_{NIR}} - \overline{\rho_R}}{\overline{\rho_{NIR}} + \overline{\rho_R}} \quad (A.1)$$

2) $NDVI_{mean}$

Cette deuxième façon de calculer consiste d'abord à calculer les valeurs de NDVI pour chacun des N pixels de la zone d'échantillonnage :

$$NDVI_k = \frac{\rho_{NIRk} - \rho_{Rk}}{\rho_{NIRk} + \rho_{Rk}}, k = 1..N \quad (A.2)$$

Puis le NDVI est pris comme la moyenne de tous les NDVI individuels :

$$NDVI_{mean} = \sum_{k=1}^N NDVI_k \quad (A.3)$$

Puisque le NDVI se calcule comme un ratio, il n'y a aucune raison de croire que les deux façons de calculer produisent des valeurs identiques. Pour l'illustrer, nous allons partir d'exemples concrets.

Pour un pixel donné, la Figure A.1 montre les valeurs possibles de NDVI selon les valeurs de réflectance dans la bande rouge (ρ_R) et dans la bande proche-infrarouge (ρ_{NIR}).

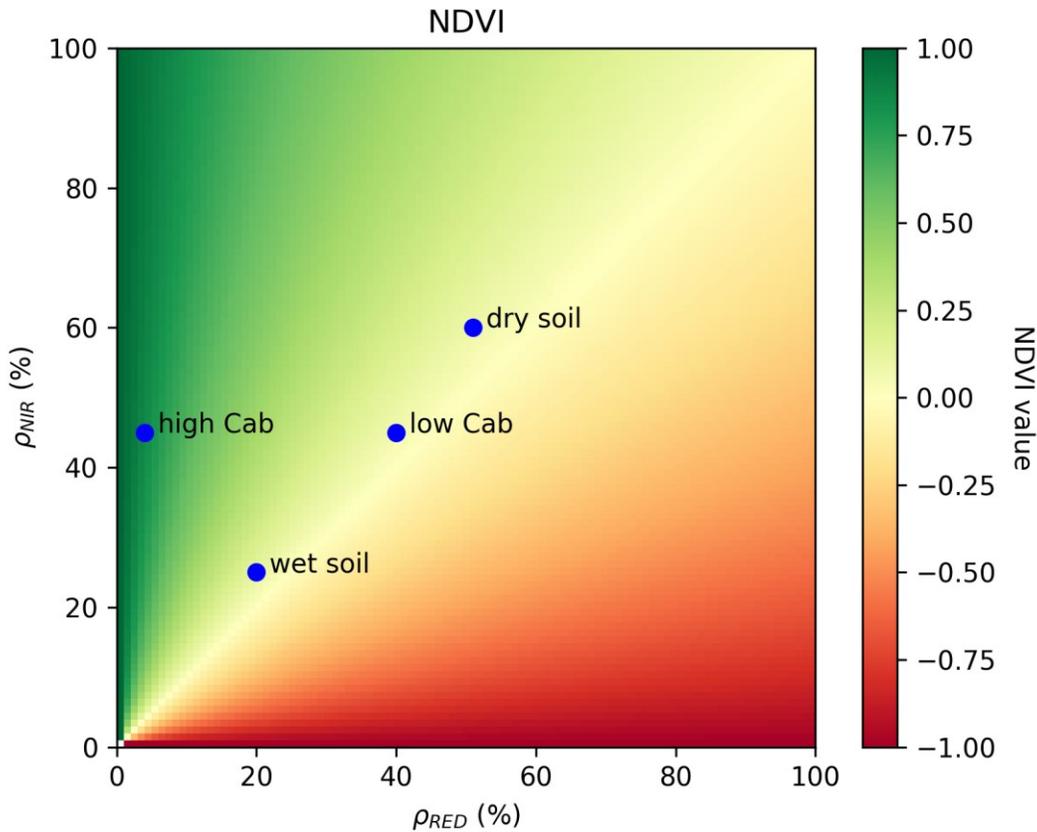


Figure A.1 – Valeurs de NDVI en fonction des valeurs de réflectance dans le rouge (ρ_R) et dans le proche infrarouge (ρ_{NIR}), avec quelques exemples de cibles traditionnelles : maïs avec peu de chlorophylle (low Cab) et beaucoup de chlorophylle (high Cab) ; sol sec (dry soil) et sol mouillé (wet soil).

Dans la Figure A.1, on situe également les valeurs de NDVI de quelques pixels purs : végétation (maïs avec peu ou beaucoup de chlorophylle) et sol (sec ou mouillé).

Pour simplifier les choses, supposons que chaque zone d'échantillonnage contient un nombre N de pixels, chaque pixel étant pur – soit végétation, soit sol. Supposons également que tous les pixels de même classe présentent les mêmes caractéristiques de réflectance : même valeur de réflectance dans la bande rouge et même valeur de réflectance dans la bande PIR. Ainsi la valeur de NDVI pour la zone d'échantillonnage ne dépendra que de la proportion de pixels végétation par rapport au nombre total de pixels dans la zone. Ce ratio de végétation se calcule :

$$r_{veg} = \frac{N_{pixels_veg}}{N} = 1 - r_{sol} \quad (4)$$

où $r_{sol} = \frac{N_{pixels_sol}}{N}$ est le ratio de sol (proportion de pixels sol par rapport au nombre total de pixels).

Les graphiques de la Figure A.2 montrent ainsi quelques combinaisons de sol et de végétation (mixels) : végétation pauvre en chlorophylle sur du sol sec ou humide, puis végétation riche en chlorophylle sur du sol sec ou humide. En faisant varier le ratio de végétation, on peut voir si les deux façons de calculer le NDVI moyen engendrent des valeurs proches ou éloignées.

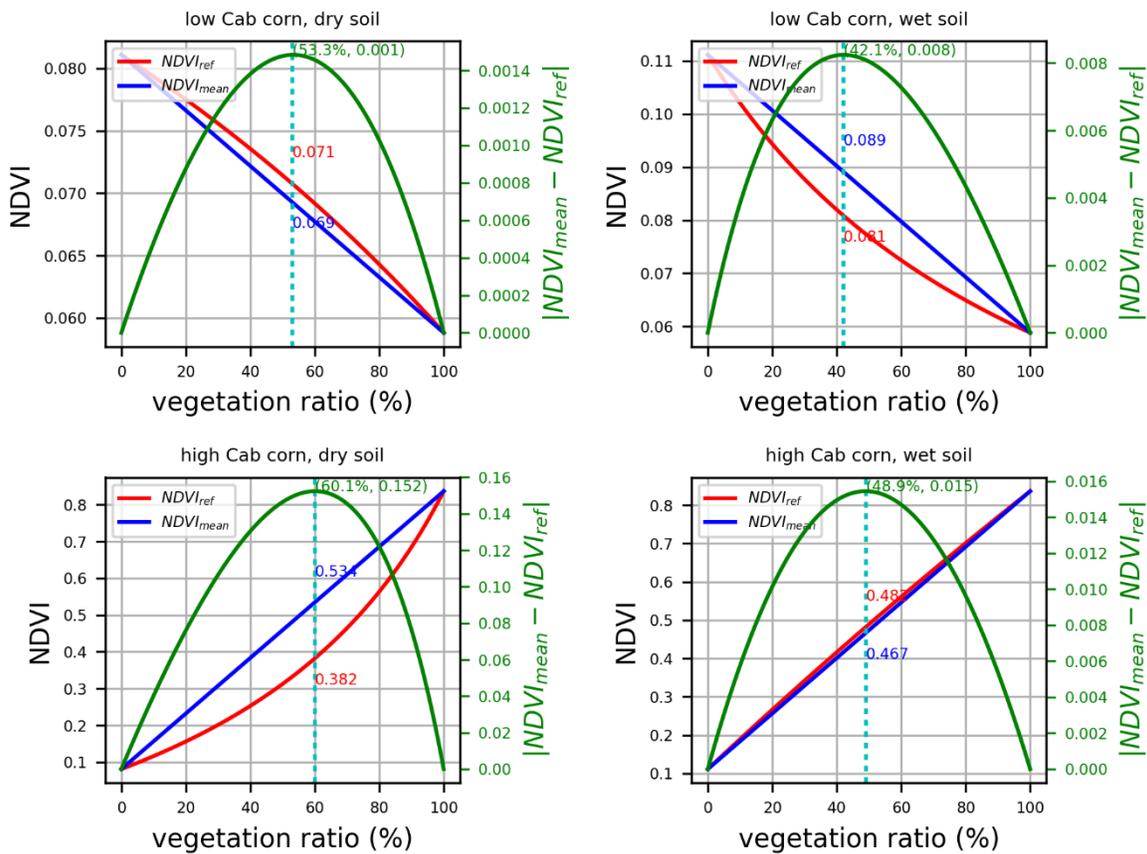


Figure A.2 – Comparaison des valeurs de NDVI moyen selon la façon de les calculer. NDVI_{ref} est calculé à partir des moyennes de réflectance dans chaque zone d'échantillonnage, tandis que NDVI_{mean} est la moyenne des valeurs de NDVI calculées à partir de la réflectance individuelle des pixels.

On constate que les deux façons de calculer le NDVI produisent généralement des valeurs proches ($|NDVI_{mean} - NDVI_{ref}| < 0,01$) sauf pour la situation où la végétation contient beaucoup de chlorophylle et que le sol est sec – ce qui est souvent le cas pour un champ de maïs.

Dans ce cas-là, les deux NDVI se distinguent nettement et produisent un écart maximal lorsque la végétation représente 60% du mixel ($|NDVI_{mean} - NDVI_{ref}| = 0,15$). Dans l'utilisation de cet indice, il faut donc garder à l'esprit la manière dont le NDVI moyen a été obtenu.

Annexe B. Tableaux et figures

Tableau B.1 – Mesures des plants échantillonnés lors de l'expérience en serre, printemps 2017.

Date des mesures	Plant échantillonné	Date de semis	Jours après semis	Hauteur (cm)	Surface totale des feuilles (cm ²)	PLANT		TIGE		FEUILLAGE		Longueur de la plus grande feuille (cm)	Stade V
						Poids frais (g)	Poids sec (g)	Poids frais (g)	Poids sec (g)	Poids frais (g)	Poids sec (g)		
2017-04-14	20170310_11	2017-03-10	35	47	2187.6	129.16	41.45	68.30	34.40	60.86	7.05	97	6
2017-04-14	20170317_5	2017-03-17	28	47	1313.7	81.83	6.86	41.80	2.50	40.03	4.36	81	6
2017-04-14	20170324_1	2017-03-24	21	28	311.4	15.30	1.17	7.50	0.43	7.80	0.74	44	7.5
2017-04-14	20170331_3	2017-03-31	14	10	46.8	1.65	0.13	0.65	0.04	1.00	0.09	21	4
2017-04-21	20170317_7	2017-03-17	35	71.5	3331.7	224.82	85.69	144.00	74.90	80.82	10.79	102	5
2017-04-21	20170324_2	2017-03-24	28	32	734.9	32.01	5.48	13.75	3.91	18.26	1.57	69	6
2017-04-21	20170331_1	2017-03-31	21	25	381.9	17.61	2.68	8.10	1.89	9.51	0.80	50.5	4
2017-04-21	20170407_28	2017-04-07	14	15	74.4	2.87	0.21	1.32	0.07	1.55	0.14	23.5	4
2017-04-21	20170407_3	2017-04-07	14	15	63.4	2.30	0.20	1.08	0.06	1.22	0.14	26	3
2017-04-21	20170407_4	2017-04-07	14	14.5	72.6	2.39	0.20	0.97	0.06	1.42	0.14	18	7
2017-04-21	20170407_7	2017-04-07	14	14	62.7	1.98	0.16	0.81	0.05	1.17	0.11	27	4
2017-04-21	20170407_8	2017-04-07	14	15	88.0	3.16	0.26	1.33	0.08	1.82	0.17	27.5	7
2017-04-28	20170324_3	2017-03-24	35	57	2721.8	165.65	17.76	90.30	7.10	75.35	10.66	100	6
2017-04-28	20170331_2	2017-03-31	28	39	1192.6	62.57	6.15	30.30	2.50	32.27	3.65	80	7
2017-04-28	20170407_1	2017-04-07	21	23.5	318.2	12.44	1.03	5.80	0.30	6.64	0.73	52	7
2017-04-28	20170407_2	2017-04-07	21	25	388.0	16.04	1.47	7.50	0.50	8.54	0.97	53.5	5.5
2017-04-28	20170407_31	2017-04-07	21	26	481.6	23.13	1.82	10.40	0.50	12.73	1.32	60.5	6
2017-04-28	20170407_5	2017-04-07	21	25	334.5	13.07	1.24	6.00	0.40	7.07	0.84	51.5	4
2017-04-28	20170407_6	2017-04-07	21	28	521.2	22.18	1.74	10.18	0.60	12.00	1.14	65	6
2017-04-28	20170414_1	2017-04-14	14	11.5	69.7	1.99	0.20	0.70	0.05	1.29	0.15	25.5	3
2017-05-05	20170331_4	2017-03-31	35	71	2753.0	179.22	33.74	109.80	23.70	69.42	10.04	98	7
2017-05-05	20170407_14	2017-04-07	28	50	1064.1	54.38	5.65	27.70	2.20	26.68	3.45	80	3
2017-05-05	20170407_15	2017-04-07	28	45	1174.0	66.24	6.91	33.90	2.70	32.34	4.21	79	5.5
2017-05-05	20170407_20	2017-04-07	28	49	1406.5	69.17	7.26	33.70	2.40	35.47	4.86	76	4
2017-05-05	20170407_30	2017-04-07	28	44	1032.0	53.40	5.62	26.30	2.50	27.10	3.12	80	2
2017-05-05	20170407_9	2017-04-07	28	44	1367.3	65.95	6.26	32.60	2.00	33.35	4.26	80	4
2017-05-05	20170414_2	2017-04-14	21	23	166.8	5.12	0.50	2.10	0.16	3.02	0.35	38	4
2017-05-05	20170421_3	2017-04-21	14	12	59.4	1.59	0.15	0.60	0.04	0.99	0.11	24	2
2017-05-12	20170407_10	2017-04-07	35	81	3218.2	184.98	19.68	112.00	8.70	72.98	10.98	106	3
2017-05-12	20170407_11	2017-04-07	35	65	2568.0	152.15	14.76	90.00	5.80	62.15	8.96	97.5	6
2017-05-12	20170407_12	2017-04-07	35	72.5	2928.9	155.43	15.74	89.90	6.20	65.53	9.54	98	2
2017-05-12	20170407_13	2017-04-07	35	71.5	2898.7	159.44	18.29	91.60	8.30	67.84	9.99	101	3
2017-05-12	20170407_29	2017-04-07	35	73.5	3459.4	199.66	33.64	121.70	23.50	77.96	10.14	101.5	4
2017-05-12	20170414_3	2017-04-14	28	28	265.5	8.73	0.87	3.68	0.26	5.05	0.62	50	3
2017-05-12	20170421_1	2017-04-21	21	21.5	148.5	5.08	0.48	2.22	0.15	2.87	0.32	43	3
2017-05-12	20170428_1	2017-04-28	14	21.5	54.3	1.55	0.13	0.54	0.03	1.01	0.10	22	2

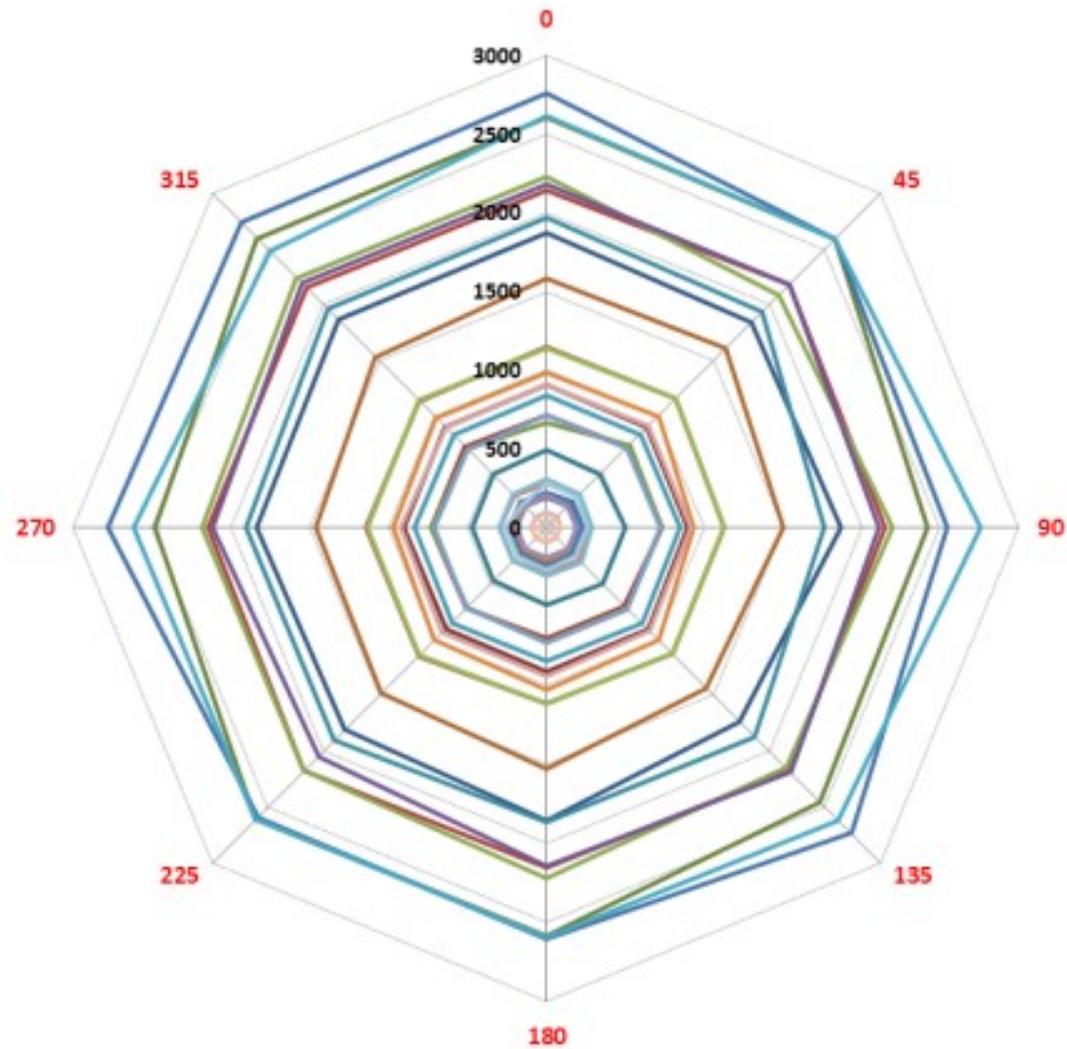


Figure B.1 – Diagramme en radar représentant la surface foliaire apparente (coordonnée radiale, en cm²) en fonction de l’angle azimutal θ (coordonnée angulaire, en degrés), pour un angle de visée $\alpha=0^\circ$ (expérience en serre, printemps 2017). Chaque couleur représente une plante différente.

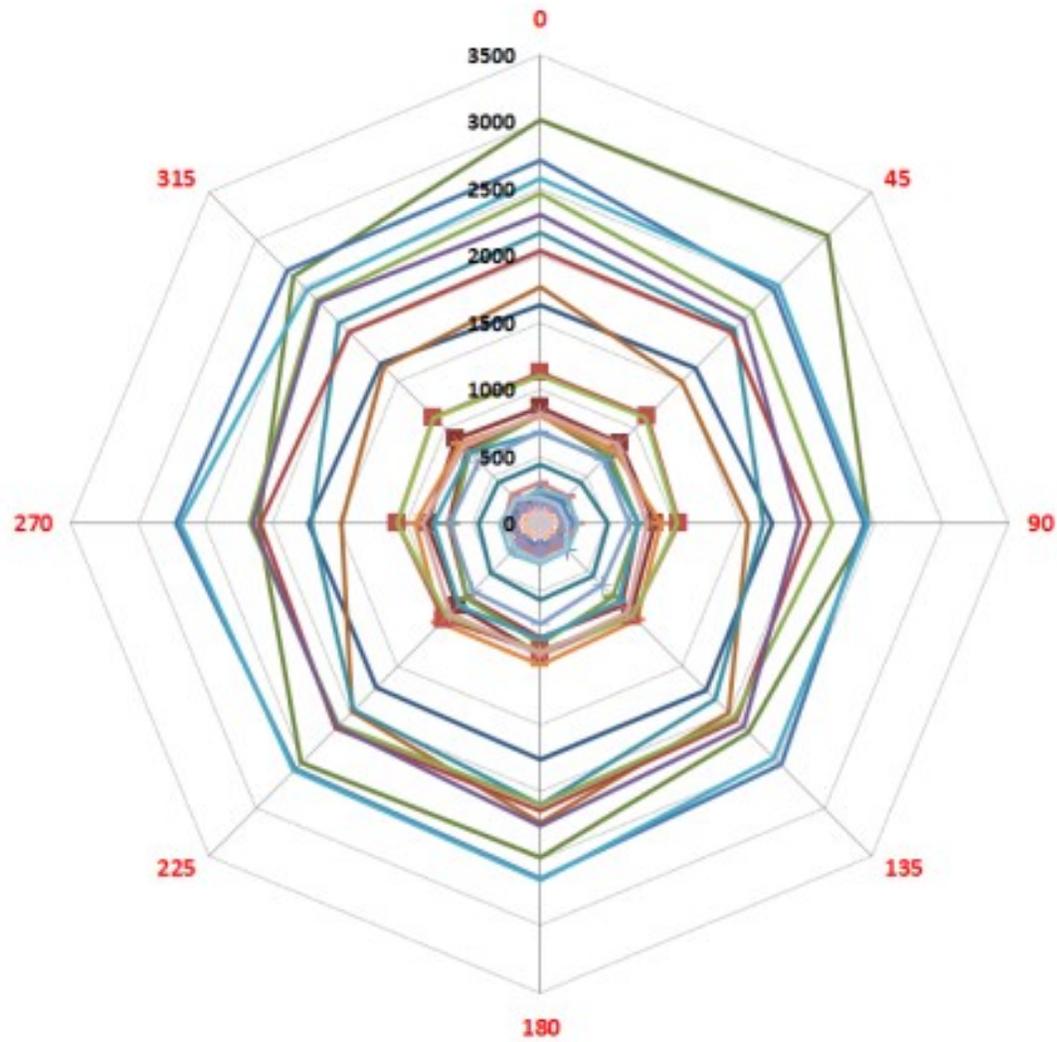


Figure B.2 – Diagramme en radar représentant la surface foliaire apparente (coordonnée radiale, en cm²) en fonction de l’angle azimutal θ (coordonnée angulaire, en degrés), pour un angle de visée $\alpha=15^\circ$ (expérience en serre, printemps 2017). Chaque couleur représente une plante différente.

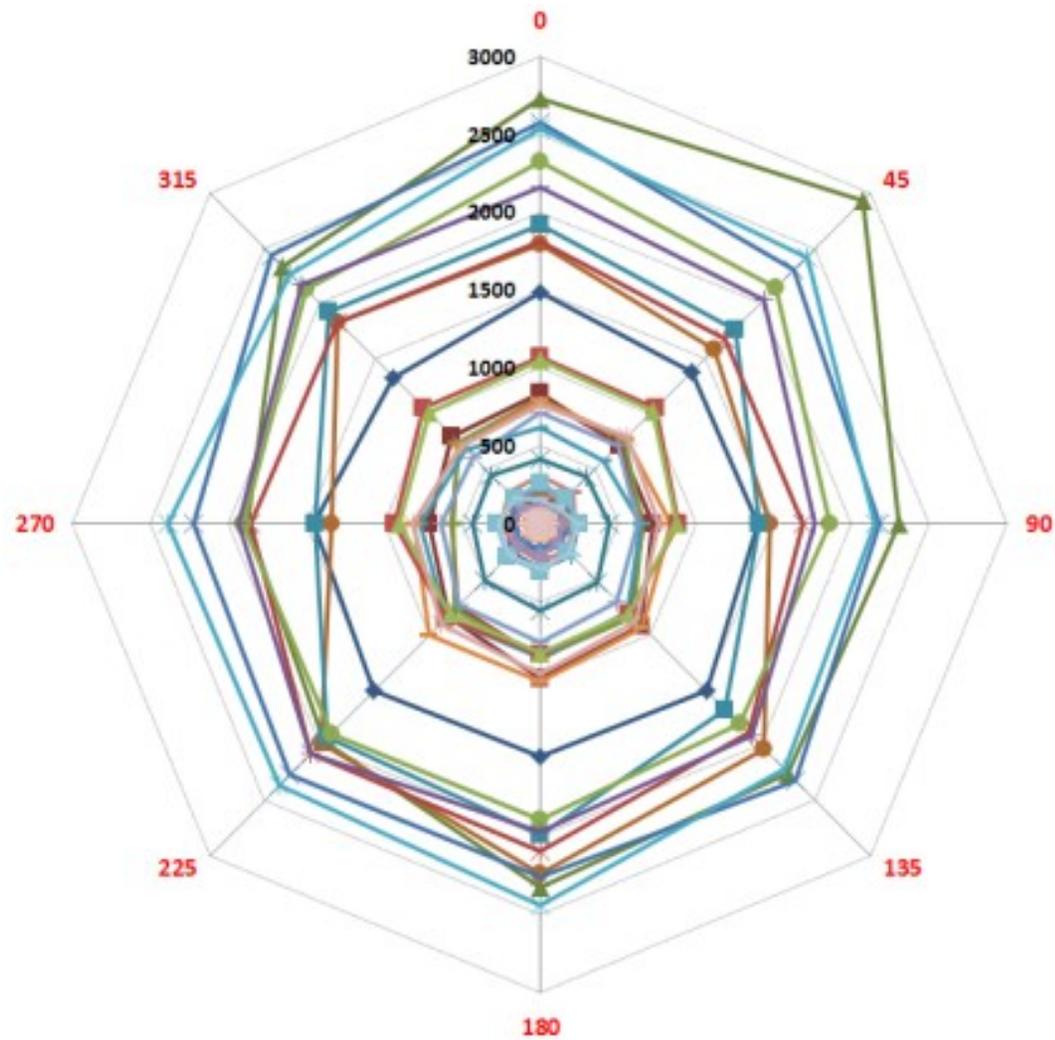


Figure B.3 – Diagramme en radar représentant la surface foliaire apparente (coordonnée radiale, en cm^2) en fonction de l'angle azimutal θ (coordonnée angulaire, en degrés), pour un angle de visée $\alpha=30^\circ$ (expérience en serre, printemps 2017). Chaque couleur représente une plante différente.

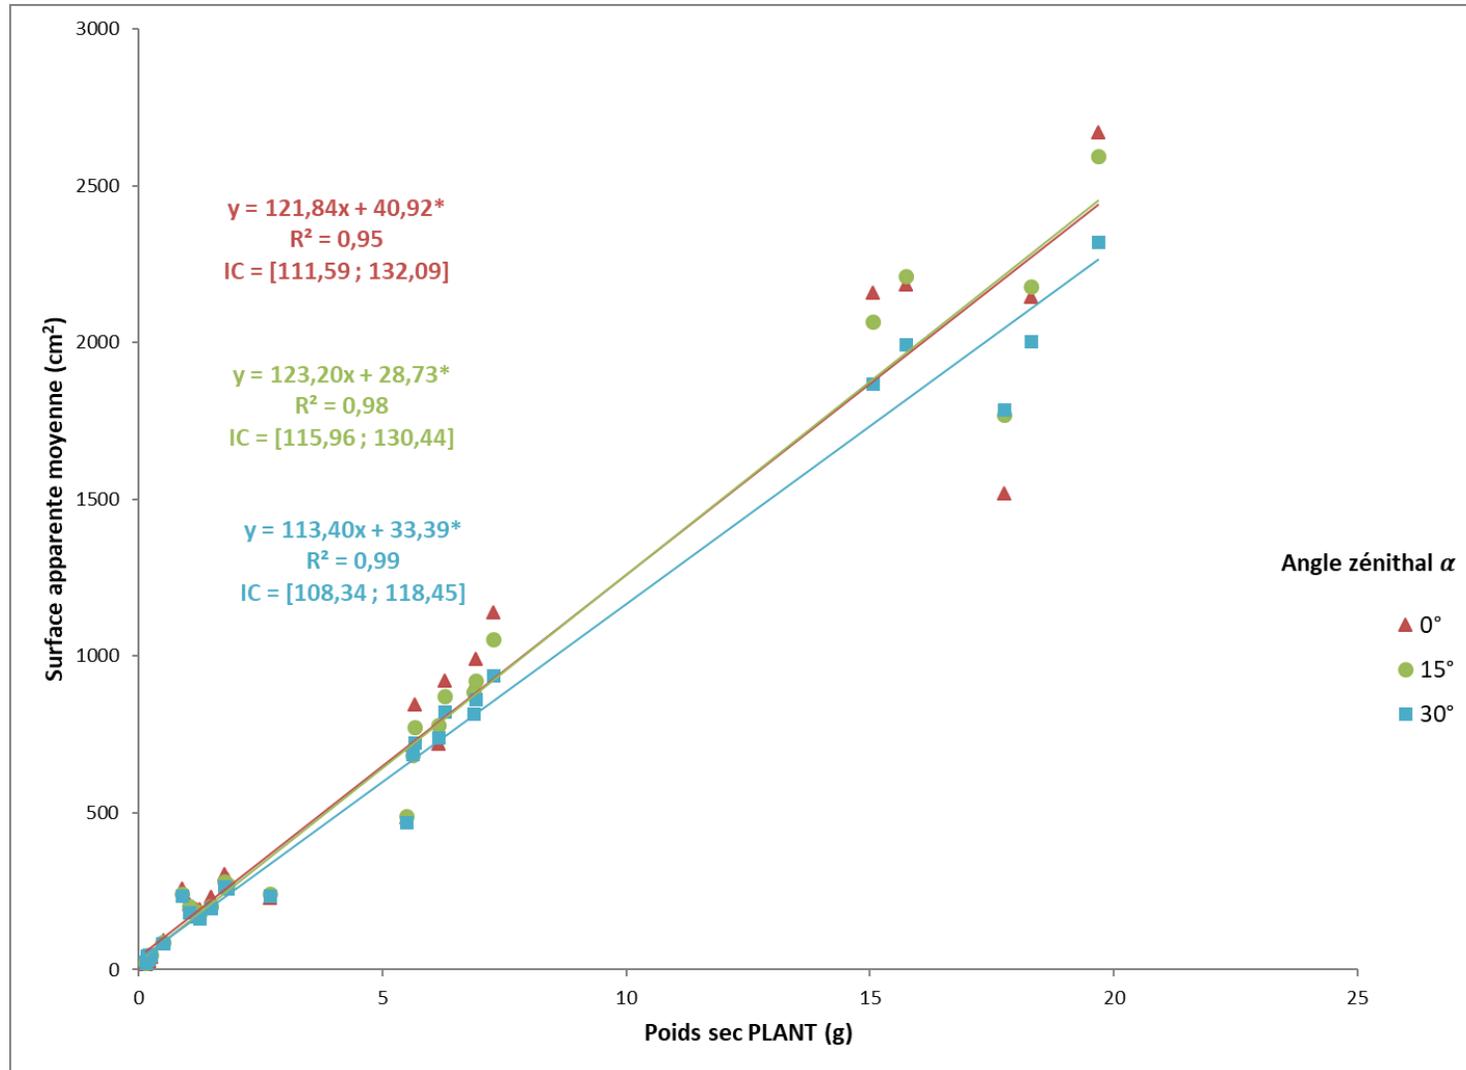


Figure B.4 – Relation entre surface apparente et poids sec du plant de maïs, en fonction de l'angle zénithal α . Seuls les plants dont le poids sec est inférieur à 30 g sont considérés (N=32). IC représente l'intervalle de confiance à 95% pour la pente. *Ordonnée à l'origine non significative. Pour les 3 équations de régression, les intervalles de confiance à 95% des 3 pentes se chevauchent.