

Modéliser la hauteur, biomasse et composition floristique des prairies : comparaison de données LiDAR, photogrammétriques et spectrales acquises par différents drones.

Julien Philippart

TRAVAIL DE FIN D'ÉTUDES PRÉSENTÉ EN VUE DE L'OBTENTION
DU DIPLÔME DE MASTER BIOINGÉNIEUR
EN SCIENCES AGRONOMIQUES

Année académique 2023-2024

CO-PROMOTEURS : Jean-François Bastin ; Jérôme Bindelle

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

Le présent document n'engage que son auteur.

Modéliser la hauteur, biomasse et composition floristique des prairies : comparaison de données LiDAR, photogrammétriques et spectrales acquises par différents drones.

Julien Philippart

TRAVAIL DE FIN D'ÉTUDES PRÉSENTÉ EN VUE DE L'OBTENTION
DU DIPLÔME DE MASTER BIOINGÉNIEUR
EN SCIENCES AGRONOMIQUES

Année académique 2023-2024

CO-PROMOTEURS : Jean-François Bastin ; Jérôme Bindelle

Remerciements

Arrivé à la fin de ce travail, il est temps pour moi d'écrire ces quelques lignes visant à remercier les différentes personnes sans lesquelles ce travail n'aurait pas été possible.

J'aimerais tout d'abord remercier mes deux co-promoteurs au sein de la Faculté de Gembloux Agro-Bio Tech, le Professeur Jérôme Bindelle de l'axe Animal Science pour ses connaissances liées aux écosystèmes pâturés et Jean-François Bastin, chargé de cours dans l'axe Biodiversité, Ecosystèmes et Paysages pour son expertise en télédétection. Leur investissement permanent, leurs conseils, ainsi que la mise à disposition de l'ensemble du matériel dont j'ai pu avoir besoin m'ont permis de réaliser ce TFE dans un environnement idéal et propice au travail. Je tiens aussi à remercier Hugo De Lame et Antoine Plumacker, doctorants de M. Bastin, pour l'initiation à l'utilisation des drones et des différents logiciels, mais aussi pour les réponses à mes nombreuses questions quotidiennes tout au long de ces derniers mois. Merci aussi à Cédric Geerts pour le prêt de matériel et l'initiation à l'utilisation du Reach RTK, à Adrien Michez pour la réunion visant à m'aider à résoudre mes problèmes de calibration, à François Debande pour son aide dans la logistique de mise en place de l'expérimentation et au CRA-W pour m'avoir permis de prendre des données de validation sur une de leur prairie. Enfin, je tiens à remercier mes différents relecteurs qui m'ont permis d'éviter de nombreuses fautes d'inattention et d'ainsi améliorer la forme de ce travail écrit.

A titre personnel, j'aimerais aussi exprimer ma reconnaissance à tous mes amis, proches et tous ceux dont j'ai pu croiser la route un jour ou l'autre et qui ont fait de mon expérience à Gembloux un moment vécu à 100 % et partagé. Enfin, merci à mes parents de m'avoir toujours laissé énormément de liberté dans mes prises de décisions et de m'avoir toujours soutenu dans tout ce que j'entreprenais.

Abstract

Grasslands are fundamental ecosystems whose management can require time-consuming measurements. In this context, remote sensing using Unmanned Aerial Vehicles (UAVs) can provide a variety of high-resolution photogrammetric (3D), spectral and LiDAR information in a short time. Combined within predictive models, this information can be used to spatially estimate variables of interest in grassland, such as sward height, biomass and botanical composition. Nowadays, these technologies are evolving and becoming more widely available, but the models developed remain highly specific to their calibration environment. The aim of this work was to develop robust models by applying good practices identified in the literature, and to compare the performance of different equipment ranging from low-cost to top-of-the-range. For this purpose, ground reference and aerial data were taken at two dates on a pasture. Numerous models were compared, depending on the equipment used, the DTM source exploited, and the type of model developed. Their performance was assessed using an independent dataset. Concerning good practices, geometric correction using GCPs, even with on-board RTK, radiometric calibration and diversification of the dataset have led to partial transferability of certain types of models, such as RF and PCR. This work also highlighted a similar sward height estimation performance from LiDAR and photogrammetry of mid- and top-of-the range sensors ($RMSE_{LiDAR} = 0.0824$ m; $RMSE_{SIM} = 0.0902$ m). This performance wasn't achieved by "low-cost" equipment. Despite better performances of some models in estimating biomass ($RMSE_{PCR} = 932$ kgDM/ha), none reached the performance of the rising plate meter (RPM) ($RMSE_{RPM} = 770$ kgDM/ha), equipment commonly used by farmers. In terms of botanical composition, the "low-cost" also performed less well than the more expensive equipment, some of whose classifiers correctly distinguished grasses from the rest of the vegetation ($KAPPA_{PLS-DA} = 0.75$). In conclusion, despite the modest performances of the models developed here, which could certainly be improved by optimizing certain aspects of the workflow, this work has demonstrated the ability to obtain robust models suitable on an independent grassland with affordable mid-range equipment.

Keywords

Grassland, UAV, photogrammetry, LiDAR, low-cost, sward height, biomass, botanical composition, direct RTK-referencing, Digital Terrain Model, robustness, Machine Learning.

Résumé

Les prairies sont des écosystèmes fondamentaux dont la gestion peut exiger des prises de mesures chronophages. Dans cette optique, la télédétection par drone permet d'obtenir diverses informations photogrammétriques (3D), spectrales ou encore LiDAR à haute résolution, en un temps réduit. Ces dernières, combinées dans des modèles prédictifs, permettent d'estimer spatialement des variables d'intérêt sur les prairies telles que la hauteur du couvert, la biomasse ou encore la composition floristique. A l'heure actuelle, ces technologies évoluent et se démocratisent mais les modèles développés demeurent très spécifiques à leur environnement de calibration. L'objectif de ce travail était de développer des modèles robustes via l'application des bonnes pratiques recensées dans la littérature et de comparer les performances de différents équipements allant du « *low-cost* » au haut de gamme. Pour ce faire, des données de référence au sol et des données aériennes ont été prises à deux dates sur une prairie. De nombreux modèles ont été comparés selon le matériel employé, la source de MNT utilisée et le type de modèle développé. Leurs performances ont été évaluées grâce à un jeu de données indépendant. En termes de bonnes pratiques, une correction géométrique via des GCP, et ce même en cas de module RTK embarqué, une calibration radiométrique ainsi qu'une diversification du jeu de données ont permis d'obtenir une transférabilité partielle de certains types de modèles tels que des RF et des PCR. Ce travail a aussi permis de conclure à des performances similaires d'estimation de la hauteur de la part du LiDAR et de la photogrammétrie avec certains capteurs de milieu et haut de gamme ($RMSE_{LiDAR} = 0,0824$ m ; $RMSE_{SIM} = 0,0902$ m), que le matériel « *low-cost* » n'a pas réussi à atteindre. Malgré de meilleures performances de certains modèles dans l'estimation de la biomasse ($RMSE_{PCR} = 932$ kgMS/ha), aucun n'a tout de même atteint les performances de l'herbomètre ($RMSE_{HERBO} = 770$ kgMS/ha), matériel couramment utilisé par les praticiens. En termes de composition floristique, le « *low-cost* » a aussi présenté des performances inférieures au matériel plus onéreux, dont certains classificateurs distinguaient de façon satisfaisante les graminées du reste de la végétation ($KAPPA_{PLS-DA} = 0,75$). En conclusion, malgré les performances modestes des modèles développés, qui pourraient être améliorées de façon certaine en optimisant certains aspects du flux de traitement, ce travail a démontré qu'il était possible d'obtenir des modèles robustes, utilisables sur une prairie indépendante, et ce, avec du matériel de milieu de gamme, accessible financièrement.

Mots-clés

Prairie, drone, photogrammétrie, LiDAR, *low-cost*, hauteur d'herbe, biomasse, composition floristique, géoréférencement RTK, Modèle Numérique de Terrain, robustesse, *Machine Learning*.

Table des matières

Table des matières	IV
Table des figures	VI
Table des tableaux	VII
Liste des abréviations	VIII
1. Introduction	1
1.1. Ecosystèmes prairiaux	1
1.1.1. Définition	1
1.1.2. Importance	1
1.1.3. Menaces	2
1.1.4. Gestion	2
1.2. Avantages de la télédétection.....	3
2. Etat de l'art	4
2.1. Drones	4
2.2. Capteurs	4
2.3. Modèles actuels	6
2.3.1. Variables d'intérêt sur les prairies.....	6
2.3.2. Variables dérivées des capteurs	6
2.3.3. Modèles et performances	7
2.4. Enjeux actuels	8
2.4.1. Evolution des capteurs et logiciels	8
2.4.2. Géoréférencement.....	8
2.4.3. Calibration radiométrique	8
2.4.4. Modèles Numériques de Terrain.....	9
2.4.5. Spécificité des modèles développés.....	9
3. Objectifs de ce travail de fin d'études	10
4. Matériel et méthodes	11
4.1. Site de calibration	12
4.2. Site de validation	13
4.3. Mesures de référence	14
4.3.1. Hauteur	14
4.3.2. Hauteur comprimée	14
4.3.3. Biomasse.....	15
4.3.4. Composition floristique	15
4.4. Données aériennes	15
4.4.1. Drones et capteurs utilisés	15
4.4.2. Plan et données de vol	17

4.4.3.	Pré-traitement des données	18
4.5.	Modèles d'estimation des variables d'intérêt sur les prairies	22
4.5.1.	Estimation de la hauteur	22
4.5.2.	Estimation de la biomasse	23
4.5.3.	Classification de la composition floristique	25
4.6.	Evaluation des modèles	25
5.	Résultats	26
5.1.	Géoréférencement	26
5.2.	Estimation de la hauteur	26
5.3.	Estimation de la biomasse	30
5.4.	Classification de la composition floristique	34
6.	Discussion	35
6.1.	Utilisation des GCP	35
6.2.	Optimisation du flux de traitement	36
6.3.	Effet du matériel et du MNT dans l'estimation de la hauteur	36
6.4.	Modèles de biomasse et importance des variables	37
6.5.	Classificateurs de la composition floristique	39
6.6.	Perspectives supplémentaires	39
6.7.	Limitations techniques et légales	40
7.	Conclusion	41
8.	Contribution de l'étudiant	42
9.	Bibliographie	42
10.	Webographie	46
11.	Annexes	47

Table des figures

Figure 1 - Courbes de réponse spectrale typiques d'appareils photos numériques RGB en fonction de la longueur d'onde (Kolláth et al., 2020).	4
Figure 2 - Courbes de réponse spectrale des bandes d'une camera Micasense Altum en fonction de la longueur d'onde (Casas Mas et al., 2023). B1 = Bleu ; B2 = Vert ; B3 = Rouge ; B4 = Red-Edge ; B5 = Infrarouge proche.	5
Figure 3 - Flux explicatif simplifié pour le passage de la valeur de radiance à la réflectance (Assmann et al., 2019).	9
Figure 4 - Organigramme du flux de travail général.	11
Figure 5 - Dispositif d'échantillonnage sur la prairie de calibration (QGIS 3.28.15).	12
Figure 6 - Photos d'un GCP (gauche), d'une unité d'échantillonnage (milieu) et du Reach RTK (droite).	13
Figure 7 - Dispositif d'échantillonnage sur la prairie de validation (QGIS 3.28.15).	13
Figure 8 - Schéma de la prise des données de hauteur dans chaque unité expérimentale.	14
Figure 9 - Photos du Mini 2 (haut-gauche), 3M (haut-droite), M300 (bas).	15
Figure 10 - Photos du ciel aux dates du 10 avril (gauche) et du 8 mai (droite).	17
Figure 11 - Organigramme du flux de travail appliqué lors du traitement des données LiDAR.	19
Figure 12 - Organigramme du flux de travail appliqué lors de la reconstruction photogrammétrique.	21
Figure 13 - Organigramme des sources de MNT utilisées pour le calcul des différents MNH.	22
Figure 14 –Meilleure régression linéaire photogrammétrique (gauche) et LiDAR (droite). ...	28
Figure 15 - Résidus moyens (+IC) des neuf régressions issues de la photogrammétrie.	29
Figure 16 – Carte de hauteur prédite sur la prairie de validation avec le modèle 3M-MNT1.	29
Figure 17 – Carte de l'écart-type de la hauteur prédite entre les modèles des trois drones.	30
Figure 18 - Régression linéaire de la racine cubique de la biomasse ($\text{kgMS}^{1/3}/\text{ha}$) en fonction de la hauteur comprimée (mm).	30
Figure 19 - Importance des variables de la RF (3M – modèles 17).	32
Figure 20 - Importance des variables de la RF (MicaSense – modèles 21).	33
Figure 21 - Régression linéaire d'estimation de la hauteur via la MicaSense avec le MNT3.	35
Figure 22 - Graphe de corrélations des 4 IV_{RGB} , des 4 IV_{MS} et des métriques de hauteurs du 3M selon les deux premières composantes d'une ACP.	37
Figure 23 - Corrélogramme de la biomasse et des 17 variables explicatives disponibles pour la MicaSense (modèles 21).	39

Table des tableaux

Tableau 1 – Tableau comparatif des caractéristiques principales des différents types de capteurs.....	5
Tableau 2- Dispositif temporel des prises de mesures destructives.	14
Tableau 3 - Spécificités des drones utilisés.	16
Tableau 4 - Conditions météorologiques des trois dates de vol à 13h UTC+2 (moyenne horaire).	17
Tableau 5 - Evolution du nuage de points LiDAR lors du traitement.	18
Tableau 6 - Métadonnées des reconstructions des différents jeux de données sur Agisoft Metashape.....	20
Tableau 7 - Indices de végétation calculés à partir de l'imagerie RGB et multispectrale.....	23
Tableau 8 - Indices de végétation calculés à partir de l'imagerie multispectrale.	24
Tableau 9 – Formules des indicateurs de qualité des régressions.	25
Tableau 10 - Formules des indicateurs de qualité des classificateurs.	25
Tableau 11 - Précision géographique des reconstructions photogrammétriques avant optimisation.	26
Tableau 12 - Précision géographique des reconstructions photogrammétriques après optimisation.	26
Tableau 13 - Résumé comparatif des neuf régressions linéaires réalisées par photogrammétrie.	27
Tableau 14 - Tableau comparatif des deux régressions linéaires réalisée par vol LiDAR.	28
Tableau 15 - Performances du modèle d'estimation de la biomasse avec la hauteur comprimée (modèle 12).	30
Tableau 16 – Performances des modèles d'estimation de la biomasse du Mini 2 avec l'ensemble des variables explicatives (modèles 14).....	31
Tableau 17 - Performances des modèles d'estimation de la biomasse du 3M avec l'ensemble des variables explicatives (modèles 17).	32
Tableau 18 - Performances des modèles d'estimation de la biomasse de la MicaSense avec l'ensemble des variables explicatives (modèles 21).....	33
Tableau 19 - Performances des modèles de classification de la composition floristique.....	34

Liste des abréviations

ACP	Analyse en composantes principales
BRDF	<i>Bidirectional Reflectance Distribution Function</i>
CSF	<i>Cloth Simulation Filter</i>
DLS	<i>Downwelling Light Sensor</i>
DN	<i>Digital Number</i>
GCP	<i>Ground Control Point</i>
GNSS	<i>Global Navigation Satellite System</i>
GSD	<i>Grid Sample Distance</i>
IV	Indice de Végétation
KNN	<i>K-Nearest Neighbors</i>
LWIR	Infrarouge à ondes longues
MNH	Modèle Numérique de Hauteur
MNS	Modèle Numérique de Surface
MNT	Modèle Numérique de Terrain
MS	Multispectral
NIR	<i>Near-InfraRed</i>
NN	<i>Neural Network</i>
PAN	Panchromatique
PCR	<i>Principal Components Regression</i>
PLS	<i>Partial Least Square regression</i>
PLS-DA	<i>Partial Least Square – Discriminant Analysis</i>
PMF	<i>Progressive Morphological Filter</i>
RTK	<i>Real Time Kinematic</i>
RF	<i>Random Forest</i>
RGB	<i>Red-Green-Blue</i>
RLM	Régression Linéaire Multivariée
RLU	Régression Linéaire Univariée
SCR	Système de Coordonnées de Référence
SOR	<i>Statistical Outliers Removal</i>
SVM	<i>Support Vector Machine</i>
TIN	<i>Triangulated Irregular Network</i>
UTC	<i>Coordinated Universal Time</i>

1. Introduction

1.1. Ecosystèmes prairiaux

1.1.1. Définition

Les écosystèmes prairiaux peuvent être caractérisés par une pléthore de définitions. Les différents auteurs dans la littérature ainsi qu'une norme internationale semblent cependant arriver à un consensus sur deux caractéristiques majeures : la présence de graminées, légumineuses et autres herbacées avec une limite du couvert arbustif (Allen et al., 2011; Squires et al., 2018; Reinermann et al., 2020).

Les prairies peuvent être caractérisées par différents qualificatifs. Il est en effet possible de différencier les prairies naturelles telles que les savanes, steppes et toundras, des prairies secondaires, encore dites « améliorées », issues d'actes anthropiques de conversion d'autres écosystèmes et principalement composées d'espèces importées. Entre ces deux extrêmes se trouvent les prairies dites « semi-naturelles », composées d'espèces indigènes et résultant d'une gestion anthropique (Allen et al., 2011; Squires et al., 2018; Bengtsson et al., 2019). Les prairies peuvent encore être qualifiées de « temporaires » lorsqu'elles s'intègrent dans une rotation et sont en place pour quelques années, ou de « permanentes » pour des implantations plus longues (Allen et al., 2011; FAO, 2022). Enfin, il est encore possible de distinguer les prairies dites « de fauche », récoltées via du matériel agricole, des prairies dites « pâturées », consistant à « laisser le bétail prélever lui-même sa nourriture sur les prairies » (Fourrages Mieux, 2020a; Bindelle et al., 2021). Parmi les espèces les plus courantes en Wallonie, on retrouve des espèces pérennes à tendance moins productives dans les prairies permanentes telles que le ray-grass anglais (*Lolium perenne* L.), la fléole des prés (*Phleum pratense* L.), le dactyle (*Dactylis glomerata* L.), la fétuque (*Festuca spp.* L.) ou encore le trèfle blanc (*Trifolium repens* L.) alors que les prairies temporaires sont souvent constituées d'espèces peu pérennes mais très productives telles que le ray-grass italien (*Lolium multiflorum* Lam.), le ray-grass hybride (*Lolium x hybridum* Hausskn.) ou encore le trèfle violet (*Trifolium pratense* L.) (Fourrages Mieux, 2020b; Lambert et al., 2020).

1.1.2. Importance

Au niveau mondial, les prairies couvrent 26 % des terres émergées (Squires et al., 2018), qui, à raison de 3,18 milliards d'hectares en 2020, représentaient deux tiers des surfaces agricoles mondiales. (Reinermann et al., 2020 ; FAO, 2022). En Wallonie, ces écosystèmes composaient, quant à eux, en 2022, pas moins de 49,3 % de la surface agricole utile (SAU), à raison de 55.620 ha de prairies temporaires et 308.900 ha de prairies permanentes (SPW, Juillet-13-2024b).

Ces écosystèmes prépondérants fournissent différents services écosystémiques pouvant être séparés en trois catégories. Les prairies ont tout d'abord un rôle de production de nourriture pour les ruminants. Cette solution est souvent considérée comme la solution la plus économique en regard des concentrés. Le pâturage direct des animaux, dans de bonnes conditions, permet aussi d'augmenter les marges des agriculteurs et de fournir à l'animal des aliments aux teneurs énergétiques et protéiques plus élevées (Parker et al., 1992; Decruyenaere et al., 2016). Par ailleurs, l'élevage est une source de revenus et de subsistance pour près d'un milliard de personnes dans le monde (Reinermann et al., 2020). Les prairies fournissent aussi de nombreux services de régulation tels que la limitation de l'érosion, le stockage du carbone, la filtration de l'eau ou encore la conservation de la biodiversité. Enfin, ces écosystèmes participent, d'un aspect plutôt culturel, à la qualité des paysages, au tourisme et à l'héritage culturel des régions où ils se situent (Squires et al., 2018; Bengtsson et al., 2019; Reinermann et al., 2020).

1.1.3. Menaces

Ces écosystèmes prépondérants et indispensables subissent cependant de nombreuses pressions, particulièrement dans le contexte du changement climatique. Selon le rapport climatique de 2020 de l'IRM (institut royal météorologique de Belgique), la Belgique fait face à une élévation significative des températures annuelles. En ce qui concerne les précipitations, si leur cumul annuel n'a pas augmenté de manière significative depuis 1981, le nombre de jour de fortes précipitations (cumul journalier supérieur ou égal à 20 mm) a, quant à lui, augmenté significativement à raison de 0,6 jour par décennie depuis cette même date. Cette variabilité de répartition des précipitations entraîne de façon de plus en plus récurrente et intense des épisodes de sécheresse saisonnière, qui, dans le cadre agricole, est définie comme « un déficit entre les précipitations et l'évapo-transpiration potentielle » (SPW, Juillet-13-2024-a) Ces changements impactent de façon certaine les systèmes fourragers en termes de qualité ou de quantité d'herbe produite. Cela rend aussi les prairies plus sensibles à des dégradations telles que le surpâturage (situation où l'herbe est rasée sous les 3 cm) en compromettant sérieusement la repousse de l'herbe (Amelung et al., 2011; SPW, Juillet-13-2024-b; Squires et al., 2018).

1.1.4. Gestion

Dans ce contexte, il est fondamental de gérer correctement ces écosystèmes et particulièrement le processus de pâturage afin d'en assurer la robustesse. Parmi les leviers qu'il est possible de mettre en place pour mieux gérer le processus de pâturage et assurer la robustesse de l'écosystème, il est possible de citer l'adaptation du taux de charge [UGB/ha], la fauche des refus, le choix du stade d'exploitation ou encore les types de pâturage appliqué (continu, dynamique tournant, rotatinu...) (SPW, Juillet-13-2024-b, Juillet-13-2024-c). Parmi ces leviers, certains nécessitent la prise de données de terrain, principalement en termes de hauteur [m] et de stock fourrager, aussi appelé « biomasse » [kgMS/ha].

Les estimations du stock fourrager disponible peuvent s'effectuer de deux façons. La première, dite « directe » et considérée comme l'évaluation de référence, consiste à prélever des échantillons d'herbe sur des surfaces définies à plusieurs endroits de la prairie, et peser ces échantillons après un séchage à l'étuve (Sanderson et al., 2001; Bindelle et al., 2021; Gargiulo et al., 2023). Le second type de méthode est, quant à lui, qualifié d'« indirect » et consiste à mesurer un paramètre sur la prairie qui est, par la suite, corrélé à la biomasse via des équations pré-calibrées. Parmi les outils utilisés couramment, il est possible de citer l'herbomètre, outil le plus utilisé en pratique et composé d'un disque comprimant la végétation et mesurant la hauteur comprimée du couvert, le capacimètre, qui mesure la capacité du mélange herbe-air ou encore le « *sward stick* », qui, à la façon d'une règle, permet de mesurer la hauteur réelle du couvert herbacé (Sanderson et al., 2001). Parmi les innovations les plus récentes, il est encore possible de citer les *C-Dax Pasture Meters* (C-Dax, Turitea, Nouvelle-Zélande), dispositifs en tunnel tractés prenant plus de 200 mesures de hauteurs d'herbe par seconde grâce à des rayons infrarouges (Bareth et al., 2018). Toutes ces méthodes, bien que moins chronophages que les évaluations directes de la biomasse, représentent, elles aussi, une charge de travail assez élevée. En effet, plusieurs dizaines de mesures par hectare sont souvent nécessaires afin de prendre en compte la variabilité de la parcelle (Sanderson et al., 2001), particulièrement dans le cas de prairies pâturées hétérogènes.

1.2. Avantages de la télédétection

Dans ce contexte, la télédétection, définie comme un « ensemble de techniques permettant de mesurer à distance des grandeurs physiques caractéristiques des objets ou des phénomènes étudiés » (Universalis, Mars-9-2024), permet de réduire la charge de travail liée aux prises de données au sol, particulièrement lorsque les surfaces étudiées sont conséquentes (Reinermann et al., 2020).

L'utilisation d'imagerie satellite provenant de la flotte Landsat, ainsi que des satellites Sentinel-1 et Sentinel-2 dans l'estimation de certaines métriques de terrains a déjà été démontrée comme étant efficace (Crabbe et al., 2020; Ara et al., 2021). L'utilisation de ces données spatiales, qui, certes, permet de couvrir des surfaces importantes, se heurte cependant à deux principaux défauts : la nécessité d'un ciel dégagé, et une faible résolution spatiale au sol, souvent supérieure à 10 mètres (Crabbe et al., 2020; Ara et al., 2021).

Au croisement entre l'utilisation de données satellite et de données prises au sol se trouvent les drones, « aéronefs sans pilote ou équipage embarqué » (Le Robert, Mars-13-2024.). En langue anglaise, ils sont appelés UAVs pour « *unmanned aerial vehicles* ». Ceux-ci permettent de prendre des données à des résolutions spatiales bien meilleures que les satellites (de l'ordre du centimètre) sur des surfaces de plusieurs hectares (Aasen et al., 2018; Bindelle et al., 2021; Gargiulo et al., 2023). Le développement actuel de nombreux capteurs différents et la démocratisation de ces technologies peuvent en faire dans les années à venir, un outil révolutionnaire dans la prise de données, que ce soit dans le domaine de la recherche scientifique ou dans une optique d'aide à la décision des agriculteurs (Aasen et al., 2018). Ces dernières années, de nombreuses études se sont penchées sur l'utilisation de cette technologie dans des applications agricoles d'estimation de biomasse, de hauteur d'herbe, de composition floristique, de surface foliaire (LAI) ou encore de la qualité nutritive des prairies (Lu et al., 2017; Forsmoo et al., 2018; Viljanen et al., 2018; Borra-Serrano et al., 2019; Grüner et al., 2019; Michez et al., 2019, 2020; Barnetson et al., 2020; Théau et al., 2021; Wang et al., 2023). La plupart combine différentes sources d'informations obtenues à l'aide de différents capteurs afin de développer des modèles de prédiction qui peuvent, dans les meilleurs cas, atteindre des qualités très élevées.

Un état de l'art de l'utilisation globale des drones dans le contexte du suivi de croissance des prairies est présenté dans le paragraphe suivant afin de saisir les principales problématiques actuelles relatives à leur utilisation. Cette revue de la littérature a permis de définir un objectif global à ce travail, subdivisé en plusieurs hypothèses, et de développer une méthodologie afin d'y répondre.

2. Etat de l'art

2.1. Drones

Il existe deux grands types de drone : ceux à ailes fixes et ceux à hélices tournantes, qui sont différenciés par le nombre de rotors que possède l'appareil. Les drones à ailes fixes, hélicoptère (rotor unique) et octoptères (huit rotors) sont ceux capables d'embarquer les plus grosses charges. Dans cette optique, ils sont plutôt utilisés en tant qu'outils d'épandage ou pour la réalisation de photos aériennes à très haute altitude. Les hexa- (six rotors) et quadricoptères (quatre rotors) sont quant à eux plutôt utilisés en télédétection à basse altitude (Kim et al., 2019).

2.2. Capteurs

Parmi les différents capteurs qui peuvent être embarqués sur ces appareils, il est possible de différencier les capteurs dits « passifs », qui se contentent de capter le rayonnement émis par la surface observée, des capteurs « actifs », émettant le rayonnement dont ils mesurent le retour.

Dans la première catégorie se trouvent les capteurs dits « spectraux ». Ceux-ci mesurent indirectement la part de lumière incidente qui est réfléchiée par une surface, aussi appelée « réflectance », dans des longueurs d'onde spécifiques. Ces capteurs se distinguent généralement par le nombre de bandes spectrales qu'ils peuvent enregistrer ainsi que par la résolution de ces dernières (largeur de la bande [nm]) (Aasen et al., 2018; Assmann et al., 2019).

Parmi ces capteurs, les plus courants et accessibles sont les capteurs dit « RGB » (*Red – Green – Blue*) qui enregistrent l'intervalle visible du spectre électromagnétique (400-700 nm). Ce sont des « capteurs instantanés en 2D » qui enregistrent les trois bandes simultanément avec une seule camera. Ils présentent souvent un large recouvrement des bandes ainsi qu'une haute résolution spatiale mais fournissent une information spectrale de qualité moindre ne permettant souvent pas de calculer les indices de végétation les plus courants (Aasen et al., 2018; Bindelle et al., 2021). Des courbes de réponse spectrale typiques de caméras RGB sont présentées à la Figure 1.




Figure 1 - Courbes de réponse spectrale typiques d'appareils photos numériques RGB en fonction de la longueur d'onde (Kolláth et al., 2020).

La gamme supérieure de capteurs englobe les capteurs dits « multispectraux » (MS). Ces capteurs enregistrent un nombre de bandes plus élevé, généralement cinq à six mais pouvant aller jusqu'à plus de neuf (Aasen et al., 2018). Parmi les bandes les plus courantes se trouvent les trois bandes visibles classiques (R, G et B), auxquelles s'ajoutent la plupart du temps le Red-Edge (entre 680 et 730 nm) ainsi que l'Infrarouge proche ou « NIR » (entre 700 à 1300 nm). Ils présentent une résolution spectrale intermédiaire ainsi qu'une résolution spatiale moins bonne que les caméras RGB. Ce sont des « capteurs 2D multi-caméras », chacune de celles-ci ayant des filtres pour cibler certaines longueurs d'onde (Aasen et al., 2018; Bindelle et al., 2021). A titre illustratif, les différentes bandes du spectre électromagnétiques enregistrées par une caméra multispectrale sont présentées à la Figure 2.




Figure 2 - Courbes de réponse spectrale des bandes d'une camera Micasense Altum en fonction de la longueur d'onde (Casas Mas et al., 2023). B1 = Bleu ; B2 = Vert ; B3 = Rouge ; B4 = Red-Edge ; B5 = Infrarouge proche.

Enfin, un niveau de gamme supérieur peut encore être défini. Celui-ci englobe les capteurs dits « hyperspectraux ». Ceux-ci enregistrent un nombre très élevé de bandes (souvent supérieur à 100) dans une large proportion du spectre électromagnétique (de 400 à 1500 nm). Leur résolution spectrale est en général très forte (largeur des bandes inférieure à 10nm) au détriment d'une résolution spatiale souvent réduite (Aasen et al., 2018; Bindelle et al., 2021).

A côté de ces trois grands types de capteurs courants, il est encore possible de citer les caméras dites « panchromatiques », caméra à très haute résolution spatiale enregistrant le spectre visible en une seule bande/canal. Ces images sont la plupart du temps utilisées en combinaison avec des capteurs spectraux à faible résolution spatiale dans des caméras multispectrales (Aasen et al., 2018).

Dans les capteurs spectraux se classent aussi les capteurs « thermiques » (LWIR) qui enregistrent une large bande spectrale dans des longueurs d'onde allant de 7.5 à 13.5 μm (Manfreda et al., 2018).

Dans la seconde catégorie de capteurs, dits « actifs », se range la technologie des capteurs LiDAR (« *light detection and ranging* »). Ceux-ci émettent des impulsions laser à haute fréquence et enregistrent la réflexion de ce rayonnement sur la surface observée afin de la localiser. Ils peuvent, dans certains cas, enregistrer plusieurs retours de ce même rayonnement (Manfreda et al., 2018; Bindelle et al., 2021).

Les principales caractéristiques de ces différents capteurs sont présentées dans le Tableau 1.

Tableau 1 – Tableau comparatif des caractéristiques principales des différents types de capteurs¹.

Capteur	Résolution spatiale	Résolution spectrale	Nombre de bandes	Poids	Prix
RGB	+++ (+)	++	3	+	+
Multispectral	++ (+)	+++	4 à > 10	++ (+)	++ (+)
Hyperspectral	++	++++	> 100	++ (+)	++++
Panchromatique	++++	+	1	/	/
Thermique	+	+	1	++	++
Lidar	/	/	/	++++	++++

¹ Pour les résolutions, un nombre plus élevé de signes « + » signifie une résolution meilleure. Pour le poids et le prix, plus de signes signifie un appareil plus lourd et plus onéreux. Pour le panchromatique, le poids et le prix ne sont pas présentés car celles-ci sont souvent combinées dans des caméras multispectrales. Pour le LiDAR, parler de résolution n'est pas pertinent.

2.3. Modèles actuels

2.3.1. Variables d'intérêt sur les prairies

Comme déjà mentionné dans la mise en contexte, lors du suivi de croissance des prairies et dans l'optique d'augmenter leur résilience, il est pertinent de pouvoir estimer différentes variables nécessaires à l'activation de différents leviers de gestion. Les variables d'intérêts dépendent du levier en question. Parmi celles-là il est possible de citer la valeur nutritive, la surface foliaire ou encore la couverture du sol. Cependant, trois principales sont souvent utilisées en pratique.

La première est la hauteur de la canopée herbacée [m], définie comme « la hauteur de la canopée non-perturbée, mesurée à partir du sol » (Allen et al., 2011). Cette mesure de structure présente un intérêt dans certaines situations de pâturage innovant tel que le pâturage rotatinu, visant à maximiser le taux d'ingestion instantané des animaux (STIR) et qui nécessite de définir des objectifs en termes de hauteur d'herbe pré- et post-pâturage (Carvalho et al., 2013).

La seconde caractéristique élémentaire à la caractérisation des prairies est la biomasse, encore appelée stock fourrager [kgMS/ha]. Celle-ci est définie comme le « poids sec total de la végétation par unité de surface au-dessus d'un niveau de référence défini ». Ce niveau de référence peut être le sol, ou une hauteur de coupe d'herbe en-dessous de laquelle l'herbe n'est pas considérée comme disponible pour l'animal ou la récolte. Sa mesure de référence se fait par récolte jusqu'au seuil de référence et séchage à 105°C jusqu'à poids constant (t Mannelje et al., 2000; Allen et al., 2011). Il est aussi possible de la mesurer indirectement en mesurant un paramètre sur la prairie qui est, par la suite, corrélé à la biomasse via des équations pré-calibrées. Parmi les outils utilisés couramment, il est possible de citer l'herbomètre, corrélant la hauteur comprimée [mm] du couvert à la biomasse. C'est la mesure de référence la plus utilisée en pratique par les agriculteurs (Sanderson et al., 2001).

Enfin, la troisième caractéristique d'intérêt généralement considérée est la composition floristique de la prairie. Définie comme la « proportion relative des composants végétaux dans une canopée au-dessus d'une hauteur d'échantillonnage définie », elle peut être évaluée par proportion de poids ou de couverture [%], via leur densité (nombre d'individus par unité de surface) ou via leur simple absence ou présence (Allen et al., 2011). Cette métrique peut par exemple apporter des informations quant à l'évolution de la prairie dans le temps (changements de proportion relative...) (Lu et al., 2017).

2.3.2. Variables dérivées des capteurs

Afin d'estimer les différentes variables d'intérêt sur la prairie, il est possible, grâce à des flux de traitements de tirer plusieurs informations des données obtenues via les différents capteurs.

Les différentes images acquises par les capteurs spectraux peuvent être traitées via de la photogrammétrie SfM (« *Structure from Motion* »). Ce processus est une « technique informatique qui utilise les positions relatives des pixels d'images superposées de la même scène obtenues sous des angles différents pour construire des modèles 3D et des images orthomosaïques composites » (Assmann et al., 2019). Le principe consiste, sur des logiciels photogrammétriques, à générer un nuage de points, parmi lesquels des points de sol peuvent être classés via différents algorithmes. Une rasterisation (conversion en une image matricielle) permet ensuite de générer un Modèle Numérique de Surface (MNS) ou un Modèle Numérique de Terrain (MNT) selon qu'elle utilise l'ensemble des points ou uniquement ceux classés comme appartenant au sol. La soustraction du MNT au MNS permet d'obtenir un Modèle Numérique de Hauteur (MNH) représentant les éléments au-dessus du sol (Michez et al., 2019).

Dans ces mêmes logiciels, des orthomosaïques spectrales peuvent être générées, contenant les informations de réflectance de chaque pixel pour les différentes bandes enregistrées. Ces valeurs de réflectance peuvent, in fine, être combinées arithmétiquement afin de définir des indices de végétation (IV). Parmi les centaines d'IV existants, les plus utilisés combinent les bandes visibles et le NIR. Ceux-ci différencient en général correctement la végétation photosynthétiquement active qui absorbe plus de rouge que de NIR (Assmann et al., 2019; Bindelle et al., 2021). En ce qui concerne les bandes thermiques (ou capteurs thermiques indépendants) le principe est similaire. L'information qu'ils fournissent concerne cependant le contenu en eau, la température ou encore l'état du sol (Manfreda et al., 2018).

Les données prélevées au moyen d'un capteur LiDAR sont assez semblables aux précédentes. En général, le nuage de points est classé selon un algorithme défini et est ensuite normalisé de telle sorte que chaque point de sol ait une hauteur nulle (Hütt et al., 2024). La hauteur de chaque autre point est donc directement connue et des statistiques de hauteurs peuvent être calculées sur des surfaces définies. Après la classification, il est aussi possible de n'utiliser que les points de sol dans une rasterisation afin de générer un MNT. Celui-ci est la plupart du temps considéré comme de meilleure qualité au vu la capacité du LiDAR à détecter plusieurs couches de l'élément observé et donc, de mieux caractériser le sol sous-jacent (Manfreda et al., 2018; Théau et al., 2021).

2.3.3. Modèles et performances

Finalement, l'ensemble de ces variables issues du traitement peuvent être combinées dans des modèles divers afin d'estimer les variables d'intérêt de la prairie. Les conditions expérimentales, les drones, les capteurs, les traitements, les variables explicatives utilisées et les types de modèles développés fluctuant entre les différentes études, la comparaison de leurs performances est très complexe.

En ce qui concerne la hauteur, celle-ci est en général estimée via des régressions linéaires univariées (RLU) entre la hauteur réelle mesurée (ponctuelle ou moyenne/médiane zonale) sur la prairie et une statistique zonale de hauteur provenant d'un MNH ou du nuage de points LiDAR normalisé. A titre d'exemple, Grüner et al. (2019) atteignent des R^2 de 0,70 lors de l'estimation de la hauteur moyenne sur des surfaces de 15 m². Michez et al. (2020) obtiennent des performances similaires avec un R^2 de 0,72 pour une surface de 10,5 m², valeur qui chute cependant à 0,48 lors de l'estimation à l'échelle ponctuelle.

Pour ce qui est de la biomasse, les modèles empiriques développés vont de la régression linéaire multivariée (RLM) avec sélection de variables à des modèles plus complexes de *Machine Learning* tels que des « *Partial Least Square Regression* » (PLS), des « *Support Vector Machine* » (SVM) ou des « *Random Forests* » (RF). Viljanen et al. (2018) et Michez et al. (2019) concluent à l'importance de combiner des données photogrammétriques 3D à des IV afin d'améliorer la performance des modèles. Ces derniers parviennent même à atteindre un R^2 de 0,98 en combinant ces variables dans des RF. Grüner et al. (2020) concluent eux aussi à une meilleure performance de la part d'une RF vis-à-vis d'un algorithme PLS et insistent sur l'importance de la colinéarité entre les variables. D'autres concluent quant à eux à de meilleurs résultats avec des RLM tels que Borra-Serrano et al. (2019) avec un R^2 de 0,81. Enfin, certains vont jusqu'à faire du *Deep Learning* grâce à des réseaux neuronaux convolutionnels tels que Alves Oliveira et al. (2022) (R^2 de 0,79).

Enfin, en ce qui concerne la composition floristique, elle est rarement estimée sous forme de régression. Les méthodes classiques définissent des classes en fonction du nombre d'espèces présentes et appliquent des algorithmes de classification tels que la méthode des « plus proches voisins » (KNN), des RF ou encore de SVM. Crabbe et al. (2020) appliquent ce principe à des données satellites et obtiennent des précisions atteignant 0,96 pour des RF. Certains utilisent aussi des approches avancées de classification orientée-objet afin d'identifier les espèces dominantes (Lu et al., 2017).

2.4. Enjeux actuels

Malgré le nombre élevé d'études traitant du sujet, de nombreux enjeux, questionnements et perspectives persistent quant à l'utilisation des drones dans ce contexte.

2.4.1. Evolution des capteurs et logiciels

Tout d'abord, la démocratisation et l'augmentation du nombre de capteurs, de drones ainsi que des logiciels de traitement ouvrent à l'heure actuelle de nombreuses perspectives nouvelles. Des drones ou capteurs considérés comme haut de gamme il y a encore quelques années se démocratisent. De plus, l'amélioration des capteurs sur du matériel dit « *low-cost* » augmente les possibilités de tout un chacun dans cette voie d'utilisation. Il est aussi maintenant possible de compenser le phénomène de « *rolling shutter* » associé aux obturateurs électroniques et pouvant causer des distorsions d'images, directement dans les logiciels de traitement (Aasen et al., 2018). Dans cette optique d'amélioration du « *low-cost* » se pose alors la question de la valeur ajoutée que le matériel haut de gamme présente encore vis-à-vis de ces derniers. Même si certaines études comparent différents drones et leur informations photogrammétriques (Michez et al., 2020), très peu les comparent à la technologie LiDAR au sein d'une même expérimentation.

2.4.2. Géoréférencement

Le géoréférencement des modèles est généralement identifié comme l'un des freins majeurs à l'utilisation des drones. Pour corriger ces erreurs, il est souvent conseillé de réaliser une correction géométrique au cours de la reconstruction photogrammétrique en utilisant des points de contrôle au sol (dits « GCP ») préalablement géoréférencés précisément (de l'ordre du cm) via un GNSS de haute précision de type « *Real Time Kinematic* » (RTK) (Aasen et al., 2018; Assmann et al., 2019). Cependant, à l'heure actuelle, de plus en plus de drones possèdent un module RTK embarqué et synchronisé au capteur permettant d'effectuer des corrections de localisation en temps réel, et ce, pour un poids et un prix de plus en plus réduit. Certains questionnent (Viljanen et al., 2018) ou ont démontré l'inutilité de l'utilisation de GCP dans ce cas, en atteignant des précisions altimétriques de l'ordre de 2,8 cm (Bareth et al., 2023) alors que la plupart des travaux continuent d'en utiliser.

2.4.3. Calibration radiométrique

Un troisième point d'attention concerne la calibration des images multispectrales. En effet, les différents capteurs spectraux susmentionnés ne mesurent pas directement la réflectance de la surface qu'ils observent. Ils enregistrent en réalité la radiance provenant de celle-ci sous forme de valeur numérique (DN) sans pour autant connaître la radiation incidente. Afin de pouvoir comparer et utiliser dans les mêmes modèles des données prises à des moments différents et dans des conditions d'illumination différentes, il est fondamental de convertir ces DN en valeurs réelles de réflectance. Pour ce faire, il est conseillé d'utiliser des panneaux dont la réflectance dans les différentes bandes est connue et de les photographier avant et après le vol afin de réaliser une correction radiométrique via une régression linéaire empirique lors de la reconstruction photogrammétrique. Certains drones, plus haut de gamme, possèdent quant à eux un capteur de radiation incidente (DLS ou ILS) qui leur permet de réaliser ces corrections en temps réel (Aasen et al., 2018; Manfreda et al., 2018; Grüner et al., 2020). Une telle calibration est très rarement réalisée pour les capteurs RGB.




Figure 3 - Flux explicatif simplifié pour le passage de la valeur de radiance à la réflectance (Assmann et al., 2019).

2.4.4. Modèles Numériques de Terrain

Les MNT soustraits aux MNS peuvent aussi provenir d'autres sources que la classification de points de sol susmentionnée. La génération d'un MNS après une coupe ou sur un sol nu, sans classification est parfois approximé à un MNT (Bareth & Schellberg, 2018; Borra-Serrano et al., 2019). Dans certaines régions, des MNT déjà générés sont disponibles sur certaines plateformes en ligne. C'est le cas en Wallonie où un MNT est disponible sur le Géoportail de la Wallonie « WalOnMap » ("Géoportail de la Wallonie," Février-29-2024). Aucune étude n'a encore comparé de façon systématique différents MNT au sein d'une même expérimentation afin de vérifier si le travail supplémentaire que représente une acquisition indépendante est réellement valorisé dans la performance des modèles vis-à-vis d'un MNT déjà disponible dans certaines régions.

2.4.5. Spécificité des modèles développés

Le dernier enjeu majeur à l'heure actuelle concerne la spécificité des modèles développés. Dans la littérature, les différents modèles sont développés à partir de variables différentes et dans des conditions différentes, ce qui rend leur comparaison et leur transférabilité complexes. Beaucoup collectent leurs données à une seule date et dans des conditions expérimentales éloignées des conditions réelles de pâturage. Lussem et al. (2019) simulent par exemple des biomasses différentes via des traitements azotés variables. Bon nombre, tels que Grüner et al. (2019), travaillent à des échelles larges de plus de 10 m² ne permettant pas de capter l'hétérogénéité de la prairie. Ce dernier conclut en outre à la spécificité des modèles vis-à-vis de la composition floristique. Théau et al. (2021) insistent quant à eux sur l'importance de prendre des données sur la saison entière afin de ne pas développer des modèles spécifiques à un stade végétatif. Enfin, la majorité des études évaluent les performances de leur modèles via un jeu de données qui n'est pas indépendant en séparant leur jeu de données initial en deux ou via de la validation croisée (Viljanen et al., 2018; Lussem et al., 2019; Grüner et al., 2020). Dans ce cadre, il est nécessaire de développer une méthodologie reproductible et des modèles de prédiction robustes et moins dépendants du site de calibration (Aasen et al., 2018; Assmann et al., 2019; Bindelle et al., 2021).

3. Objectifs de ce travail de fin d'études

Au regard des différents enjeux susmentionnés, l'objectif de ce travail sera de comparer les performances prédictives de différentes classes de matériel, allant du drone « *low-cost* » à la technologie LiDAR, ainsi que diverses sources de MNT, pour estimer de façon exacte et précise la hauteur, la biomasse et la composition floristique des prairies. L'application des bonnes pratiques (plan de vol adapté, correction géométrique si nécessaire, correction radiométrique et diversification du jeu de données) visera à assurer la transférabilité des modèles, qui sera vérifiée à l'aide d'un jeu de données indépendant.

Cet objectif général sera divisé en différentes hypothèses qui seront vérifiées au fil de ce travail.

Hypothèse spécifique 1 :

L'utilisation de points de contrôle au sol (GCP) n'est pas nécessaire pour obtenir des précisions centimétriques lorsque le drone est équipé d'un GNSS de haute précision du type RTK.

Hypothèse spécifique 2 :

Des données LiDAR acquises par drone permettent d'obtenir des modèles systématiquement et statistiquement plus performants que ceux basés sur des données photogrammétriques.

Hypothèse spécifique 3 :

L'utilisation d'un Modèle Numérique de Terrain (MNT) en accès libre tel que disponible dans certaines régions est une source de données tout aussi performante que d'autres sources de MNT.

Hypothèse spécifique 4 :

Des données photogrammétriques acquises au moyen d'un drone « *low-cost* » permettent d'obtenir des modèles statistiquement aussi performants que des capteurs haut de gamme.

Hypothèse spécifique 5 :

L'application des bonnes pratiques recensées dans la littérature permet d'obtenir des modèles transférables et utilisables sur un jeu de données indépendant.

4. Matériel et méthodes

La démarche générale de ce travail va s'articuler autour de la prise de données aériennes au moyen de trois drones différents, dont l'un servira à embarquer deux capteurs distincts visant respectivement à obtenir des données multispectrales et LiDAR. En parallèle à ces données aériennes, des données de référence en termes de hauteur, biomasse et composition floristique seront prélevées au sol, tout comme une mesure de hauteur comprimée à l'herbomètre qui servira de comparaison pour les modèles développés sur base des données aériennes. La prise de données se fera en deux dates sur une première prairie afin de créer un jeu de données de calibration diversifié. Une prise de données en une seule date sur une seconde prairie servira de jeu de validation. La Figure 4 vise à schématiser ce flux de travail.




Figure 4 - Organigramme du flux de travail général.

4.1. Site de calibration

Le site de calibration est une prairie permanente de 1,2 ha (Longitude : 4,702°E ; Latitude : 50,565° N) de la ferme expérimentale de Gembloux Agro Bio-Tech (Université de Liège, Belgique). La prairie, installée depuis 2012, présente une composition floristique très diversifiée avec diverses graminées telles que la houlque laineuse (*Holcus lanatus* L.), le dactyle aggloméré (*Dactylis glomerata* L.), le ray-grass (*Lolium sp.* L.), divers paturins (*Poa sp.* L.), mais aussi des légumineuses telles que le trèfle blanc (*Trifolium repens* L.) et divers adventices, principalement représentés par des pissenlits (*Taraxacum sp.* Weber ex F.H.Wigg). Elle est située majoritairement sur un sol limoneux modérément gleyifié avec horizon B textural possible (“Géoportail de la Wallonie,” Février-29-2024). En 2024, aucune opération n’a été réalisée sur la prairie avant le début de l’expérimentation.

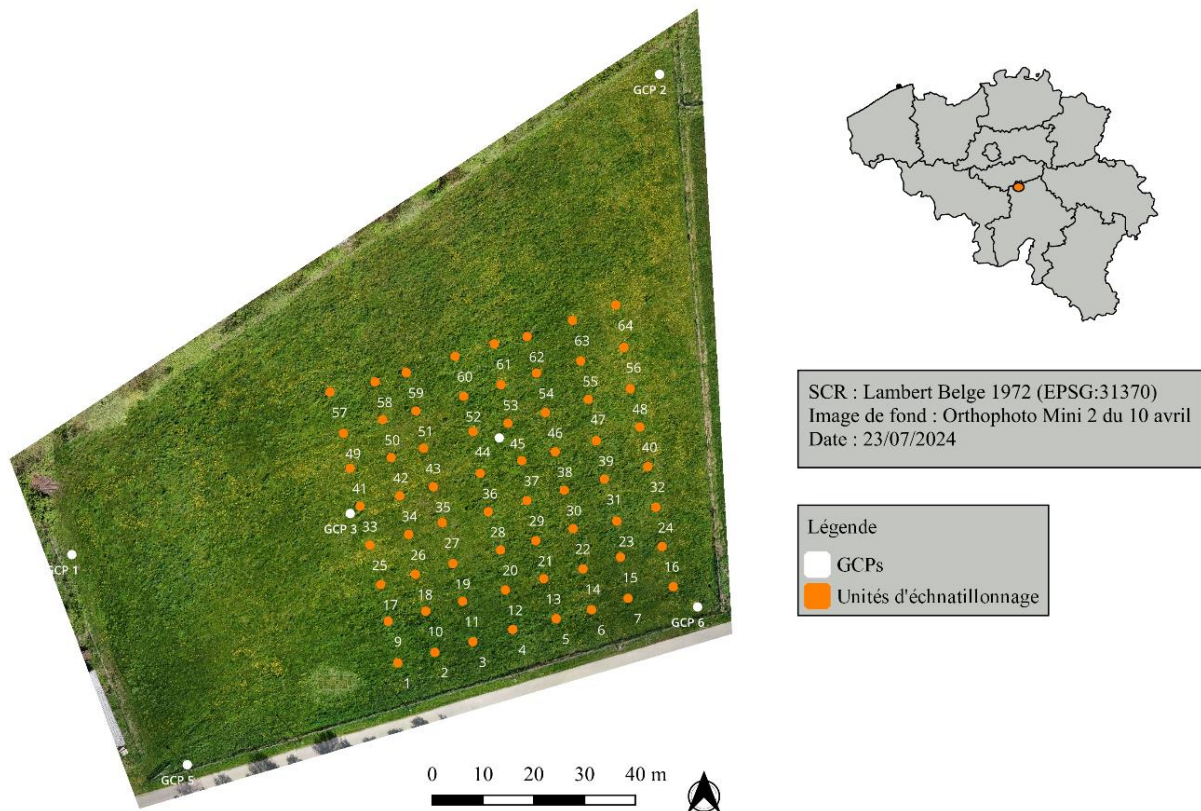


Figure 5 - Dispositif d'échantillonnage sur la prairie de calibration (QGIS 3.28.15).

Soixante-quatre unités d'échantillonnage circulaires de 0,4 m de diamètre ($A=2*\pi*r=0,1257\text{ m}^2$) ont été disposées selon un dispositif en quadrillage afin de faciliter les mesures au sol (Figure 5). Celles-ci ont été géoréférencées en leur centre via un Reach RTK (Emlid, Budapest, Hongrie) connecté en signal fixe au réseau Walcors (“WALCORS Réseau permanent de stations GNSS de référence de la Wallonie,” Juillet-25-2024) permettant une correction en temps réel de la géolocalisation. La base du réseau utilisée était celle de Namur située à 13,6 km de la prairie. Pour chacune des unités, la base et le rover avaient au minimum 20 satellites en vue. Ce dispositif assurait une précision de l'ordre du centimètre en termes de longitude, de latitude et d'altitude. En pratique, elles ont été marquées au moyen de piquets d'implantation en plastique au niveau du sol afin de pouvoir facilement retrouver leur centre (Figure 6).

Six points de contrôle au sol (GCP) ont aussi été placés à raison d'un dans chaque coin ainsi que deux au milieu de la prairie. Ces GCP sont des plaques de béton carrées, noires et blanches, de 50 cm de côté. Ils ont aussi été géoréférencés. Leur nombre a été fixé en suivant les recommandations de Aasen et al. (2018) et Assmann et al. (2019).



Figure 6 - Photos d'un GCP (gauche), d'une unité d'échantillonnage (milieu) et du Reach RTK (droite).

4.2. Site de validation

Le site de validation est une prairie temporaire, d'une surface de 1,2 ha, appartenant au CRA-W et située à Gembloux (Longitude : 4,728°E ; Latitude : 5,562°N). Sa flore était composée de ray-grass (*Lolium sp. L.*), de trèfle (*Trifolium sp. L.*) ainsi que de quelques adventices tels que des pissenlits (*Taraxacum sp. Weber ex F.H.Wigg*) et de l'oseille (*Rumex sp. L.*). Elle se situe majoritairement sur un sol limoneux faiblement à modérément gleyifié avec horizon B textural. Elle avait déjà subi une coupe au cours du début du mois de mai et présentait donc un stade de repousse. Sur celle-ci, 24 unités d'échantillonnage circulaires et 6 GCP ont été disposés selon la même méthodologie que sur la prairie de calibration (Figure 7).




Figure 7 - Dispositif d'échantillonnage sur la prairie de validation (QGIS 3.28.15).

4.3. Mesures de référence

Les données de référence de hauteur, biomasse et composition floristiques ont été prises le 10 avril et le 08 mai 2024 pour la prairie de calibration et le 3 juin 2024 pour la prairie de validation.

Pour la première, des mesures non-destructives de hauteur et hauteur comprimée ont été prises sur chacune des 64 unités aux deux dates. Les mesures destructives (biomasse et composition floristique) ont, quant à elles, suivi un schéma d'échantillonnage temporel permettant d'obtenir des données variées en termes de quantité de biomasse et de stade phénologique. Sur les 64 unités, 32 ont été récoltées lors de la prise de données du mois d'avril. Trente-deux autres ont été récoltées lors de la prise de données du mois de mai. Parmi celles-ci, 16 avaient déjà été récoltées en avril et 16 subissaient leur première coupe (Tableau 2). Une troisième récolte initialement prévue en juin n'a pas été réalisée en raison de la météo pluvieuse et d'une verse des graminées.

En ce qui concerne la prairie de validation, l'ensemble des mesures non-destructives et destructives a été réalisé à la date mentionnée sur les 24 unités d'échantillonnage.

Tableau 2- Dispositif temporel des prises de mesures destructives.

Code unités	Nombre	Avril	Mai
AMJ	16	x	x
AJ	16	x	
MJ	16		x

4.3.1. Hauteur

Au sein des unités d'échantillonnage, les mesures de la hauteur ont été réalisées au moyen d'un *sward-stick* en aluminium (Rueda-Ayala et al., 2019). Huit mesures par cercle ont été réalisées de façon systématique tel que présenté sur la Figure 8. La hauteur [m] a été définie comme étant la distance verticale entre le sol et la feuille la plus haute dans un rayon de 0,025 m autour du stick (Michez et al., 2020). A partir de ces huit mesures, la hauteur médiane de chaque unité a été calculée.

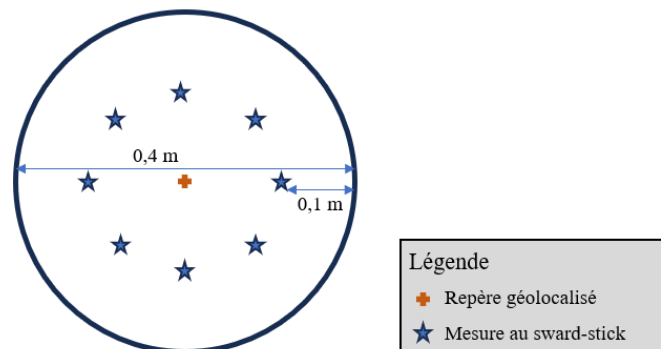


Figure 8 - Schéma de la prise des données de hauteur dans chaque unité expérimentale.

4.3.2. Hauteur comprimée

Une mesure de hauteur comprimée [mm] a aussi été prise au centre de chaque unité au moyen d'un herbomètre EC20 (Jenquip, Feilding, Nouvelle-Zélande) connecté via Bluetooth à un smartphone.

4.3.3. Biomasse

La biomasse de référence a été évaluée de façon directe en récoltant celle-ci, comme préconisé par Mannetje et al. (2000) et Allen et al. (2011). Les coupes ont été réalisées à 0,05 m du sol au moyen de d'une cisaille manuelle, les graminées ont ensuite été séparées des légumineuses et des adventices et placés dans des sacs microperforés. Ceux-ci ont été pesés afin d'obtenir le poids frais. Ils ont ensuite été placés 72 heures dans une étuve à 65°C (Tarr et al., 2005; Kümmerer et al., 2023) jusqu'à atteindre un poids constant. Ils ont ensuite été pesés afin d'obtenir le rendement en matière sèche [kgMS/ha].

4.3.4. Composition floristique

La composition floristique n'a pas été étudiée d'un point de vue spécifique, le nombre d'espèces étant trop élevé. Une classification plus fonctionnelle en « forme de vie » (FV), inspirée de Ansquer et al. (2004), a été utilisée. Elle différencie les graminées (FV1), les dicotylédones hors légumineuses (FV2) ainsi que les légumineuses (FV3). Pour chacun de ces groupes, le pourcentage de matière sèche que chacun représentait a été calculé à la suite du séchage.

4.4. Données aériennes

4.4.1. Drones et capteurs utilisés

Les données aériennes ont été collectées au moyen de trois appareils quadricoptères de budget différent (prix renseignés en février 2024) et équipés de capteurs et de systèmes de géolocalisation variés. Le DJI Mini 2 (DJI, Shenzhen, Chine), drone low-cost appelé « Mini 2 » dans la suite de ce travail, possède une caméra RGB et un système de positionnement classique (Figure 9 ; Tableau 3). Le DJI Mavic 3M (ci-dessous dénommé « 3M ») possède une caméra RGB, une caméra multispectrale à quatre bandes ainsi qu'un module de géolocalisation RTK. Enfin, le DJI M300, gros-porteur, possède, lui-aussi, un module RTK. La caméra MicaSense Altum-PT (MicaSense, Seattle, Etats-Unis) qu'il embarque est une caméra multispectrale à 7 bandes enregistrant une bande panchromatique et une bande thermique. Elle possède aussi un capteur de lumière incidente (DLS) permettant une correction radiométrique en temps réel. Le LiDAR DJI Zenmuse L1 peut lui aussi être embarqué sur ce drone gros-porteur lors d'un vol différent, la plateforme d'accroche n'acceptant qu'un capteur à la fois (Altum-PT - Drone Sensors, Mars-01-2024 ; DJI Mavic 3M - Specifications, Mars-01-2024 ; Specs - MATRICE 300 RTK - DJI Enterprise, Mars-04-2024 ; Specs - Zenmuse L1 - DJI Enterprise, Mars-04-2024 ; Support for DJI Mini 2, Mars-01-2024).



Figure 9 - Photos du Mini 2 (haut-gauche), 3M (haut-droite), M300 (bas)².

² Tailles non proportionnelles.

Matériel et méthodes

Tableau 3 - Spécificités des drones utilisés.³

Appareil	DJI Mini 2 (+/-300€ ; 242 g)	DJI Mavic 3M (+/-5000€ ; 951 g)		DJI Matrice 300 RTK (+/-12000€ ; 6300 g)		
Module RTK	Non	Oui		Oui		
GNSS	GPS + GLONASS + GALILEO (vert. ±0,5 m ; hor. ±1,5 m)	GPS + Galileo + BeiDou + GLONASS Avec RTK (vert. ±0,1 m ; hor. ±0,1 m) Sans RTK (vert. ±0,5 m ; hor. ±0,5 m)		GPS + BeiDou + Galileo + GLONASS Avec RTK (vert. ±0,1 m ; hor. ±0,1 m) Sans RTK (vert. ±0,5 m ; hor. ±1,5 m)		
Caméra	RGB Red (R) : 700 nm* Green (G) : 546,1 nm* Blue (B) : 453,8 nm*	RGB Red (R) : 700 nm* Green (G) : 546,1 nm* Blue (B) : 453,8 nm*	Multispectrale Green (G): 560 ± 16 nm Red (R): 650 ± 16 nm Red Edge (RE): 730 ± 16 nm Near IR (NIR): 860 ± 26 nm	MicaSense Altum-PT (Multispectrale) (+/-20000€ ; 577g) Blue (B): 475 nm ± 32 nm Green (G) : 560 nm ± 27 nm Red (R) : 668 nm ± 14 nm Red Edge (RE) : 717 nm± 12 nm Near-IR (NIR) : 842 nm ± 57 nm Panchromatique (PAN) : 450 – 745 nm Thermique (LWIR) : 7,5 -13,5µm + DLS	Zemuse L1 (Lidar) (+/-12000€ ; 930 g)	
					Lidar Livox	RGB Red (R) : 700 nm* Green (G) : 546,1 nm* Blue (B) : 453,8 nm*
Capteur et résolution	1/2.3" CMOS 12 MP (4000x3000)	4/3 CMOS 20 MP (5280x3956)	1/2.8-inch CMOS 5 MP (2592x1944)	3,2 MP/bande (2064 x 1544) 12,4 MP PAN (4112 x 3008) 0,082 MP LWIR (320 × 256)	240 000pts/s Support : 3 retours	1 inch CMOS 20 MP (5472x3078)
Lentille	FOV: 83° Focal length : 24 mm Aperture: f/2.8	FOV: 84° Focal length: 24 mm Aperture: f/2.8 to f/11	FOV: 73.91° Focal length: 25 mm Aperture: f/2.0	FOV MS : 50° H x 38° V FOV PAN : 46° H x 35° V FOV LWIR : 48° H x 40° V Focal length MS: 8 mm Focal length PAN: 16,3 mm Focal length LWIR: 4,5 mm	Scan non-répétitif : FOV : 70.4° H × 77.2° V Scan répétitif : FOV : 70.4° H × 4.5° V	Focal length : 24mm Aperture : f/2.8 - f/11
Obturbateur	Electronique : 4-1/8000 s	Electronique : 8-1/8000 s Mécanique : 8-1/2000 s	Electronique : 1/30~1/12800 s	Global	/	Mécanique : 1/2000 - 8 s Electronique : 1/8000 - 8 s

³ *= Longueurs d'onde par définition car non-renseignées par le constructeur.

4.4.2. Plan et données de vol

Les vols ont été réalisés aux mêmes dates que la prise des données de référence. Les vols du Mini 2 ont été programmés via l'application Dronelink (Dronelink, Austin, Etats-Unis) alors que les vols des drones 3M et M300 ont été programmés directement sur la radiocommande via l'application propriétaire DJI Pilot 2. Pour tous les vols, l'altitude a été fixée à 50 m (Hyowon Lee et al., 2015; Barnetson et al., 2020; Grüner et al., 2020) permettant d'obtenir une distance d'échantillonnage au sol (GSD) de l'ordre du centimètre, acceptable pour l'échelle de travail appliquée. Le recouvrement latéral et le frontal ont été fixés à 80 % (Assmann et al., 2019; Kümmerer et al., 2023). Cette valeur a été sélectionnée selon les recommandations de Assmann et al. (2019), afin de s'assurer d'obtenir plusieurs images d'un même endroit de sol. La vitesse de vol a été fixée à 2 m/s afin d'éviter toute zone floue (Grüner et al., 2020). Pour le vol avec le LiDAR, le recouvrement latéral et frontal a été fixé sur 50 %, avec l'utilisation d'un scan répétitif avec un retour triple. Les vols ont tous été réalisés entre 11h et 14h (UTC+2) afin d'éviter des variations trop importantes de l'angle solaire (Assmann et al., 2019; Barnetson et al., 2020; Wijesingha et al., 2020). Les vols couvrant une surface de 1,5 ha duraient de 12 à 15 minutes pour les caméras spectrales et 10 minutes pour le LiDAR. Les caméras étaient en position nadir.

Dans l'optique de la calibration de la réflectance, avant et après chaque vol, une photographie d'un panneau de réflectance connue fourni avec la MicaSense Altum-PT a été réalisée avec chaque drone à une hauteur de 1 m tout en s'assurant de ne pas obscurcir celui-ci avec le drone.

Les conditions météo présentées dans le Tableau 4 sont issues de la plateforme météo du CRA-W « Agromet » (“Agromet.be,” Juillet-26-2024) pour la station située à Gembloux. Le ciel du 10 avril était dégagé avec quelques nuages éparses. Les vols étaient mis en pause lorsqu'un de ceux-ci obscurcissait la zone afin d'éviter de trop fortes variations d'illumination. Lors des vols du 8 mai et du 3 juin, le ciel présentait une couverture nuageuse continue, avec une illumination diffuse plus constante (Figure 10).

Tableau 4 - Conditions météorologiques des trois dates de vol à 13h UTC+2 (moyenne horaire).

	Ensoleillement [W/m ²]	Température [°C]	Précipitations [mm]	Humidité relative [%]	Vitesse _{vent} à 2m [m/s]
10 avril	825	11,6	0,0	58,8	3,7
8 mai	321	12,0	0,0	82,4	2,8
3 juin	442	13,2	0,0	70,2	1,6



Figure 10 - Photos du ciel aux dates du 10 avril (gauche) et du 8 mai (droite).

4.4.3. Pré-traitement des données

4.4.3.1. Nuage de points LiDAR

En ce qui concerne les données issues du LiDAR DJI Zenmuse L1, celles-ci ont été traitées via le logiciel DJI Terra. Le nuage de point global a été généré en qualité « élevée », avec un filtre à 300 m. Ce nuage a ensuite été prétraité en R version 4.3.2. (*R Foundation for Statistical Computing*, Vienne, Autriche) dans l'environnement RStudio version 2023.12.1. avec l'aide du package « lidR » (Roussel et al., 2024). Ce prétraitement a consisté en un dé-densification à 500 points/m² ainsi qu'à l'élimination des valeurs aberrantes via l'algorithme de classification de bruit « *statistical outliers removal* » (sor). Dans ce cas, par essai-erreur, les valeurs de « k » et « m » ont respectivement été fixées à 20 et à 10. Le nuage de points a ensuite été traité via deux flux de travail différents (Figure 11).

Le premier consiste en une classification du nuage de points pour identifier les points de sol avec l'algorithme « *progressive morphological filter* » (pmf). Les valeurs de fenêtre (ws) et de seuil (th) ont été fixées à 10 et 0,001. Elles ont été déterminées sur base de nombreux tests sur un plus petit jeu de données. Après cette classification, une normalisation a été réalisée avec l'algorithme « *triangular irregular network* » (tin). Cet algorithme est basé sur une interpolation linéaire entre les points de sol. La hauteur de chaque point au-dessus du sol est ensuite définie par différence avec ce modèle de sol. Diverses statistiques de hauteur utilisant l'ensemble des points au sein de chaque unité d'échantillonnage peuvent ensuite être calculées. Parmi celles-ci, le maximum, la moyenne, l'écart-type ainsi que les percentiles de 5 à 95 par pas de 5 ont été conservés. Cette première méthode de traitement sera dénommée « Normalisation LiDAR » dans l'analyse des résultats. Les détails des différentes étapes pour les trois jeux de données (vols) sont visibles dans le Tableau 5.

Tableau 5 - Evolution du nuage de points LiDAR lors du traitement.

	Nombre points [en millions]		Densités de points [pts/m ²]		Bruit	Points de sol
	Avant dé-densification	Après dé-densification	Avant dé-densification	Après dé-densification		
10 avril	32,73	6,62	2395,0	484,5	3667	204.166 (3%)
8 mai	27,53	6,32	2099,4	482,0	7450	140.431 (2,2%)
3 juin	32,30	7,05	2201,3	480,7	78	52651 (0,7%)

Le deuxième flux de travail appliqué au nuage de points est basé sur des principes de rasterisation afin de mener à la création d'un MNT et d'un MNS. Le MNT a été créé en conservant, pour chaque fenêtre d'une résolution de 20 cm, le point du nuage non-classifié présentant l'altitude la plus basse afin de vérifier si cette voie pouvait se substituer à une classification de points de sol. Ensuite, un MNS a été réalisé en exécutant le même procédé mais en prenant cette fois comme altitude le 90e percentile de chacune de ces fenêtres. Ce n'est pas la valeur maximale qui a été utilisée pour éviter qu'un point unique trop élevé ne fausse le modèle. Le MNT a ensuite été soustrait au MNS afin d'obtenir un MNH. Une valeur a ensuite été extraite pour chacune des unités d'échantillonnage en conservant la valeur du pixel (d'une résolution de 20 cm) qui recouvrait le centroïde, celui-ci étant le plus représentatif de l'unité. Cette seconde méthode, se différencie de la première car elle permet d'obtenir un lissage plus important des différentes valeurs au dépend d'une résolution spatiale fortement réduite mais tout de même acceptable vis-à-vis de l'échelle de travail. Elle sera dénommée « Rasterisation LiDAR » dans la comparaison des résultats.

Matériel et méthodes

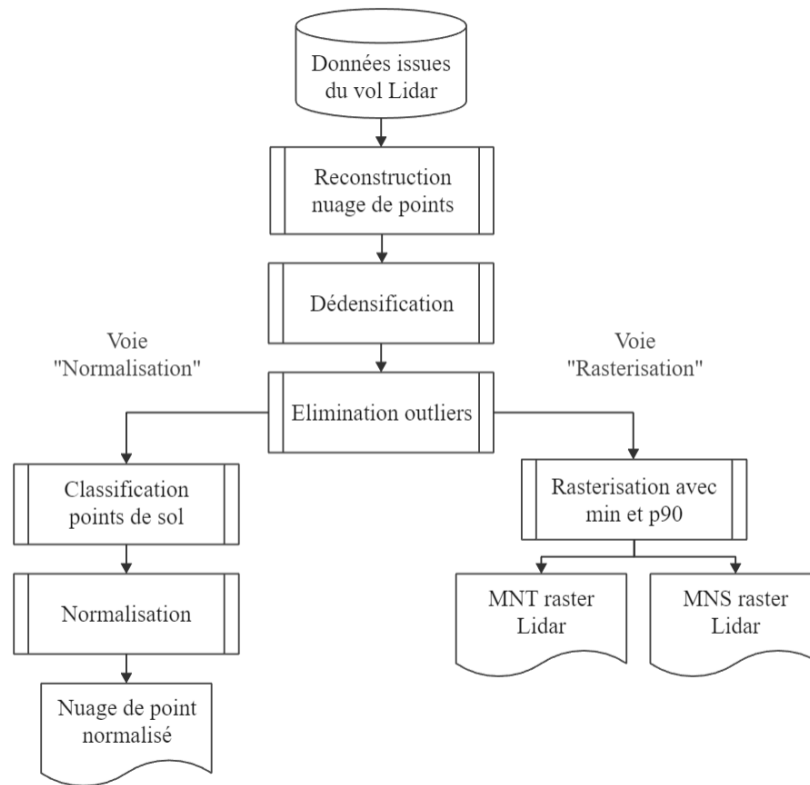


Figure 11 - Organigramme du flux de travail appliqué lors du traitement des données LiDAR.

4.4.3.2. Images spectrales

Les images spectrales (RGB et MS) prélevées lors des différents vols ont été traitées à l'aide de la version 2.0.2 du logiciel de traitement photogrammétrique Agisoft Metashape Professional (Agisoft LLC, Saint-Petersbourg, Russie) (Viljanen et al., 2018; Grüner et al., 2019, 2020; Rueda-Ayala et al., 2019; Michez et al., 2020). Le DJI Mavic 3M possédant une caméra RGB (format Jpeg) ainsi qu'une caméra multispectrale (format Tiff), les images ont été traitées séparément selon le même processus et deux orthomosaïques différentes ont été générées (Figure 12).

Les images aériennes ont tout d'abord été importées et leur qualité a été évaluée grâce à une fonction d'estimation automatique de la qualité des images du logiciel. Les images avec une qualité inférieure à 0,5 ont été écartées, comme recommandé par le manuel d'utilisateur du logiciel ("Agisoft Metashape: User Manuals," Juillet-26-2024). Les images ont ensuite été alignées avec une qualité fixée sur « Très haute précision ». Le paramètre « Limite de points » a été fixé à 60.000 (afin d'obtenir une qualité encore meilleure que Viljanen et al. (2018) qui fixent ce paramètre sur 40.000) et le paramètre « Limite de points de liaison » à 0, permettant de ne pas fixer de limite pour cette valeur ("Agisoft Metashape: User Manuals," Juillet-26-2024). La correction géométrique du modèle a été réalisée grâce à l'importation des coordonnées géographiques des GCP. Ceux-ci ont été repérés manuellement sur les images. Le nuage de point clairsemé issu de l'étape d'alignement a ensuite été optimisé avec cinq GCP et sa qualité évaluée grâce au sixième point, utilisé en validation. Le modèle a ensuite été optimisé à nouveau avec l'ensemble des GCP afin d'assurer la meilleure précision possible pour la suite du traitement. La réflectance des images multispectrales a ensuite été calibrée grâce à l'utilisation des images du panneau de réflectance connue. Pour les images RGB, cette étape a été passée, la largeur de leurs trois bandes étant inconnue et la calibration s'est limitée à une standardisation lors de l'exportation. Par après, le nuage de points dense a été généré en fixant la qualité à « Ultra haute », permettant au logiciel de travailler sur les images avec leur taille originale ("Agisoft Metashape: User Manuals," Juillet-26-2024).

Matériel et méthodes

Afin d'obtenir un niveau de lissage des cartes de profondeur faible et de préserver un maximum de détails, le paramètre de profondeur de filtrage a été fixé sur « Léger ». Dans Metashape, il existe trois outils de classification des points, à savoir, une « classification automatique des points de terrain », une « classification automatique multi-classe » et une « classification manuelle ». Howland et al. (2022) ont conclu à une meilleure performance du premier. C'est celui-ci qui a été utilisé pour réaliser une classification qui s'est vue agressive afin de ne pas classer trop de végétation basse comme appartenant au sol. Par essai-erreur et appréciation visuelle, les paramètres ont été fixés à 10° pour l'angle maximal, à 0,0002 m pour la distance maximale et à 10 m pour la taille des cellules en lesquelles le nuage était divisé. Un premier modèle numérique d'élévation a été généré à partir des points de sol uniquement afin d'obtenir un MNT (appelé « MNT Metashape »). Un second a ensuite été généré en utilisant tous les points afin d'obtenir un MNS (appelé « MNS Metashape »). Les deux modèles ont été réalisés en projection géographique en se basant sur le nuage de points dense et avec le mode « interpolation » activé. Un maillage a ensuite été généré à partir du nuage dense avec un type de surface défini sur « Champs de hauteur », conseillé pour la photographie aérienne et un nombre de faces fixé sur « Haut ». Une orthomosaïque a finalement été générée à partir de ce maillage avec une taille de pixel laissée à sa valeur par défaut (Tableau 6). En ce qui concerne leur exportation, les orthomosaïques multispectrales ont été exportées en divisant les valeurs de chacune de ses bandes par 32.768 afin de passer des valeurs entières en 16 bits à une réflectance normalisée entre 0 et 1 ("MicaSense RedEdge MX processing workflow (including Reflectance Calibration) in Agisoft Metashape Professional," Juillet-26-2024). Les orthomosaïques RGB n'ayant pas été calibrées, celles-ci ont été divisées par la somme des valeurs des trois autres bandes afin de les « standardiser » en fonction de la luminosité totale et d'obtenir des valeurs comparables malgré des conditions d'ensoleillement variables (Michez et al., 2018). Ces données seront, par opposition aux données issues du vol LiDAR, appelées « photogrammétriques ». Un visuel des produits intermédiaires et finaux de ce traitement est présenté dans l'Annexe A.

Tableau 6 - Métadonnées des reconstructions des différents jeux de données sur Agisoft Metashape.

Vols	Drone	Image	Nombre images	Points de liaison	Nuage de point	Points de sol	Résolution rasters [cm/px]
10 avril	Mini 2	RGB	136	403.098	51.861.038	8290	1,75
	3M	RGB	180	939.150	12.988.271	296.944	1,44
		MS	180	3.842.080	20.449.604	15.592	2,48
		M300 - MicaSense	MS	716	55.591.223	21.220.069	21.905
8 mai	Mini 2	RGB	136	160.098	65.172.741	1485	1,73
	3M	RGB	177	739.386	75.995.357	50.518	1,44
		MS	177	3.842.750	22.583.768	5.745	2,47
		M300 - MicaSense	MS	535	16.507.965	24.971.963	12.711
3 juin	Mini 2	RGB	98	115.104	45.389.585	14.980	1,61
	3M	RGB	144	730.933	16.603.075	158.528	1,39
		MS	144	7.080.049	5.111.573	2305	2,38
		M300 - MicaSense	MS	542	13.654.428	6.201.527	1527

Matériel et méthodes

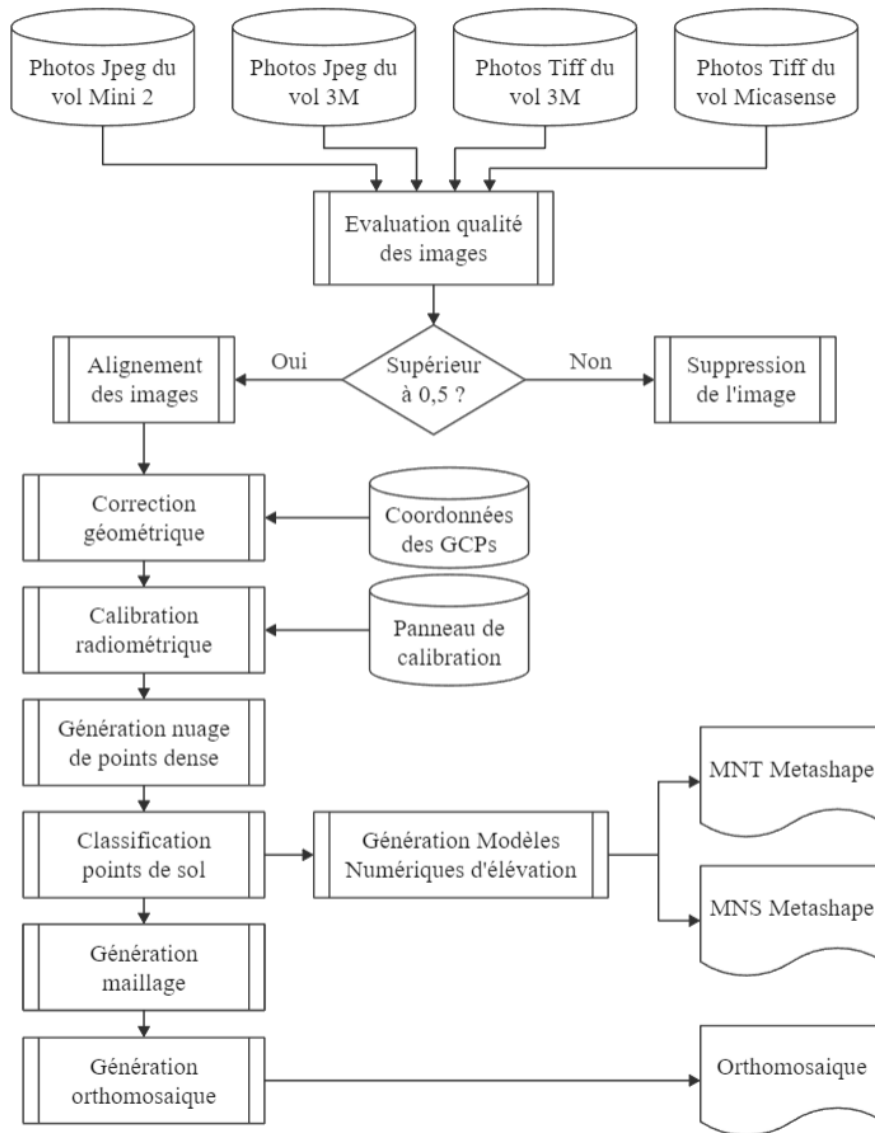


Figure 12 - Organigramme du flux de travail appliqué lors de la reconstruction photogrammétrique.

4.5. Modèles d'estimation des variables d'intérêt sur les prairies

4.5.1. Estimation de la hauteur

En ce qui concerne les données issues de la reconstruction photogrammétrique, trois MNT différents ont été soustraits du MNS issu de Metashape afin de créer, pour chaque drone, trois modèles numériques de hauteur d'herbe devant être, in fine, comparés (Figure 13).

Le premier MNT est celui généré sur Metashape après la classification de point comme mentionné dans le paragraphe précédent. Il présente donc la même résolution que le MNS et est aussi exprimé en hauteur au-dessus de l'ellipsoïde. Après soustraction, un premier MNH a été généré, dont la hauteur maximum, la moyenne, l'écart-type ainsi que les percentiles 5 à 95 par pas de cinq ont été extraits.

Le second MNT comparé est le MNT de la Wallonie issu d'acquisitions LiDAR effectuées en 2021 et 2022 disponible sur WalOnMap ("Géoportail de la Wallonie," Février-29-2024). Il est d'une résolution de 0,5 m et son altitude est exprimée en hauteur orthométrique. Sa référence altimétrique est le Deuxième Nivellement Général (EPSG : 5710) avec une précision altimétrique de 0,12 m. Afin de convertir cette hauteur orthométrique en hauteur ellipsoïdale, le modèle gravitationnel de la Terre EGM2008 de résolution 1'x1' (minute d'arc) a été utilisé. Une fois cette conversion faite, il a été nécessaire de réduire la résolution du MNS jusqu'à celle du MNT afin de pouvoir réaliser la soustraction. La résolution de ce modèle étant de 50 cm, seule la valeur du pixel recouvrant le centroïde a pu être extraite.

Le troisième et dernier MNT comparé n'est autre que le MNT issu de la rasterisation du nuage de points du vol LiDAR, qui, comme déjà mentionné, est parfois considéré comme étant la référence. Sa résolution étant de 0,2 m, il a été ici aussi nécessaire d'ajuster la résolution afin de permettre la soustraction. Les mêmes métriques que pour le premier MNH ont été extraites.

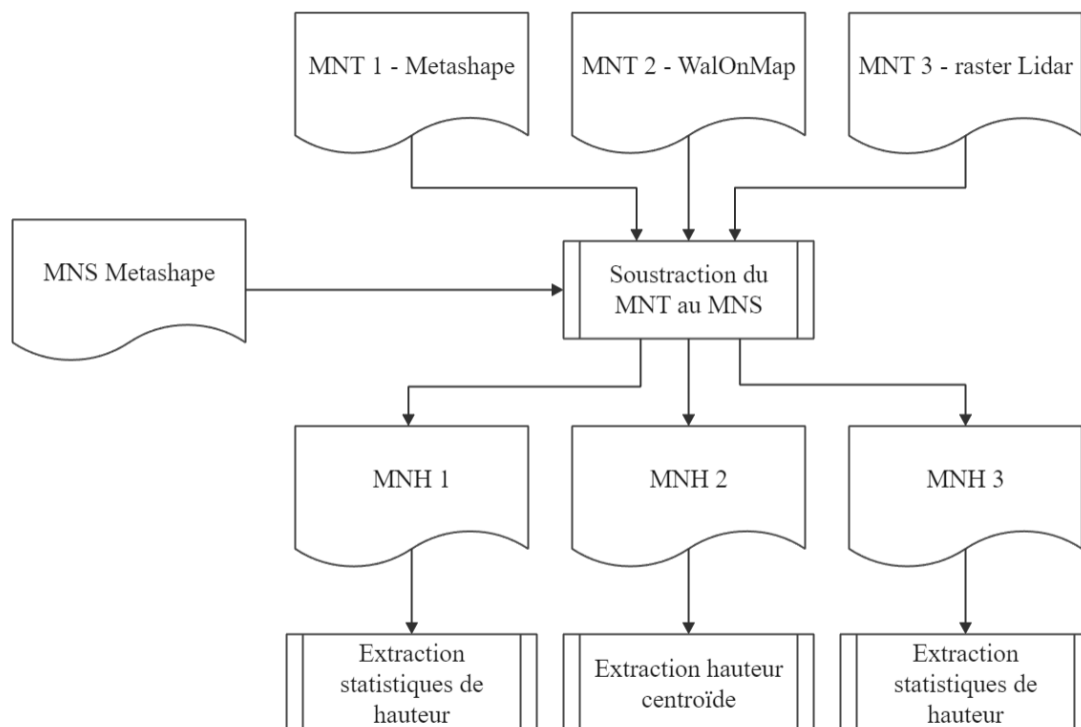


Figure 13 - Organigramme des sources de MNT utilisées pour le calcul des différents MNH.

Les 9 jeux de données photogrammétriques (combinaison croisée des trois drones et des trois sources de MNT) ainsi que les 2 jeux de données LiDAR (normalisation et rasterisation) ont ensuite été comparés en réalisant des régressions linéaires univariées (RLU) afin d'expliquer la médiane de référence de mesurée au sol pour chaque unité d'échantillonnage. Le modèle est le suivant :

Modèles 1 à 9 : Hauteur médiane $_{REF} = f(\text{statistique de hauteur}_{MNH(3 \times 3)})$

Modèle 10 et 11 : Hauteur médiane $_{REF} = f(\text{statistique de hauteur}_{LiDAR(\text{norm. et raster})})$

Pour les jeux de données où plusieurs métriques/statistiques étaient disponibles, la métrique la plus fortement corrélée avec cette médiane a été retenue. La normalité des résidus a été vérifiée via un test de Shapiro tout comme l'homoscédasticité via l'analyse du graphe des résidus en fonction des valeurs prédites. Pour les régressions où ces conditions n'étaient pas vérifiées, des transformations linéaires ont été réalisées sur la variable à expliquer, respectivement, des transformations racine carré, racine cubique, log2 et inverse. Les modèles ont ensuite été soumis au jeu de données de validation. Afin de différencier statistiquement les différentes régressions, leurs résidus en validation ont été comparés au moyen d'un ANOVA à deux facteurs (drone et MNT). Les conditions d'applications de celle-ci ayant été rejetées après un test de Shapiro et un test de Levene, le package R « ARTool », permettant de réaliser des ANOVA non-paramétriques, a été utilisé (Kay et al., 2021). Une décomposition a ensuite été faite selon chaque facteur et des tests de Kruskal-Wallis exécutés. Finalement un test de comparaison multiple de Dunn a été réalisé lorsque des différences significatives étaient mises en évidence. En termes de visualisation, les modèles ont ensuite été appliqués spatialement sur la prairie de validation afin d'obtenir des cartes de hauteur prédite, avec une résolution abaissée à 1,5 m afin de gagner du temps lors du processus d'édition.

4.5.2. Estimation de la biomasse

Un premier modèle d'estimation de la biomasse a été calculé à partir des données de hauteur d'herbe comprimée prise à l'aide de l'herbomètre. Cette méthode étant la plus utilisée en pratique, elle servira de point de comparaison aux autres modèles développés avec les informations issues des drones. Cette estimation a pris la forme d'une régression linéaire univariée. Le modèle est le suivant :

Modèle 12 : Biomasse $_{REF} = f(\text{hauteur comprimée}_{HERBO})$

A partir des orthomosaïques RGB et multispectrales, différents IV ont été calculés et leur valeur médiane extraite pour chaque unité. Les IV_{RGB} (Tableau 7) ont aussi été calculés pour les orthomosaïques multispectrales étant donné que leurs bandes étaient disponibles. Pour le 3M, les IV_{RGB} étaient calculés à partir de l'orthomosaïques RGB et les IV_{MS} (Tableau 8), à partir de l'orthomosaïques multispectrale.

Tableau 7 - Indices de végétation calculés à partir de l'imagerie RGB et multispectrale.

VI	Nom	Formule	Source
PPR	Indice de rapport de pigment végétal	$(G-B)/(G+B)$	Lussem et al., 2019
GRDI	Indice de différence vert rouge	$(G-R)/(G+R)$	Lussem et al., 2019
ExG	Indice de végétation d'excès de vert	$(2 * G - (R+B))$	Borra-Serrano et al., 2019
VARI	Indice visible de réduction des effets atmosphériques	$(G-R)/(G+R-B)$	Michez et al., 2020

Matériel et méthodes

Tableau 8 - Indices de végétation calculés à partir de l'imagerie multispectrale.

VI	Nom	Formule	Source
NDVI	Indice de végétation par différence normalisé	$(\text{NIR}-\text{R})/(\text{NIR}+\text{R})$	Théau et al., 2021
GNDVI	NDVI vert	$(\text{NIR}-\text{G})/(\text{NIR}+\text{G})$	Théau et al., 2021
NDRE	Indice de différence normalisé du bord-rouge	$(\text{NIR}-\text{RE})/(\text{NIR}+\text{RE})$	Théau et al., 2021
GRVI	Indice de végétation du rapport vert	(NIR/G)	Michez et al., 2020

Afin d'estimer la biomasse de chaque unité d'échantillonnage, différents types de modèles ont été développés pour chacun des trois drones. Les premiers sont des RLM avec sélection de variables via les méthodes « *stepwise* », « *forward* » et « *backward* » basées sur le critère d'information d'Akaike (AIC). Au vu de la colinéarité des variables explicatives utilisées, des modèles PCR (« *principal component regression* ») et PLS ont aussi été testés pour un nombre de composantes expliquant 99 % de la variabilité des variables explicatives. Une RF avec optimisation du nombre d'arbres (ntree), du nombre de variables testées à chaque division (mtry) et de la taille minimale du nœud (ns) a aussi été testée, tout comme des SVM linéaires et radiaux (avec optimisation de la fonction de coût (C) et du facteur de généralisation (sigma)). Cela représente au total huit types de modèles. Les variables explicatives utilisées variaient selon le drone, ceux-ci étant équipés de capteurs différents.

En ce qui concerne le Mini 2, huit modèles ont été développés en utilisant uniquement les IV_{RGB} (4 variables). De nouveaux ont ensuite été développés en ajoutant les statistiques de hauteur (moyenne, max, sd, percentiles 25, 50, 75 et 90) issues du MNH1 (11 variables).

Modèles 13 8 types : $\text{Biomasse}_{\text{REF}} = f(IV_{\text{RGB-Mini2}})$

Modèles 14 8 types : $\text{Biomasse}_{\text{REF}} = f(IV_{\text{RGB-Mini2}} ; \text{statistiques hauteur}_{\text{MNH1-Mini2}})$

Pour le 3M, les mêmes modèles que pour le Mini 2 ont été développés. Un troisième type a utilisé les IV_{RGB} , les statistiques de hauteur et les IV_{MS} (15 variables) afin de comparer l'apport de la caméra multispectrale.

Modèles 15 8 types : $\text{Biomasse}_{\text{REF}} = f(IV_{\text{RGB-3M}})$

Modèles 16 8 types : $\text{Biomasse}_{\text{REF}} = f(IV_{\text{RGB-3M}} ; \text{statistiques hauteur}_{\text{MNH1-3M}})$

Modèles 17 8 types : $\text{Biomasse}_{\text{REF}} = f(IV_{\text{RGB-3M}} ; IV_{\text{MS-3M}} ; \text{statistiques hauteur}_{\text{MNH1-3M}})$

Enfin, pour la MicaSense Altum-PT du M300, les mêmes types de modèles que pour le 3M ont été développés. Un modèle supplémentaire incluant la valeur brute de réflectance de la bande panchromatique (PAN) et de la bande thermique (LWIR) a finalement été testé afin de conclure sur un éventuel apport de leur part.

Modèles 18 8 types : $\text{Biomasse}_{\text{REF}} = f(IV_{\text{RGB-Mica}})$

Modèles 19 8 types : $\text{Biomasse}_{\text{REF}} = f(IV_{\text{RGB-Mica}} ; \text{statistiques hauteur}_{\text{MNH1-Mica}})$

Modèles 20 8 types : $\text{Biomasse}_{\text{REF}} = f(IV_{\text{RGB-Mica}} ; IV_{\text{MS-Mica}} ; \text{statistiques hauteur}_{\text{MNH1-Mica}})$

Modèles 21 8 types : $\text{Biomasse}_{\text{REF}} = f(IV_{\text{RGB-Mica}} ; IV_{\text{MS-Mica}} ; \text{statistiques hauteur}_{\text{MNH1-Mica}} ; \text{réflectance}_{\text{PAN}} ; \text{réflectance}_{\text{LWIR}})$

4.5.3. Classification de la composition floristique

Les proportions relatives des différentes « formes de vie » définies plus haut n'étant pas assez variables pour faire de la régression, le choix a été fait de se tourner vers des algorithmes de classification. Pour ce faire, chaque unité d'échantillonnage s'est vue attribuer une classe, inspirée de Crabbe et al. (2020) mais adaptée au jeu de données pour assurer un nombre suffisant d'enregistrements dans chaque classe. Les unités se sont vues étiquetées « classe 1 » lorsque leur proportion de graminées dépassait les 90 % et « classe 2 » dans les autres cas. Les variables explicatives utilisées sont les mêmes que pour les modèles de biomasse 14, 17 et 21. Les algorithmes de classification utilisés sont une analyse discriminante linéaire, la méthode des plus proches voisins (KNN), une RF, une PLS-DA (« *partial least square – discriminant analysis* ») et un SVM linéaire.

4.6. Evaluation des modèles

Pour estimer la qualité globale des régressions, le coefficient de détermination (R^2), la Racine carré de l'erreur quadratique moyenne (RMSE) et la Racine carré relative de l'erreur quadratique moyenne (rRMSE) ont été calculés lors de la calibration et de la validation (Tableau 9).

Tableau 9 – Formules des indicateurs de qualité des régressions.

Indicateur	Nom	Equation	Unité
Racine de l'Erreur Quadratique Moyenne	RMSE	$\sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}}$	[m] ou [kgMS/ha]
RMSE relative	rRMSE	$100\% * \frac{RMSE}{\bar{y}}$	[%]
Coefficient de Détermination	R^2	$1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$	[-]

où :

- \hat{y} = la valeur prédite
- y = la valeur réelle
- \bar{y} = la moyenne des valeurs réelles
- n = le nombre d'observations

En ce qui concerne les algorithmes de classification développés pour l'estimation de la composition floristique, leurs performances ont été évaluées grâce à leur sensibilité (proportion de « classe 1 » effectivement classé comme tel), leur spécificité (proportion de « classe 2 » effectivement classé comme tel) et leur coefficient Kappa de Cohen permettant de prendre en compte la probabilité de classer correctement un échantillon au hasard (Tableau 10) (Buitrago et al., 2018).

Tableau 10 - Formules des indicateurs de qualité des classificateurs.

Indicateur	Equation	Unité
Sensibilité	$V1 / V1 + F2$	[-]
Spécificité	$V2 / V2 + F1$	[-]
Coefficient Kappa	$\frac{2 * (V1 * V2 - F1 * F2)}{(V1 + F1) * (F1 + V2) + (V1 + F2) * (F2 + V2)}$	[-]

où :

- V1 = classé « 1 », effectivement « 1 »
- V2 = classé « 2 », effectivement « 2 »
- F1 = classé « 1 », alors que « 2 »
- F2 = classé « 2 », alors que « 1 »

5. Résultats

5.1. Géoréférencement

En ce qui concerne la précision de géoréférencement, les Tableaux 11 et 12 présentent les erreurs de géolocalisation lors des trois vols, respectivement avant et après optimisation avec les 5 GCP.

Le Mini 2 présente des erreurs systématiques de plus d'un mètre en termes de longitude qui peuvent descendre à moins d'un centimètre après correction géométrique. Pour l'altitude, il présente une erreur très variable de plus de 100 m dû à un référencement altimétrique différent et inconnu. Le 3M, qui dispose d'un GNSS RTK embarqué, présente une erreur réduite par rapport au Mini 2, avec tout de même une erreur altimétrique non-négligeable, qui atteint jusqu'à 26 cm pour le vol du 3 juin. L'utilisation des GCP permet de ramener cette précision à une erreur approchant les 7 cm. Enfin, le M300, qui dispose lui aussi d'un système de positionnement RTK, a tendance à présenter des erreurs en longitude et latitude plus élevées que le 3M pour une erreur en altitude du même ordre de grandeur. Après optimisation, le vol du 3 juin présente toujours une erreur de 16 cm.

Les jeux de données utilisés présentant des hauteurs d'herbe allant de 8 à 65 cm, les erreurs avant optimisation permettent de réfuter *l'hypothèse 1* d'inutilité d'utilisation de GCP en présence d'un module RTK.

Tableau 11 - Précision géographique des reconstructions photogrammétriques avant optimisation.

	Mini 2			3M			M300		
	Long. err. [m]	Lat. err. [m]	Alt. err. [m]	Long. err. [m]	Lat. err. [m]	Alt. err. [m]	Long. err. [m]	Lat. err. [m]	Alt. err. [m]
10 avril	1,252	0,224	196,471	0,0615	0,0524	0,0993	0,140	0,0867	0,134
8 mai	1,405	0,491	178,139	0,0463	0,0428	0,182	0,0805	0,0702	0,173
3 juin	1,0872	1,164	104,004	0,0404	0,0408	0,265	0,160	0,109	0,286

Tableau 12 - Précision géographique des reconstructions photogrammétriques après optimisation.

	Mini 2			3M			M300		
	Long. err. [m]	Lat. err. [m]	Alt. err. [m]	Long. err. [m]	Lat. err. [m]	Alt. err. [m]	Long. err. [m]	Lat. err. [m]	Alt. err. [m]
10 avril	0,0963	0,139	0,00879	0,00616	0,00868	0,00826	0,00510	0,0253	0,0258
8 mai	0,0160	0,00854	0,0622	0,0131	0,0195	0,0691	0,0156	0,00767	0,0897
3 juin	0,00533	0,0102	0,137	0,00744	0,00692	0,0687	0,00207	0,0174	0,157

5.2. Estimation de la hauteur

La comparaison des neuf régressions linéaires univariées issues de la photogrammétrie (modèles 1 à 9) met en évidence des performances variables selon le drone et le MNT utilisés. La variable explicative sélectionnée varie du 45^e au 65^e centile selon le modèle mais toutes présentent un coefficient de corrélation proche de 0,8. Les performances en calibration des différentes régressions sont relativement semblables quand leurs performances en validation sont très variables. En termes de RMSE, la meilleure régression est celle de la combinaison de la MicaSense avec le MNT 3 avec une erreur de 0,0902 m tandis que la moins bonne résulte de l'utilisation du Mini 2 avec le MNT 1 pour une erreur de 0,253 m.

Résultats

Tableau 13 - Résumé comparatif des neuf régressions linéaires réalisées par photogrammétrie.

	Mini 2		3M		MicaSense	
MNT 1	Variable explicative (x) : 45 ^e centile Coef. de corrélation : 0,848 Equation : y = 0,0947 + 0,709*x Shapiro p-val = 0,0718		Variable explicative (x) : 60 ^e centile Coef. de corrélation : 0,810 Equation : y = 0,112+ 1,065*x Shapiro p-val = 0,411		Variable explicative (x) : 65 ^e centile Coef. de corrélation : 0,835 Equation : sqrt(y) = 0,3659+ 0,904*x Shapiro p-val = 0,154	
	$R^2_{\text{calib.}} = 0,717$	$R^2_{\text{valid.}} = 0,343$	$R^2_{\text{calib.}} = 0,654$	$R^2_{\text{valid.}} = 0,663$	$R^2_{\text{calib.}} = 0,630$	$R^2_{\text{valid.}} = 0,628$
	RMSE _{calib.} [m]=0,0637 rRMSE _{calib.} [%] = 24,1	RMSE _{valid.} [m] = 0,253 rRMSE _{valid.} [%] = 62,4	RMSE _{calib.} [m]=0,0705 rRMSE _{calib.} [%] = 26,6	RMSE _{valid.} [m] = 0,132 rRMSE _{valid.} [%] = 32,5	RMSE _{calib.} [m]=0,0669 rRMSE _{calib.} [%] = 25,2	RMSE _{valid.} [m] = 0,132 rRMSE _{valid.} [%] = 32,5
MNT 2	Variable explicative (x) : valeur centroïde Coef. de corrélation : 0,830 Equation : y = 2,448 + 0,927*x Shapiro p-val = 0,0346*		Variable explicative (x) : valeur centroïde Coef. de corrélation : 0,818 Equation : sqrt(y) = 2,529 + 0,869*x Shapiro p-val = 0,0683		Variable explicative (x) : valeur centroïde Coef. de corrélation : 0,764 Equation : y = 1,709 + 0,620*x Shapiro p-val = 0,0575	
	$R^2_{\text{calib.}} = 0,686$	$R^2_{\text{valid.}} = 0,0731$	$R^2_{\text{calib.}} = 0,647$	$R^2_{\text{valid.}} = 0,626$	$R^2_{\text{calib.}} = 0,581$	$R^2_{\text{valid.}} = 0,519$
	RMSE _{calib.} [m]=0,0671 rRMSE _{calib.} [%] = 25,3	RMSE _{valid.} [m] = 0,221 rRMSE _{valid.} [%] = 54,5	RMSE _{calib.} [m]=0,0690 rRMSE _{calib.} [%] = 26,0	RMSE _{valid.} [m] = 0,153 rRMSE _{valid.} [%] = 37,6	RMSE _{calib.} [m]=0,0775 rRMSE _{calib.} [%] = 29,3	RMSE _{valid.} [m] = 0,0925 rRMSE _{valid.} [%] = 22,8
MNT 3	Variable explicative (x) : 65 ^e centile Coef. de corrélation : 0,864 Equation : sqrt(y) = 0,295 + 0,881*x Shapiro p-val = 0,856		Variable explicative (x) : 50 ^e centile Coef. de corrélation : 0,881 Equation : y = -0,0158 + 1,131*x Shapiro p-val = 0,0142		Variable explicative (x) : 45 ^e centile Coef. de corrélation : 0,821 Equation : y = 0,0842+ 0,738*x Shapiro p-val = 0,1866	
	$R^2_{\text{calib.}} = 0,726$	$R^2_{\text{valid.}} = 0,113$	$R^2_{\text{calib.}} = 0,774$	$R^2_{\text{valid.}} = 0,731$	$R^2_{\text{calib.}} = 0,672$	$R^2_{\text{valid.}} = 0,547$
	RMSE _{calib.} [m]=0,0608 rRMSE _{calib.} [%] = 22,9	RMSE _{valid.} [m] = 0,233 rRMSE _{valid.} [%] = 57,4	RMSE _{calib.} [m]=0,0570 rRMSE _{calib.} [%] = 21,5	RMSE _{valid.} [m] = 0,172 rRMSE _{valid.} [%] = 42,3	RMSE _{calib.} [m]=0,0686 rRMSE _{calib.} [%] = 25,9	RMSE _{valid.} [m] = 0,0902 rRMSE _{valid.} [%] = 22,2

Résultats

En ce qui concerne les deux régressions réalisées à partir des données du vol LiDAR (modèles 10 et 11), c'est la méthode par « Normalisation » qui présente les meilleures performances avec une RMSE de 0,0824 m.

Tableau 14 - Tableau comparatif des deux régressions linéaires réalisée par vol LiDAR.

	Normalisation		Rasterisation	
	Variable explicative (x) : 90 ^e centile		Variable explicative (x) : 90 ^e centile (lors rasterisation)	
	Coef. de corrélation : 0,769		Coef. de corrélation : 0,525	
	Equation : $y = 0,117 + 1,518 * x$		Equation : $\text{sqrt}(y) = 0,3882 + 1,721 * x$	
	Shapiro p-val = 0,0667		Shapiro p-val = 0,5134	
Lidar				
	$R^2_{\text{calib.}} = 0,588$	$R^2_{\text{valid.}} = 0,700$	$R^2_{\text{calib.}} = 0,240$	$R^2_{\text{valid.}} = 0,173$
	$\text{RMSE}_{\text{calib.}} [\text{m}] = 0,0768$	$\text{RMSE}_{\text{valid.}} [\text{m}] = 0,0824$	$\text{RMSE}_{\text{calib.}} [\text{m}] = 0,103$	$\text{RMSE}_{\text{valid.}} [\text{m}] = 0,145$
	$\text{rRMSE}_{\text{calib.}} [\%] = 29,0$	$\text{rRMSE}_{\text{valid.}} [\%] = 20,3$	$\text{rRMSE}_{\text{calib.}} [\%] = 38,7$	$\text{rRMSE}_{\text{valid.}} [\%] = 35,7$

Les graphiques de la meilleure régression photogrammétrique et de la régression issue de la normalisation du nuage de points LiDAR sont présentés à la Figure 14.




Figure 14 – Meilleure régression linéaire photogrammétrique (gauche) et LiDAR (droite).

L'ANOVA non-paramétrique à deux facteurs sur les résidus des régressions (statistiques en Annexe B) a révélé une interaction entre le facteur « drone » et le facteur « MNT » (p-val = 0,00925).

La décomposition par MNT (Figure 15) montre une moyenne des résidus significativement inférieure pour la MicaSense dans le cas du MNT 2 (p-val = 0,000668) et du MNT 3 (p-val = $1,65 * 10^{-5}$). Dans le cas du MNT1, seul le Mini 2 présente des résidus significativement plus élevés (p-val = $3,55 * 10^{-6}$). Il y a donc une performance globalement meilleure de la MicaSense, suivie du 3M avec en dernière position le Mini 2 dont aucune des combinaisons n'atteint la qualité des meilleures régressions de la MicaSense. **L'hypothèse 4** de qualité équivalente d'estimation via un drone *low-cost* peut donc être réfutée.

La décomposition par drone (Figure 15) ne montre aucune différence significative entre les MNT pour le Mini 2 (p-val = 0,269), des résidus significativement plus élevés pour le MNT 1 dans le cas de la MicaSense (p-val = 0,00490) et enfin des différences significatives dans le cas du 3M entre le MNT 1 et le MNT 3 (p-val = 0,0249). Il est donc possible de valider **l'hypothèse 3**, de performances similaires du MNT 2, issu du Géoportail de la Wallonie, celui-ci ne donnant jamais des résidus significativement supérieurs aux autres.

Résultats




Figure 15 - Résidus moyens (+IC) des neuf régressions issues de la photogrammétrie.

En ce qui concerne les résultats de l'ANOVA entre la meilleure régression issue du LiDAR (voie « normalisation ») et la meilleure régression photogrammétrique (MicaSense et MNT 3), celle-ci ne met pas en évidence de différence significative ($p\text{-val} = 0,929$). Ce constat réfute **l'hypothèse 2** affirmant des modèles systématiquement plus performants de la part du LiDAR vis-à-vis de la photogrammétrie.

Les valeurs en validation des différentes RMSE montrent que l'application des bonnes pratiques susmentionnées permet tout de même d'obtenir des modèles partiellement transférables. En effet, dans certains cas, les erreurs n'augmentent que de quelques centimètres lorsque le modèle est soumis à un jeu de données acquis indépendamment. **L'hypothèse 5** de transférabilité grâce à l'application des bonnes pratiques peut donc être partiellement validée.

Une carte de hauteur obtenue après application d'un modèle sur la prairie de validation est présentée à la Figure 16. La Figure 17 présente quant à elle une carte avec l'écart-type des hauteurs prédites par les modèles développés avec les trois drones. Il est possible de mettre en évidence un écart-type de prédiction plus élevé dans les zones où la hauteur d'herbe prédite est supérieure. Les cartes de hauteur du Mini 2 et de la MicaSense sont disponibles à l'Annexe C.




Figure 16 – Carte de hauteur prédite sur la prairie de validation avec le modèle 3M-MNT1.

Résultats




Figure 17 – Carte de l'écart-type de la hauteur prédite entre les modèles des trois drones.

5.3. Estimation de la biomasse

Le premier modèle d'estimation de la biomasse est celui développé à partir de la hauteur comprimée mesurée avec l'herbomètre (modèle 12) et sert de référence aux autres modèles (Figure 18). La corrélation entre les deux variables est de 0,753. La RLU a nécessité une transformation racine cubique sur la variable à expliquer afin de répondre aux conditions d'application (Shapiro p-val = 0,0556). Le modèle présente une RMSE de validation de 770,30 kg MS/ha (Tableau 15).

Tableau 15 - Performances du modèle d'estimation de la biomasse avec la hauteur comprimée (modèle 12).

Matériel	R2 calib. [-]	R2 valid. [-]	RMSE calib. [kg MS/ha]	RMSE valid. [kg MS/ha]	rRMSE calib. [%]	rRMSE valid. [%]
Herbomètre	0,550	0,432	914,65	770,30	49,7	28,2




Figure 18 - Régression linéaire de la racine cubique de la biomasse (kgMS^{1/3}/ha) en fonction de la hauteur comprimée (mm).

Résultats

En ce qui concerne les modèles développés avec les différentes informations du Mini 2 (détails à l'Annexe D), les premiers (modèles 13) obtiennent les meilleurs résultats en validation avec une RF ($R^2_{\text{valid.}} = 0,159$; $\text{RMSE}_{\text{valid.}} = 1119,97$ kg MS/ha ; $\text{rRMSE}_{\text{valid.}} = 41\%$). Les deux variables les plus importantes sont le PPR et l'ExG. Lors de l'ajout des statistiques de hauteur (modèles 14), les modèles perdent en qualité, le meilleur étant le SVM radial (Tableau 16). Lorsque l'on s'intéresse à la sélection de variables, que ce soit pour les RLM ou pour la RF, ce sont avant tout les métriques de hauteur (moyenne, médiane, percentile 25 et 75) qui sont alors sélectionnées. Dans les RLM, seul l'indice VARI, et non plus, ni le PPR, ni l'ExG, est conservé avec une importance relative de 3 %. Les modèles PCR et PLS présentent les pires performances. Parmi leurs composantes principales, les métriques de hauteur participent principalement à la première (qui explique 61,6 % de la variabilité) alors que les IV participent majoritairement à la deuxième (26,4 % de la variabilité).

Tableau 16 – Performances des modèles d'estimation de la biomasse du Mini 2 avec l'ensemble des variables explicatives (modèles 14).

Matériel	Modèle	R2 calib. [-]	R2 valid. [-]	RMSE calib. [kgMS/ha]	RMSE valid. [kgMS/ha]	rRMSE calib. [%]	rRMSE valid. [%]
Mini 2	Stepwise (5 var.)	0,722	0,139	698,44	2067,77	38,0	75,7
	Forward (5 var.)	0,722	0,139	698,44	2067,77	38,0	75,7
	Backward (8 var.)	0,747	0,0046	649,26	1753,25	35,3	64,2
	PCR (ncomp=4)	0,682	0,113	778,55	2222,13	42,3	81,4
	PLS (ncomp=4)	0,687	0,119	773,17	2200,93	42,0	80,1
	RF (ntree=500 ; nsize= 1 ; mtry= 4)	0,505	0,00121	971,92	1488,0	52,8	54,5
	SVM linéaire (C=5)	0,622	0,0234	782,02	1764,06	42,5	64,6
	SVM radial (sigma= 0,025 ; C= 1)	0,526	0,120	881,11	1262,184	47,9	46,2

Pour ce qui est du 3M, le meilleur modèle avec les IV_{RGB} (modèles 15) est la RF ($R^2_{\text{valid.}} = 0,0075$; $\text{RMSE}_{\text{valid.}} = 1145,18$ kg MS/ha ; $\text{rRMSE}_{\text{valid.}} = 41,9\%$). Globalement, les modèles présentent les mêmes performances que les modèles du Mini 2 développés avec les mêmes variables. En revanche, dans ce cas, l'ajout des statistiques de hauteur (modèles 16), au contraire du Mini 2, permet d'augmenter la qualité de la plupart des modèles avec un optimum pour la RF ($R^2_{\text{valid.}} = 0,125$; $\text{RMSE}_{\text{valid.}} = 1128,27$ kg MS/ha ; $\text{rRMSE}_{\text{valid.}} = 41,3\%$) qui reste, certes, proche du précédent. Enfin, l'ajout des IV_{MS} (modèles 17) permet un gain significatif de qualité, où les maxima sont atteints pour le modèle PCR à une composante (surajustement dès deux composantes) (Tableau 17). Dans celle-ci participent les métriques de hauteur ainsi que les différents IV, dont les 4 multispectraux. A noter que le PPR participe avec un signe opposé aux autres. La RF, qui présente des résultats assez bons, donne, elle aussi, des informations quant à l'importance des variables (Figure 19). Leur importance est exprimée en pourcentage d'augmentation de l'erreur quadratique moyenne en cas d'exclusion de la variable.

Résultats

Tableau 17 - Performances des modèles d'estimation de la biomasse du 3M avec l'ensemble des variables explicatives (modèles 17).

Matériel	Modèle	R2 calib. [-]	R2 valid. [-]	RMSE calib. [kgMS/ha]	RMSE valid. [kgMS/ha]	rRMSE calib. [%]	rRMSE valid. [%]
3M	Stepwise (6 var.)	0,746	0,295	661,92	1612,45	36,0	59,1
	Forward (6 var.)	0,746	0,295	661,92	1612,45	36,0	59,1
	Backward (8 var.)	0,755	0,168	638,12	954,36	34,7	35,0
	PCR (ncomp=1)	0,504	0,166	972,90	932,99	52,9	34,2
	PLS (ncomp=1)	0,619	0,220	852,86	1078,88	46,3	39,5
	RF (ntree=500 ; nsize= 5 ; mtry= 1)	0,515	0,133	961,79	1065,53	52,3	39,0
	SVM linéaire (C=0,05)	0,719	0,265	763,57	1260,42	41,5	46,2
	SVM radial (sigma= 0,025 ; C= 0,75)	0,656	0,216	844,21	1068,61	45,9	39,1

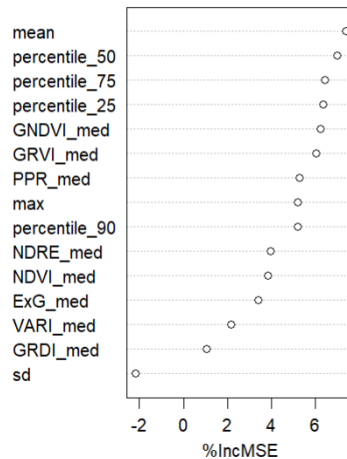


Figure 19 - Importance des variables de la RF (3M – modèles 17).

Enfin, en ce qui concerne la MicaSense, le meilleur modèle avec les 4 IV_{RGB} (modèles 18) est une RF ($R^2_{valid.} = 0,0296$; $RMSE_{valid.} = 1160,41$ kg MS/ha ; $rRMSE_{valid.} = 42,5$ %). L'ajout des métriques de hauteur (modèles 19) permet d'atteindre une qualité supérieure où aucun des modèles ne présente de RMSE supérieure à 1099,23 kg MS/ha avec le meilleur étant la RLM avec sélection *backward* ($R^2_{valid.} = 0,410$; $RMSE_{valid.} = 859,84$ kg MS/ha ; $rRMSE_{valid.} = 31,5$ %), meilleure que les deux autres drones à ce stade. Ceci permet déjà de réfuter *l'hypothèse 4* concernant les performances du *low-cost* en termes de biomasse, les meilleures performances du drone Mini 2 n'atteignant jamais celles des deux autres. Les IV_{MS} ajoutés (modèles 20), des modèles aux performances globalement similaires sont obtenus avec le meilleur étant la PCR à 3 composantes ($R^2_{valid.} = 0,368$; $RMSE_{valid.} = 943,93$ kg MS/ha ; $rRMSE_{valid.} = 34,6$ %), équivalent aux performances obtenues avec le 3M. Que ce soit dans les RLM, les premières composantes de la PCR ou dans la RF, les métriques de hauteur sont, ici aussi, les variables avec le plus d'importance relative. L'ajout des valeurs de réflectance de la bande panchromatique et de la bande thermique (modèles 21) entraîne en revanche une baisse des performances globale de la part de tous les modèles (Tableau 18). Ces deux variables sont sélectionnées dans les différents modèles avec des importances relatives de 22,7 % et 5,5 % pour le LWIR et le PAN dans les RLM *stepwise*. Cette importance est aussi visible dans la RF (Figure 20).

Résultats

Tableau 18 - Performances des modèles d'estimation de la biomasse de la MicaSense avec l'ensemble des variables explicatives (modèles 21).

Matériel	Modèle	R2 calib. [-]	R2 valid. [-]	RMSE calib. [kgMS/ha]	RMSE valid. [kgMS/ha]	rRMSE calib. [%]	rRMSE valid. [%]
MicaSense	Stepwise (5 var.)	0,770	0,195	635,11	1510,16	34,5	55,3
	Forward (5 var.)	0,770	0,195	635,11	1510,16	34,5	55,3
	Backward (8 var.)	0,777	0,210	609,92	1404,96	33,1	51,5
	PCR (ncomp=1)	0,521	0,314	955,83	1142,70	51,9	41,8
	PLS (ncomp=1)	0,654	0,331	812,61	1167,23	44,2	42,7
	RF (ntree=500 ; nsize=5 ; mtry= 4)	0,613	0,0965	858,83	1222,98	46,7	44,7
	SVM linéaire (C=0,75)	0,656	0,183	713,05	1545,67	38,7	56,6
	SVM radial (sigma=0,025 ; C= 0,5)	0,541	0,167	944,94	1333,85	34,6	48,8

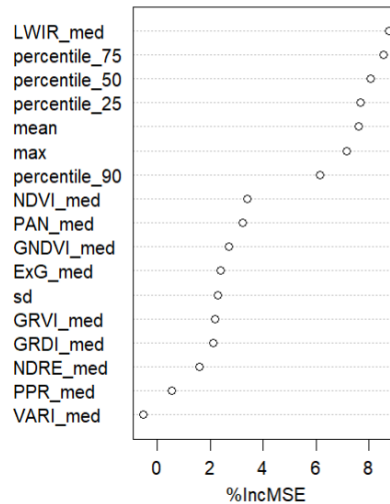


Figure 20 - Importance des variables de la RF (MicaSense – modèles 21).

Quant à la transférabilité des modèles (*hypothèse 5*), il semble, à première vue, que dans certaines situations, celle-ci soit tout à fait possible puisque des augmentations de RMSE inférieures à 100kg MS/ha sont visibles, comme c'est le cas pour le modèle PCR du 3M (modèles 17). Aucun des modèles n'atteint cependant la qualité de l'herbomètre.

5.4. Classification de la composition floristique

Pour les trois drones, c'est l'algorithme KNN qui obtient les meilleurs résultats avec des coefficients Kappa de Cohen de respectivement 0,556 ; 0,778 et 0,882 en allant du « *low-cost* » au haut-de-gamme (Tableau 19). Les deuxièmes meilleurs classificateurs sont la PLS-DA pour la MicaSense, suivi de la RF du 3M, celle du Mini 2 n'ayant qu'un coefficient approchant les 0,06. Les variables sélectionnées par la RF varient selon les drones. Pour le Mini 2, ce sont les métriques de hauteur ainsi que l'ExG qui sont prépondérants. Pour le 3M, il s'agit des métriques de hauteur, suivie des IV_{MS} . Pour la MicaSense, où la RF donne de mauvais résultats, le LWIR et le PAN ont une importance plus élevée que les IV.

Tableau 19 - Performances des modèles de classification de la composition floristique.

Matériel	Modèle	Sensibilité	Spécificité	Coefficient Kappa
Mini 2	Analyse discriminante	0,444	0,500	-0,0400
	KNN (k=5)	0,889	0,667	0,556
	RF (ntree = 500, nsize = 5, mtry = 4)	0,111	1,00	0,0588
	PLS-DA (ncomp = 7)	0,278	0,667	-0,0345
	SVM linéaire (C = 2)	1,00	0,00	0,00
3M	Analyse discriminante	1,00	0,00	0,00
	KNN (k=5)	0,944	0,833	0,778
	RF (ntree = 500, nsize = 2, mtry = 2)	0,722	0,833	0,455
	PLS-DA (ncomp = 6)	1,00	0,00	0,00
	SVM linéaire (C = 2)	1,00	0,00	0,00
MicaSense	Analyse discriminante	1,00	0,167	0,231
	KNN (k=5)	1,00	0,833	0,882
	RF (ntree = 500, nsize = 2, mtry = 2)	0,944	0,00	-0,0769
	PLS-DA (ncomp = 5)	1,00	0,667	0,75
	SVM linéaire (C = 0,75)	1,00	0,00	0,00

6. Discussion

6.1. Utilisation des GCP

Comme l'ont montré les résultats, l'utilisation de GCP dans un contexte prairial ne peut pas être évitée et ce, même lorsque le drone possède un système de positionnement RTK comme le mentionnent Bareth et al. (2023). De plus, les erreurs rémanentes même après optimisation avec 5 GCP ne sont pas en accord avec Assmann et al. (2019) qui affirment que ce nombre est suffisant pour une surface d'un hectare. Il y aurait donc un intérêt, dans n'importe quelle situation, à augmenter leur nombre afin de s'assurer une géolocalisation centimétrique, comme Borra-Serrano et al. (2019) et leurs 35 GCP sur 0,5 ha. Cet aspect, certes chronophage, est fondamental pour les modèles développés en aval. En effet, dans le cadre de ce travail, des erreurs d'altitude de plusieurs centimètres ont persisté malgré la correction. Des différences d'erreur d'une date à l'autre peuvent avoir un impact sur la droite de régression qui est générée comme le montre la Figure 21. Sur celle-ci, il apparaît clairement un décalage entre le jeu de calibration du mois d'avril (bleu) et celui du mois de mai (orange), qui tire la pente de la régression globale vers le bas (rouge), les deux jeux de données ayant une tendance parallèle. Ce décalage ne semble a priori par dû à un effet de la coupe puisque le jeu de données d'avril qui n'avait pas encore été coupé est bien aligné avec celui du mois de juin, sur la prairie du CRA, qui avait déjà subi une coupe. Il semblerait que la cause réside, du moins partiellement, dans les erreurs rémanentes. Une autre source pourrait être l'anisotropie de la surface (due à une réflectance non-lambertienne), qui malgré un large recouvrement des images pourrait exercer une influence sur la reconstruction photogrammétrique et interférer sur la transférabilité. Parmi les perspectives, il serait pertinent de réaliser par exemple une correction BRDF (*bidirectional reflectance distribution function*) afin de prendre en compte l'influence de cette anisotropie (Aasen et al., 2018). Ces deux aspects (amélioration de la précision et correction BRDF) devraient aussi permettre la transférabilité des modèles entre les équipements. L'utilisation de données de validation prises par le Mini 2 ou le 3M, appliquées au modèle calibré avec la MicaSense, ne donne jamais des résultats aussi bons que les modèles calibrés sur leurs propres données. Ce constat réfute une transférabilité entre drones dans ces conditions.

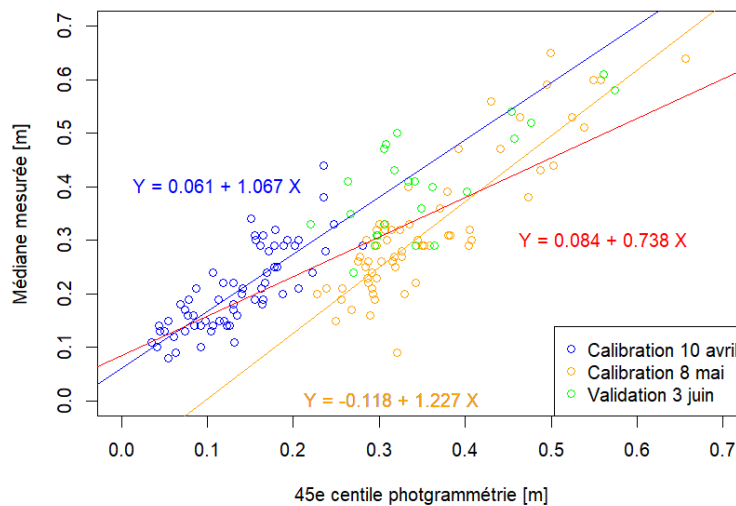


Figure 21 - Régression linéaire d'estimation de la hauteur via la MicaSense avec le MNT3.

6.2. Optimisation du flux de traitement

Il est aussi possible de discuter des pré-traitements appliqués aux données LiDAR et photogrammétriques, principalement en ce qui concerne les algorithmes de classification de points de sol. En effet, pour le traitement LiDAR, c'est l'algorithme pmf qui a été utilisé mais d'autres algorithmes de classification tels que le « *cloth simulation filter* » (csf) sont aussi pertinents (Roussel et al., 2024). Dans le cadre de ce travail, les valeurs des différents arguments ont été testées de façon aléatoire avec une appréciation visuelle de leur résultat. Il aurait été pertinent de tester les différents algorithmes de façon systématique avec de nombreuses combinaisons d'arguments et de réaliser une analyse de sensibilité plus poussée afin de s'assurer d'avoir opté pour le meilleur classificateur. En ce qui concerne la classification sur Metashape, cette remarque est aussi valable pour les différents paramètres qui devaient être fournis. La différence de proportion relative de points de sol entre les deux prairies avec des arguments de classification similaires, poussent cependant à se demander si un algorithme universel de classification des points de sol en prairie, transférable d'une à l'autre, est vraiment possible.

En ce qui concerne la calibration radiométrique des orthomosaïques multispectrales, malgré l'application des bonnes pratiques recommandées par Aasen et al. (2018), et l'utilisation du panneau fourni avec la MicaSense, de légères erreurs subsistent. En effet, une comparaison de certains points dont la réflectance est approximativement constante (route, GCP...) montre que malgré la calibration, des différences atteignant jusqu'à 0,1 peuvent être présentes entre les deux dates. Ce constat est aussi valable pour la MicaSense qui dispose d'un capteur de radiation incidente. Cette différence a tendance à être moins marquée pour les orthomosaïques RGB qui n'ont, quant à elles, subi qu'une standardisation et non pas une calibration à proprement parler, qui semble donc, a priori, efficace. Il est aussi possible de comparer les valeurs de réflectance des différentes bandes entre les drones. Pour les orthomosaïques RGB, les valeurs du Mini 2 et du 3M sont très proches (de l'ordre de 0,05). Cette constatation rassure encore quant à l'efficacité relative de la méthode de standardisation. En revanche, en ce qui concerne les orthomosaïques multispectrales du 3M et de la MicaSense, des différences pouvant aussi atteindre 0,1 sont observables, faisant douter de la transférabilité d'un modèle à un nouveau capteur spectral s'il a été calibré avec un capteur différent.

6.3. Effet du matériel et du MNT dans l'estimation de la hauteur

En ce qui concerne les neuf régressions linéaires issues de la photogrammétrie, il est difficile de conclure à une combinaison équipement/MNT idéale. L'effet du matériel sur l'erreur de prédiction semble cependant plus important que l'effet dû à la source de MNT. Le drone *low-cost* qu'est le Mini 2 offre de moins bonnes performances quel que soit le MNT utilisé. Celles-ci ne peuvent pas être entièrement attribuées à l'imprécision de localisation précédemment mentionnée puisqu'il ne présente pas d'erreur systématiquement plus élevée. Il s'agirait donc bien d'un effet matériel ayant un impact dans la reconstruction photogrammétrique. Le 3M atteint tout de même des qualités proches de celles de la MicaSense pour un prix drastiquement inférieur. En termes de MNT, le MNT 1 est celui qui présente les meilleures performances avec le 3M mais des performances légèrement inférieures avec la MicaSense. Il faut rappeler que ces performances pourraient certainement être améliorées en optimisant la classification de points de sol sur Metashape susmentionnée. De plus, il ne faut pas négliger que ce MNT, comme le MNT 2, ne nécessite pas de prise de données supplémentaires avec un LiDAR, qui, en outre, est un matériel onéreux. Enfin, comparé au MNT 2, il possède une meilleure résolution spatiale et n'a pas nécessité de conversion de hauteur orthométrique en hauteur ellipsoïdale. Il peut donc certainement être un bon compromis. Dans ce contexte, la combinaison du DJI Mavic 3M, avec un MNT issu d'une classification de points sur Metashape semble être une solution photogrammétrique prometteuse.

La meilleure performance atteinte par la normalisation du nuage de points LiDAR n'est pas très éloignée de Hütt et al. (2024), qui parviennent à estimer la hauteur comprimée de l'herbe via un vol LiDAR avec une RMSE de 5,9 cm, pour un jeu de validation qui n'est pas indépendant. De plus, ils ont utilisé l'intensité de la réflexion (quantité d'énergie) comme variable explicative supplémentaire, ce qui n'a pas été fait dans ce travail. Dans ce travail, cette valeur de RMSE est pratiquement atteinte en calibration par l'ensemble des régressions photogrammétriques. En validation, seules les régressions issues de la MicaSense parviennent à égaler le LiDAR même si le 3M s'en approche.

Après avoir conclu à une importance significative de la source de MNT et du capteur utilisé sur la qualité des modèles en validation, quelques tests supplémentaires ont été réalisés afin d'essayer d'expliquer les résidus rémanents. Une tentative de corrélation entre l'écart-type des hauteurs au sein de chaque unité et de leur composition floristique a été réalisée. Aucune relation significative n'a pu être mise en évidence, écartant la responsabilité de l'hétérogénéité intra-unité et de sa composition floristique (proportion de graminées) dans l'augmentation de l'erreur de hauteur.

6.4. Modèles de biomasse et importance des variables

Le modèle de référence développé à partir des données acquises avec l'herbomètre atteint des performances en accord avec la littérature, voire meilleures que Borra-Serrano et al. (2019) qui atteignaient une RMSE de 986 kgMS/ha (rRMSE de 31,0 %), eux aussi, avec une régression linéaire univariée. Cependant, dans leur cas, les modèles basés sur de l'information aérienne dépassaient tous la performance de l'herbomètre, outil dont il faut mentionner l'utilisation impossible sur des hauteurs comprimées de plus de 250 mm ("EC20 Bluetooth Electronic Platometer," Juillet-31-2024).

Lors de l'utilisation des IV_{RGB} uniquement, une qualité globalement supérieure des modèles de la MicaSense avait été mise en évidence malgré un modèle optimal qui était équivalent pour les trois capteurs. L'effet de la qualité spectrale du capteur semble donc être négligeable. Parmi ces IV, l'ExG et le PPR étaient quasi systématiquement sélectionnés, Lussem et al. (2019) avaient, eux aussi, conclu à une bonne performance de l'indice PPR, qui donne une indication du rapport entre caroténoïdes et chlorophylle mais peut présenter des limitations sur des stades végétatifs avancés. Sa contribution opposée aux métriques de hauteur dans la première composante de la PCR (Figure 22) est liée à sa corrélation négative avec la biomasse, comme Lussem et al. (2019) l'avaient aussi mis en évidence. L'importance récurrente du PPR prouve l'utilité de la camera RGB du 3M afin d'avoir des données de réflectance pour la bande bleue, non-disponibles sur sa caméra multispectrale.




Figure 22 - Graphe de corrélations des 4 IV_{RGB} , des 4 IV_{MS} et des métriques de hauteurs du 3M selon les deux premières composantes d'une ACP.

L'ajout des métriques de hauteur a permis une augmentation de la qualité pour le 3M et la MicaSense qui obtiennent des performances quasi semblables alors que cela entraîne une forte baisse de performance pour le Mini 2. Cette baisse de performance est dans ce cas-ci probablement liée à l'estimation de la hauteur précédemment mentionnée qui était systématiquement plus mauvaise pour le Mini 2. Celui-ci semblerait donc présenter une qualité spectrale quasi équivalente mais des difficultés en reconstruction photogrammétrique. L'importance relative élevée des métriques de hauteur est en accord avec la plupart des autres travaux qui concluent à leur meilleure performance dans l'estimation de la biomasse (Viljanen et al., 2018; Borra-Serrano et al., 2019). Leur utilisation seule, semble cependant biaisée puisqu'il est difficile de lier la hauteur, métrique de structure, à la biomasse disponible. Dans cette optique, les IV apportent de l'information quant à la densité du couvert végétal (Borra-Serrano et al., 2019). Il est donc possible de conclure, comme Viljanen et al. (2018) et Michez et al. (2019) à une importance de la combinaison des données photogrammétriques 3D et des IV.

En ce qui concerne les IV_{MS} , leur ajout permet un léger gain de qualité pour le 3M, négligeable pour la MicaSense. Ceux-ci sont en revanche systématiquement sélectionnés par les modèles et semblent donc apporter quelque chose. Viljanen et al. (2018) obtenaient, eux aussi, de meilleurs résultats en intégrant des IV contenant la bande NIR dans leurs modèles alors que Lussem et al. (2019) concluaient à une meilleure efficacité du PPR vis-à-vis du NDVI qui manifestait de la saturation. La baisse de performances lors de l'ajout des valeurs de réflectance des bandes panchromatique et thermique pour la MicaSense questionne quant à leur utilisation sous forme de valeur brute. Cela nécessiterait d'investiguer le potentiel du LWIR sous forme d'indice de végétation et l'utilisation de la bande panchromatique dans des applications de *PAN-sharpening*, consistant à la fusionner avec d'autres bandes spectrales pour en augmenter la résolution spatiale (Yang et al., 2017).

En termes de types de modèles, d'une manière générale, ce sont des algorithmes de *Machine Learning* tels que les RF et les PCR qui présentent les meilleures performances, comme l'avaient mis en évidence Viljanen et al. (2018) et Grüner et al. (2020). Ceux-ci, certes, moins interprétables que des régressions, présentent une robustesse accrue en validation du fait de leur prise en compte de la colinéarité des variables explicatives. Celle-ci peut, dans certains cas, être assez importante comme le montre la Figure 23. Les valeurs en validation des indicateurs de qualité de certains de ces modèles ont mis en évidence une transférabilité possible et ce, malgré les doutes émis quant à la qualité de la correction radiométrique. Les performances globalement moins bonnes que ce qui est généralement retrouvé dans la littérature, peuvent être relativisées puisque celles-ci sont le résultat d'un jeu de validation complètement indépendant. Les modèles restent cependant loin d'être acceptables pour une utilisation sur le terrain qui nécessiterait d'atteindre des erreurs inférieures à 300 kg MS/ha (Gargiulo et al., 2023). Dans certains cas, les RMSE et R^2 en validation présentaient des valeurs respectivement inférieures et supérieures à la calibration. Cela peut s'expliquer par des distributions différentes des jeux de données de calibration et de validation. A titre d'exemple, les données de biomasse présentaient un écart-type en calibration de 1392 kg MS/ha pour un écart-type de 863 kg MS/ha en validation. Ce constat amène à penser que la calibration d'un modèle avec un jeu de données diversifié permet ensuite de le transférer sur un jeu de données plus homogène. Dans le cadre de ce travail, la taille de ce jeu de données semble être une limite et aurait pu être plus importante. Une troisième date de prise de données avait initialement été prévue mais il a fallu y renoncer du fait d'une météo capricieuse et d'une prairie en mauvais état, dont les herbes ont versé.

Discussion




Figure 23 - Corrélogramme de la biomasse et des 17 variables explicatives disponibles pour la MicaSense (modèles 21).

6.5. Classificateurs de la composition floristique

En ce qui concerne la classification, la meilleure performance de la méthode KNN doit être relativisée puisqu'il ne s'agit pas d'un modèle à proprement parler. Il ne présente en effet pas de phase d'entraînement et classe directement les données de validation à partir de celles de calibration. Certains algorithmes de *Machine Learning* tels qu'une RF et une PLS-DA ont tout de même réussi à discriminer de façon correcte les deux classes prédéterminées prouvant la possibilité de combiner des données photogrammétriques et spectrales et la transférabilité du classificateur. Il serait à l'avenir intéressant de diversifier les données de calibration afin d'avoir la possibilité de définir plus de deux classes avec un nombre suffisant d'enregistrements et de tester, par exemple, la capacité à discriminer les légumineuses des adventices, toutes deux dicotylédones. Pour la MicaSense, à l'image de la biomasse, de meilleurs résultats auraient peut-être été obtenus en utilisant différemment le PAN et le LWIR. Buitrago et al. (2018) arrivent par exemple à différencier en laboratoire 19 espèces herbacées et ligneuses uniquement avec 5 bandes dans le LWIR mettant en avant le potentiel de ces longueurs d'onde.

6.6. Perspectives supplémentaires

Dans une optique d'amélioration des modèles, il aurait été possible d'augmenter le nombre de variables explicatives afin de sélectionner les meilleures de toutes. Pour les IV, il aurait été possible de ne pas se limiter à la médiane par unité d'échantillonnage mais de calculer d'autres statistiques telles que l'écart-type, métrique sélectionnée par Borra-Serrano et al. (2019) dans leurs modèles. D'autres IV auraient aussi pu être investigués, cependant, ceux-ci ont tendance à présenter de la colinéarité, une sélection adaptée serait donc fondamentale et est un point d'intérêt futur. De plus, augmenter le nombre de variables à l'excès fait souvent perdre de l'interprétabilité aux modèles, d'où le choix de ne sélectionner que 8 IV et d'extraire uniquement leur valeur médiane. Gruner et al. (2020) intègrent des variables de texture par le calcul de matrice de co-occurrence de gris afin de prendre en compte les relations spatiales entre les pixels. Borra-Serrano et al. (2019) ont conclu, quant à eux, à une amélioration des modèles via l'intégration d'une variable environnementale qu'est la somme de degré-jours. Cette perspective est problématique pour un modèle de prairie diversifiée puisqu'elle nécessite de prendre une température de base (zéro de végétation) qui est propre à chaque espèce.

Le développement de modèles de *Machine (Deep) Learning* plus innovants tels que des réseaux neuronaux, comme l'ont fait Alves Oliveira et al. (2022) est aussi une perspective d'amélioration qui n'a pas été testée ici au vu du nombre trop réduit de données disponibles. Il serait aussi possible de développer des modèles plus mécanistes permettant de mieux prendre en compte les processus sous-jacent à l'écosystème, ou encore de combiner des informations aériennes et des mesures de terrain limitées, afin d'ajuster certains paramètres des modèles (Bindelle et al., 2021).

La diversification du jeu de données susmentionnée permet certes de transférer les modèles et de les rendre plus robustes mais peut entraîner une réduction globale des qualités prédictives vis-à-vis de modèles développés sur un type de prairie spécifique. Ce constat est aussi remarqué par Grüner et al. (2019) qui obtiennent de meilleures performances prédictives en développant différents modèles spécifiques selon la proportion de légumineuses de la prairie. Le développement de tels modèles nécessite cependant de définir une typologie de prairie selon différents critères afin d'appliquer les modèles adaptés aux nouveaux jeux de données. Il est donc absolument fondamental, lors de la modélisation d'opter pour un compromis entre transférabilité et spécificité selon l'objectif visé.

6.7. Limitations techniques et légales

Enfin, l'avantage que présentent les drones pour obtenir de l'information spatialisée à de hautes résolutions, sur des surfaces conséquentes en un temps bien moindre que des mesures de terrains (Bindelle et al., 2021; Gargiulo et al., 2023) doit encore être relativisé. En effet, si l'ensemble des vols réalisés ne dépassaient pas les 15 minutes alors que les mesures au sol représentaient plusieurs heures de travail, l'ensemble du temps nécessaire au pré-traitement des données doit être pris en compte. Celui-ci durait dans certains cas plusieurs heures sur les logiciels de reconstruction. Plusieurs difficultés ayant été rencontrées et ayant engendré une perte de temps, il est difficile de comparer réellement l'avantage temporel que présentent ce type de télédétection. Le grand nombre de données générées et leur taille peut aussi dans certains cas poser des problèmes en termes de stockage si cela était répété pour des surfaces conséquentes. De plus, la méthodologie et les logiciels utilisés dans ce travail demandent certaines connaissances qui demeurent un frein à une utilisation sur le terrain par des agriculteurs. Ce point nécessiterait le développement à l'avenir de flux de travail automatisés avec des interfaces plus *consumer-friendly*. De plus, l'étude de surfaces « conséquentes » qui est prônée par certains, doit être relativisée en regard des capacités des batteries des différents appareils. Dans ce cadre, la batterie du Mini 2 permettait de réaliser un vol de 15 minutes, lorsque le M300 pouvait voler jusqu'à 45 minutes, ce qui représente environ trois fois la surface étudiée ici, dans les conditions de vol appliquées. Une troisième limitation concerne la législation actuelle, qui, en Belgique, stipule que le drone doit en permanence rester dans le champ de vision du pilote à une altitude qui ne dépasse pas les 120 m. Des restrictions spécifiques aux drones M300 (de classe C3) et 3M (classe C2) en termes de proximité des bâtiments (minimum 150 m) ou de survol de personne (proscrit) peuvent en revanche donner un avantage au drone *low-cost* qu'est le Mini 2 (classe C0), qui, dans certaines situations, pourrait être la seule option légale ("Formations et examens UAS - SPF mobilité et transports," Mars-13-2024). Enfin, malgré une moins forte dépendance à la couverture nuageuse, ces appareils restent tout de même dépendants des conditions climatiques telles que le vent ou la pluie (Assmann et al., 2019; Gargiulo et al., 2023). Dans ce cadre, les drones *low-cost* présentent bien souvent dans leurs spécifications des conditions météorologiques d'utilisation bien plus strictes que les drones haut-de gamme ("Support for DJI Mini 2," Mars-1-2024; "Specs - MATRICE 300 RTK - DJI Enterprise," Mars-4-2024).

7. Conclusion

En conclusion, le drone *low-cost* testé dans ce travail méthodologique et comparatif a tout de même rencontré des difficultés à atteindre les qualités d'estimation des deux autres capteurs. Le DJI Mavic 3M et la MicaSense Altum-PT ont présenté des performances dans l'estimation de la hauteur remettant en question la qualité supérieure parfois évoquée de la technologie LiDAR. L'utilisation d'un MNT généré par classification de points sur Metashape a aussi été démontré comme étant une solution efficace. En termes d'estimation de biomasse et de composition floristique, le 3M et la MicaSense atteignent des performances approximativement similaires lors de la combinaison d'information photogrammétrique avec des IV RGB et multispectraux. Par ses performances et son prix, le DJI Mavic 3M semble donc être un bon compromis entre les drones *low-cost* et haut-de-gamme et une solution prometteuse pour l'obtention d'information spatialisée, en alternative à l'herbomètre. Des algorithmes de *Machine Learning* tels que des RF ou des PCR ont présenté un avantage certain vis-à-vis de RLM malgré une interprétabilité plus complexe. Parmi les bonnes pratiques mentionnées dans la littérature, la correction géométrique par l'utilisation de GCP, et ce, même en cas de module RTK embarqué, s'est ici révélée fondamentale lors d'un travail à l'échelle centimétrique et dans une optique de transférabilité des modèles. La correction radiométrique et la diversification des données de calibration ont réussi, dans plusieurs cas, à donner des modèles robustes et transférables sur un jeu de données indépendant. L'ensemble de ces résultats pourraient encore être améliorés dans des perspectives d'optimisation de précision, de classification de sol, de meilleur choix d'IV, de meilleure utilisation de l'information panchromatique et thermique, d'intégration d'information texturale et environnementale, et de développement de modèles plus complexes à partir de jeux de données plus importants. Enfin, le développement d'interfaces plus *consumer-friendly* pourrait faire de cette technologie un outil d'aide à la décision efficace, tout en gardant à l'esprit les limitations techniques et légales auxquelles elle est encore soumise.

8. Contribution de l'étudiant

En tant qu'étudiant, j'ai contribué à l'ensemble de ce travail. Sur base de la littérature et en concertation avec mes co-promoteurs, j'ai identifié les enjeux sur lesquels mon travail allait porter. J'ai établi moi-même un protocole et réalisé la prise de données en autonomie. J'ai aussi eu la charge du traitement de ces données et de la création des différents modèles nécessaires pour répondre à mes objectifs. In fine, c'est moi qui ai rédigé l'ensemble du présent document.

9. Bibliographie

- Aasen H., Honkavaara E., Lucieer A. & Zarco-Tejada P.J., 2018. Quantitative Remote Sensing at Ultra-High Resolution with UAV Spectroscopy: A Review of Sensor Technology, Measurement Procedures, and Data Correction Workflows. *Remote Sens.* **10**(7), 1091, DOI:10.3390/rs10071091.
- Allen V. G., Batello C., Berretta E. J., Hodgson J., Kothmann M., Li X., McIvor J., Milne J., Morris C., Peeters A., Sanderson M., & The Forage and Grazing Terminology Committee, 2011. An international terminology for grazing lands and grazing animals. *Grass Forage Sci.* **66**(1), 2–28, DOI:10.1111/j.1365-2494.2010.00780.x.
- Alves Oliveira R., Marcato Junior J., Soares Costa C., Näsi R., Koivumäki N., Niemeläinen O., Kaivosoja J., Nyholm L., Pistori H. & Honkavaara E., 2022. Silage Grass Sward Nitrogen Concentration and Dry Matter Yield Estimation Using Deep Regression and RGB Images Captured by UAV. *Agronomy* **12**(6), 1352, DOI:10.3390/agronomy12061352.
- Amelung B., Biernaux M., Cauchy A., Céron J.-P., Cornélis P., Dubois G., Frisson G., Henrard S., Joveneau A., Mahy G., Monty A., Mouazan E., Pouria X., Speybroeck N. & van Ypersele de Strihou J.-P., 2011. L'adaptation au changement climatique en région wallonne. *Agence wallonne de l'air et du climat*, <http://hdl.handle.net/2078.1/133946>.
- Ansquer P., Theau J.-P., Cruz P., Viegas J., Al Haj Khaled R. & Duru M., 2004. Caractérisation de la diversité fonctionnelle des prairies naturelles. Une étape vers la construction d'outils pour gérer les milieux à flore complexe. Présenté aux Journées de l'Association Française pour la Production Fourragère, *Fourrages* **179**, 353–368.
- Ara I., Harrison M.T., Whitehead J., Waldner F., Bridle K., Gilfedder L., Marques Da Silva J., Marques F. & Rawnsley R., 2021. Modelling seasonal pasture growth and botanical composition at the paddock scale with satellite imagery. *Silico Plants* **3**(1), diaa013, DOI:10.1093/insilicoplants/diaa013.
- Assmann J.J., Kerby J.T., Cunliffe A.M. & Myers-Smith I.H., 2019. Vegetation monitoring using multispectral sensors — best practices and lessons learned from high latitudes. *J. Unmanned Veh. Syst.* **7**(1), 54–75, DOI:10.1139/juvs-2018-0018.
- Bareth G. & Hütt C., 2023. Evaluation of Direct RTK-georeferenced UAV Images for Crop and Pasture Monitoring Using Polygon Grids. *PFG – J. Photogramm. Remote Sens. Geoinformation Sci.* **91**(6), 471–483, DOI:10.1007/s41064-023-00259-7.
- Bareth G. & Schellberg J., 2018. Replacing Manual Rising Plate Meter Measurements with Low-cost UAV-Derived Sward Height Data in Grasslands for Spatial Monitoring. *PFG – J. Photogramm. Remote Sens. Geoinformation Sci.* **86**(3), 157–168, DOI:10.1007/s41064-018-0055-2.

Bibliographie

- Barnetson J., Phinn S. & Scarth P., 2020. Estimating Plant Pasture Biomass and Quality from UAV Imaging across Queensland's Rangelands. *AgriEngineering* **2**(4), 523–543, DOI:10.3390/agriengineering2040035.
- Bengtsson J., Bullock J.M., Ego B., Everson C., Everson T., O'Connor T., O'Farrell P.J., Smith H.G. & Lindborg R., 2019. Grasslands—more important for ecosystem services than you might think. *Ecosphere* **10**(2), e02582, DOI:10.1002/ecs2.2582.
- Bindelle J., Da Silva Neto G.F., Kokah E.U., de Faccio Carvalho P. & Michez A., 2021. Drone-based remote sensing of sward structure and biomass for precision grazing: state of the art and future challenges. Présenté au 21st Symposium of the European Grassland Federation. <https://hdl.handle.net/2268/261219>.
- Borra-Serrano I., De Swaef T., Muylle H., Nuyttens D., Vangeyte J., Mertens K., Saeys W., Somers B., Roldán-Ruiz I. & Lootens P., 2019. Canopy height measurements and non-destructive biomass estimation of Lolium perenne swards using UAV imagery. *Grass Forage Sci.* **74**(3), 356–369, DOI:10.1111/gfs.12439.
- Buitrago M.F., Skidmore A.K., Groen T.A. & Hecker C.A., 2018. Connecting infrared spectra with plant traits to identify species. *ISPRS J. Photogramm. Remote Sens.* **139**, 183–200, DOI:10.1016/j.isprsjprs.2018.03.013.
- Carvalho P.C. de F., 2013. Harry Stobbs Memorial Lecture: Can grazing behavior support innovations in grassland management? *Tropical Grassland-Forrajés Tropicales* **1**(2), 137–155, DOI:10.17138/tgft(1)137-155.
- Casas Mas E., Arbelo M., Moreno-Ruiz J., Hernandez-Leal P. & Reyes-Carlos J., 2023. UAV-Based Disease Detection in Palm Groves of Phoenix canariensis Using Machine Learning and Multispectral Imagery. *Remote Sens.* **15**, 3584, DOI:10.3390/rs15143584.
- Crabbe R.A., Lamb D. & Edwards C., 2020. Discrimination of species composition types of a grazed pasture landscape using Sentinel-1 and Sentinel-2 data. *Int. J. Appl. Earth Obs. Geoinformation* **84**, 101978, DOI:10.1016/j.jag.2019.101978.
- Decruyenaere V., Seutin Y. & Stilmant D., 2016. Place de la prairie pâturée dans les schémas d'engraissement. Présenté aux Journées d'études sur Les légumineuses, éléments clés pour les systèmes d'élevage herbagers. *Organic eprints*, 51709.
- FAO, 2022. *World Food and Agriculture – Statistical Yearbook 2022*, FAO, Rome.
- Forsmo J., Anderson K., Macleod C.J.A., Wilkinson M.E. & Brazier R., 2018. Drone-based structure-from-motion photogrammetry captures grassland sward height variability. *Journal of Applied Ecology* **55**(6), 2587–2599, DOI:10.1111/1365-2664.13148.
- Gargiulo J.I., Lyons N.A., Masia F., Beale P., Insua J.R., Correa-Luna M. & Garcia S.C., 2023. Comparison of Ground-Based, Unmanned Aerial Vehicles and Satellite Remote Sensing Technologies for Monitoring Pasture Biomass on Dairy Farms. *Remote Sens.* **15**(11), 2752, DOI:10.3390/rs15112752.
- Grüner E., Astor T. & Wachendorf M., 2019. Biomass Prediction of Heterogeneous Temperate Grasslands Using an SfM Approach Based on UAV Imaging. *Agronomy* **9**(2), 54, DOI:10.3390/agronomy9020054.

Bibliographie

- Grüner E., Wachendorf M. & Astor T., 2020. The potential of UAV-borne spectral and textural information for predicting aboveground biomass and N fixation in legume-grass mixtures. *PLoS One* **15**(6), e0234703, DOI:10.1371/journal.pone.0234703.
- Howland M., Tamberino A., Liritzis I. & Levy T., 2022. Digital Deforestation: Comparing Automated Approaches to the Production of Digital Terrain Models (DTMs) in Agisoft Metashape. *Quaternary* **5**(1), 5, DOI:10.3390/quat5010005.
- Hütt C., Isselstein J., Komainda M., Schöttker O. & Sturm A., 2024. UAV LiDAR-based grassland biomass estimation for precision livestock management. *Journal of Applied Remote Sens.* **18**(1), 1-12, DOI:10.1117/1.JRS.18.017502.
- Hyowon Lee, Hyo-Jin Lee, Jong-Sung Jung, & Han-Jong Ko, 2015. Mapping Herbage Biomass on a Hill Pasture using a Digital Camera with an Unmanned Aerial Vehicle System. *J. Korean Soc. Grassl. Forage Sci.* **35**(3), 225–231, DOI:10.5333/KGFS.2015.35.3.225.
- Kolláth Z., Cool A., Jechow A., Kolláth K., Száz D. & Tong K., 2020. Introducing the Dark Sky Unit for multi-spectral measurement of the night sky quality with commercial digital cameras. *Journal of Quant. Spectrosc. Radiat. Transf.* **253**, 107162, DOI:10.1016/j.jqsrt.2020.107162.
- Kümmerer R., Noack P.O. & Bauer B., 2023. Using High-Resolution UAV Imaging to Measure Canopy Height of Diverse Cover Crops and Predict Biomass. *Remote Sens.* **15**(6), 1520, DOI:10.3390/rs15061520.
- Lambert R., Van der Veeren B., Decamps C., Cremer S., De Toffoli M. & Javaux M., 2020. Production fourragère et sécheresse, quelles solutions pour la Wallonie? Présenté aux Journées de l'Association Française pour la Production Fourragère. *Fourrages* **244**, 31-37.
- Lu B. & He Y., 2017. Species classification using Unmanned Aerial Vehicle (UAV)-acquired high spatial resolution imagery in a heterogeneous grassland. *ISPRS J. Photogramm. Remote Sens.* **128**, 73–85, DOI:10.1016/j.isprsjprs.2017.03.011.
- Lussem U., Bolten A., Menne J., Gnyp M.L. & Bareth G., 2019. ULTRA-HIGH SPATIAL RESOLUTION UAV-BASED IMAGERY TO PREDICT BIOMASS IN TEMPERATE GRASSLANDS. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **XLII-2-W13**, 443–447, DOI:10.5194/isprs-archives-XLII-2-W13-443-2019.
- Manfreda S., McCabe M.F., Miller P.E., Lucas R., Pajuelo Madrigal V., Mallinis G., Ben Dor E., Helman D., Estes L., Ciraolo G., Müllerová J., Tauro F., De Lima M.I., De Lima J.L.M.P., Maltese A., Frances F., Caylor K., Kohv M., Perks M., Ruiz-Pérez G., Su Z., Vico G. & Toth B., 2018. On the Use of Unmanned Aerial Systems for Environmental Monitoring. *Remote Sens.* **10**(4), 641, DOI:10.3390/rs10040641.
- Michez A., Bauwens S., Brostaux Y., Hiel M.-P., Garré S., Lejeune P. & Dumont B., 2018. How Far Can Consumer-Grade UAV RGB Imagery Describe Crop Production? A 3D and Multitemporal Modeling Approach Applied to *Zea mays*. *Remote Sens.* **10**(11), 1798, DOI:10.3390/rs10111798.
- Michez A., Lejeune P., Bauwens S., Herinaina A.A.L., Blaise Y., Castro Muñoz E., Lebeau F. & Bindelle J., 2019. Mapping and Monitoring of Biomass and Grazing in Pasture with an Unmanned Aerial System. *Remote Sens.* **11**(5), 473, DOI:10.3390/rs11050473.

Bibliographie

- Michez A., Philippe L., David K., Sébastien C., Christian D. & Bindelle J., 2020. Can Low-Cost Unmanned Aerial Systems Describe the Forage Quality Heterogeneity? Insight from a Timothy Pasture Case Study in Southern Belgium. *Remote Sensing* **12**(10), 1650, DOI:10.3390/rs12101650.
- Parker W.J., Muller L.D. & Buckmaster D.R., 1992. Management and Economic Implications of Intensive Grazing on Dairy Farms in the Northeastern States1. *J. Dairy Sci.* **75**(9), 2587–2597, DOI:10.3168/jds.S0022-0302(92)78021-7.
- Reinermann S., Asam S. & Kuenzer C., 2020. Remote Sensing of Grassland Production and Management—A Review. *Remote Sens.* **12**(12), 1949, DOI:10.3390/rs12121949.
- Rueda-Ayala V.P., Peña J.M., Höglind M., Bengochea-Guevara J.M. & Andújar D., 2019. Comparing UAV-Based Technologies and RGB-D Reconstruction Methods for Plant Height and Biomass Monitoring on Grass Ley. *Sensors* **19**(3), 535, DOI:10.3390/s19030535.
- Sanderson M., Rotz C.A., Fultz S. & Rayburn E., 2001. Estimating Forage Mass with a Commercial Capacitance Meter, Rising Plate Meter, and Pasture Ruler. *Agronomy Journal* **93**(6), DOI:10.2134/agronj2001.1281.
- Squires V.R., Dengler J., Feng H. & Hua L., 2018. *Grasslands of the World: Diversity, Management and Conservation*, CRC Press, Etats-Unis, DOI:10.1201/9781498796262.
- 't Mannetje L. & Jones R.M., 2000. Measuring biomass of grassland vegetation. In: *Field Laboratory Methods for Grassland and Animal Production Research*, CABI Books. 151–177, DOI:10.1079/9780851993515.0151.
- Tarr A., Moore K. & Dixon P., 2005. Spectral Reflectance as a Covariate for Estimating Pasture Productivity and Composition. *Crop Sci.* **45**(3), 996-1003, DOI:10.2135/cropsci2004.0004.
- Théau J., Lauzier-Hudon É., Aubé L. & Devillers N., 2021. Estimation of forage biomass and vegetation cover in grasslands using UAV imagery. *PLOS One* **16**(1), e0245784, DOI:10.1371/journal.pone.0245784.
- Viljanen N., Honkavaara E., Näsi R., Hakala T., Niemeläinen O. & Kaivosoja J., 2018. A Novel Machine Learning Method for Estimating Biomass of Grass Swards Using a Photogrammetric Canopy Height Model, Images and Vegetation Indices Captured by a Drone. *Agriculture* **8**(5), 70, DOI:10.3390/agriculture8050070.
- Wang X., Yan S., Wang W., Yin L., Li M., Yu Z., Chang S. & Hou F., 2023. Monitoring leaf area index of the sown mixture pasture through UAV multispectral image and texture characteristics. *Comput. Electron. Agric.* **214**(3), 108333-, DOI:10.1016/j.compag.2023.108333.
- Wijesingha J., Astor T., Schulze-Brüninghoff D., Wengert M. & Wachendorf M., 2020. Predicting Forage Quality of Grasslands Using UAV-Borne Imaging Spectroscopy. *Remote Sens.* **12**(1), 126, DOI:10.3390/rs12010126.
- Yang J., Fu X., Hu Y., Huang Y., Ding X. & Paisley J., 2017. PanNet: A Deep Network Architecture for Pan-Sharpening. Présenté à l' IEEE International Conference on Computer Vision, 5449–5457, DOI:10.1109/ICCV.2017.193.

10. Webographie

- Agisoft Metashape: User Manuals, Juillet-26-2024. . <https://www.agisoft.com/downloads/user-manuals/>, (26/07/2024).
- Agromet.be, Juillet-26-2024. . <https://www.agromet.be/fr/pages/home/>, (26/07/2024).
- EC20 Bluetooth Electronic Platometer, Juillet-31-2024. . *Jenquip*. <https://www.jenquip.nz/product-page/ec20-bluetooth-electronic-platometer>, (31/07/2024).
- Formations et examens UAS - SPF mobilité et transports, Mars-13-2024. . *SPF Mobilité et Transports* <http://mobilit.belgium.be/fr/aviation/voler-en/drones-uas/formations-et-examens>, (13/03/2024).
- Fourrages Mieux, 2020a. Le pâturage. *fourragesmieux.be*. https://www.fourragesmieux.be/prairie_exploitation_paturage.html, (07/03/2024).
- Fourrages Mieux, 2020b. Prairie. *fourragesmieux.be*. <https://www.fourragesmieux.be/prairie.html>, (04/03/2024).
- Géoportail de la Wallonie, Février-29-2024. . <http://geoportail.wallonie.be/home.html>, (29/02/2024).
- Kay M., Elkin L.A., Higgins J.J. & Wobbrock J.O., 2021. ARTool: Aligned Rank Transform.
- Le Robert, Mars-13-2024. Drone - Définitions, synonymes, prononciation, exemples. *Dico En Ligne Robert*. <https://dictionnaire.lerobert.com/definition/drone>, (13/03/2024).
- MicaSense RedEdge MX processing workflow (including Reflectance Calibration) in Agisoft Metashape Professional, Juillet-26-2024. . *Help. Portal*. <https://agisoft.freshdesk.com/support/solutions/articles/31000148780-micasense-rededge-mx-processing-workflow-including-reflectance-calibration-in-agisoft-metashape-pro>, (26/07/2024).
- Roussel J.-R., Auty D., De Boissieu F. & Meador A.S., 2024. lidR: Airborne LiDAR Data Manipulation and Visualization for Forestry Applications.
- Specs - MATRICE 300 RTK - DJI Enterprise, Mars-4-2024. . *DJI*. <https://enterprise.dji.com/matrice-300/photo>, (04/03/2024).
- SPW, Mars-9-2024a. Appréhender la croissance de l’herbe - Portail de l’agriculture wallonne. *Agric. En Wallonie*. <http://agriculture.wallonie.be/cms/render/live/fr/sites/agriculture/home/recherche-developpement/adaptations-a-la-secheresse/resilience-fourragere/apprehender-la-croissance-de-lherbe.html>, (09/03/2024).
- SPW, Juillet-13-2024b. Productions végétales - Portail de l’agriculture wallonne. *Agric. En Wallonie*. <https://agriculture.wallonie.be/cms/render/live/fr/sites/agriculture/home/productions-agricoles/productions-vegetales.html>, (13/07/2024).
- SPW, Juillet-13-2024c. Adaptations à la sécheresse - Portail de l’agriculture wallonne. *Agric. En Wallonie*. <https://agriculture.wallonie.be/cms/render/live/fr/sites/agriculture/home/recherche-developpement/adaptations-a-la-secheresse.html>, (13/07/2024).
- SPW, Juillet-13-2024d. Gérer la prairie - Portail de l’agriculture wallonne. *Agric. En Wallonie*. <https://agriculture.wallonie.be/cms/render/live/fr/sites/agriculture/home/recherche-developpement/adaptations-a-la-secheresse/resilience-fourragere/gerer-la-prairie.html>, (13/07/2024).
- Support for DJI Mini 2, Mars-1-2024. . *DJI*. <https://www.dji.com/be/support/product/mini-2>, (01/03/2024).
- Universalis, Mars-9-2024. TÉLÉDÉTECTION. *Encyclopaedia Universalis*. <https://www.universalis.fr/encyclopedie/teledetection/>, (09/03/2024).
- WALCORS Réseau permanent de stations GNSS de référence de la Wallonie, Juillet-25-2024. . *Portail Walcors*. <https://gnss.wallonie.be/walcors.html>, (25/07/2024).

11. Annexes

A. Produits intermédiaires lors du traitement photogrammétrique

Les figures suivantes sont présentées à des fins d'illustration des différents produits qu'il est possible d'obtenir au départ d'images lorsque celles-ci sont traitées dans le logiciel Agisoft Metashape. La Figure 24 présente un nuage de points dense servant de base à la classification des points de sol. La Figure 25 représente une orthomosaïque RGB. Les Figures 26 et 27 représentent quant à elles respectivement un Modèle Numérique de Surface (MNS) et un Modèle Numérique de Terrain (MNT) obtenus après classification et rasterisation du nuage de points.




Figure 24 - Visualisation dans Agisoft Metashape du nuage de points généré à partir des données acquises le 10 avril avec le drone DJI Mavic 3M.



Figure 25 - Visualisation dans Agisoft Metashape de l'orthomosaïque RGB générée à partir des données acquises le 10 avril avec le drone DJI Mavic 3M.

Annexes




Figure 26 - Visualisation dans Agisoft Metashape du Modèle Numérique de Surface généré à partir des données acquises le 10 avril avec le drone DJI Mavic 3M.




Figure 27 - Visualisation dans Agisoft Metashape du Modèle Numérique de Terrain généré à partir des données acquises le 10 avril avec le drone DJI Mavic 3M.

B. Statistiques des résidus de hauteur utilisés dans l'ANOVA

Ce paragraphe fournit deux tableaux présentant les statistiques détaillées des résidus ayant été comparés au moyen de l'ANOVA non-paramétrique et des tests de Kruskal-Wallis. Cette information avait été résumée à la Figure 15 sous forme de graphe. L'intervalle de confiance a été calculé avec un seuil à 95% avec la formule ($n = 24$) :

$$IC = \bar{y} \pm 1,96 * \frac{sd}{\sqrt{n}}$$

où : \bar{y} = moyenne des résidus
 sd = écart-type des résidus
 n = nombre de résidus

Tableau 20 - Statistiques des résidus en validation des 9 régressions linéaires issues de la photogrammétrie.

Matériel	MNT	Moyenne [m]	Ecart-type [m]	Médiane [m]	Erreur standard [m]	Limite inf. IC [m]	Limite sup. IC [m]
MINI 2	MNT 1	0,239	0,0869	0,248	0,0177	0,204	0,273
	MNT 2	0,166	0,149	0,203	0,0304	0,107	0,226
	MNT 3	0,187	0,141	0,197	0,0289	0,131	0,244
3M	MNT 1	0,119	0,0585	0,119	0,0119	0,095	0,142
	MNT 2	0,139	0,0651	0,138	0,0133	0,113	0,165
	MNT 3	0,164	0,0524	0,156	0,0107	0,143	0,185
MICASENSE	MNT 1	0,118	0,0614	0,117	0,0125	0,0930	0,142
	MNT 2	0,0547	0,0762	0,0503	0,0156	0,0241	0,0852
	MNT 3	0,0609	0,0680	0,0708	0,0139	0,0337	0,0881

Tableau 21 - Statistiques des résidus en validation des 2 régressions linéaires issues du traitement Lidar.

Matériel	Méthode	Moyenne [m]	Ecart-type [m]	Médiane [m]	Erreur standard [m]	Limite inf. IC [m]	Limite sup. IC [m]
Lidar	Normalisation	0,0592	0,0585	0,0610	0,0119	0,0358	0,0826
	Rasterisation	0,110	0,0958	0,109	0,0195	0,0721	0,149

C. Cartes de hauteur et de biomasse

Dans le corps de texte, la Figure 16 présentait la carte de hauteur générée après application du modèle développé avec les données 3M-MNT1 sur la prairie de validation. Dans cette annexe, les Figures 28 et 29 présentent les cartes de hauteur générées après application du modèle développé pour les capteurs Mini2-MNT1 et MicaSense-MNT1. Ce sont ces trois cartes, qui, réunies, ont servi à générer la carte de l'écart-type de la hauteur estimée entre les modèles, présentée à la Figure 17. La Figure 30 est, quant à elle, issue de l'application du modèle RF de prédiction de la biomasse de la MicaSense avec l'ensemble des variables (modèles 21) sur la prairie de validation et est présentée à des fins illustratives. Cette carte de biomasse n'a pas été générée pour l'ensemble des modèles au vu de leur nombre élevé.

Annexes




Figure 28 - Carte de hauteur prédite sur la prairie de validation avec le modèle Mini2-MNT1.




Figure 29 - Carte de hauteur prédite sur la prairie de validation avec le modèle MicaSense-MNT1.




Figure 30 - Carte de biomasse prédite sur la prairie de validation avec le modèle RF de la MicaSense (modèles 21).

D. Performances des différents modèles intermédiaires

Dans le corps du travail, seuls les tableaux de performances de l'ensemble des modèles avec l'ensemble des variables explicatives étaient présentés. Ci-dessous sont présentés différents tableaux avec les résultats des différents modèles intermédiaires de prédiction de la biomasse pour les trois drones en fonction du nombre de variables explicatives utilisées pour chacun.

Tableau 22 - Performances des modèles d'estimation de la biomasse du Mini 2 à partir des 4 IV_{RGB} (modèles 13).

Matériel	Modèle	R2 calib. [-]	R2 valid. [-]	RMSE calib. [kgMS/ha]	RMSE valid. [kgMS/ha]	rRMSE calib. [%]	rRMSE valid. [%]
Mini 2	Stepwise (2 var.)	0,243	0,130	1182,57	2005,80	64,3	73,5
	Forward (2 var.)	0,243	0,130	1182,57	2005,80	64,3	73,5
	Backward (3 var.)	0,266	0,00861	1154,53	1781,37	62,7	65,2
	PCR (ncomp=1)	0,008	0,174	1375,33	1363,02	74,7	49,9
	PLS (ncomp=1)	0,236	0,0510	1207,07	2215,21	65,6	81,1
	RF (ntree=500 ; nsize= 10 ; mtry= 3)	0,0655	0,159	1335,12	1119,97	72,5	41,0
	SVM linéaire (C=0,01)	0,263	0,0935	1294,15	1373,02	70,3	50,3
	SVM radial (sigma= 0,075 ; C= 0,1)	0,173	0,0888	1145,1	1306,41	41,9	47,8

Tableau 23 - Performances des modèles d'estimation de la biomasse du 3M à partir des 4 IV_{RGB} (modèles 15).

Matériel	Modèle	R2 calib. [-]	R2 valid. [-]	RMSE calib. [kgMS/ha]	RMSE valid. [kgMS/ha]	rRMSE calib. [%]	rRMSE valid. [%]
3M	Stepwise (2 var.)	0,306	0,00503	1131,83	2000,62	61,5	73,3
	Forward (2 var.)	0,306	0,00503	1131,83	2000,62	61,5	73,3
	Backward (2 var.)	0,306	0,00503	1131,83	2000,62	61,5	73,3
	PCR (ncomp=1)	0,026	0,090	1381,09	1486,89	75,1	54,4
	PLS (ncomp=1)	0,261	0,039	1381,09	2220,46	75,1	81,3
	RF (ntree=500 ; nsize= 5 ; mtry= 1)	0,115	0,0075	1299,62	1145,18	70,1	41,9
	SVM linéaire (C=0,75)	0,400	0,000572	1214,80	1760,24	66,0	64,5
	SVM radial (sigma= 0,1 ; C= 0,25)	0,297	0,0143	1146,2	1342,07	62,3	49,2

Annexes

Tableau 24 - Performances des modèles d'estimation de la biomasse du 3M à partir des 4 IV_{RGB} et des métriques de hauteur (modèles 16).

Matériel	Modèle	R2 calib. [-]	R2 valid. [-]	RMSE calib. [kgMS/ha]	RMSE valid. [kgMS/ha]	rRMSE calib. [%]	rRMSE valid. [%]
3M	Stepwise (2 var.)	0,598	0,201	861,21	1517,36	46,8	55,6
	Forward (2 var.)	0,598	0,201	861,21	1517,36	46,8	55,6
	Backward (3 var.)	0,605	0,191	839,99	1285,35	45,6	47,1
	PCR (ncomp=2)	0,576	0,272	899,26	1532,95	48,9	56,1
	PLS (ncomp=2)	0,567	0,253	908,31	1553,95	49,36	56,9
	RF (ntree=500 ; nsize= 1 ; mtry= 3)	0,513	0,125	974,15	1128,27	52,9	41,3
	SVM linéaire (C=2)	0,557	0,146	959,37	1446,24	52,1	53,0
	SVM radial (sigma= 0,025 ; C= 0,75)	0,529	0,0948	1048,89	1145,31	57,0	41,9

Tableau 25 - Performances des modèles d'estimation de la biomasse de la MicaSense à partir des 4 IV_{RGB} (modèles 18).

Matériel	Modèle	R2 calib. [-]	R2 valid. [-]	RMSE calib. [kgMS/ha]	RMSE valid. [kgMS/ha]	rRMSE calib. [%]	rRMSE valid. [%]
MicaSense	Stepwise (1 var.)	0,0209	0,0820	1355,69	1428,36	73,7	52,3
	Forward (1 var.)	0,0209	0,0820	1355,69	1428,36	73,7	52,3
	Backward (1 var.)	0,0760	0,106	1295,58	1296,74	70,4	47,5
	PCR (ncomp=3)	0,037	0,136	1355,51	1453,98	73,7	53,2
	PLS (ncomp=2)	0,037	0,135	1355,62	1429,08	73,7	52,3
	RF (ntree=500 ; nsize= 5 ; mtry= 1)	-0,121	0,0296	1462,17	1160,41	79,5	42,5
	SVM linéaire (C=0,01)	0,229	0,0543	1335,72	1367,55	72,6	50,1
	SVM radial (sigma= 0,5 ; C= 0,05)	0,140	0,0160	1171,10	1424,85	77,4	52,2

Annexes

Tableau 26 - Performances des modèles d'estimation de la biomasse de la MicaSense à partir des 4 IV_{RGB} et des métriques de hauteur (modèles 19).

Matériel	Modèle	R2 calib. [-]	R2 valid. [-]	RMSE calib. [kgMS/ha]	RMSE valid. [kgMS/ha]	rRMSE calib. [%]	rRMSE valid. [%]
MicaSense	Stepwise (3 var.)	0,685	0,334	756,99	964,05	41,1	35,3
	Forward (3 var.)	0,685	0,334	756,99	964,05	41,1	35,3
	Backward (5 var.)	0,681	0,410	748,99	859,84	40,7	31,5
	PCR (ncomp=3)	0,633	0,369	836,39	934,62	45,5	34,2
	PLS (ncomp=2)	0,643	0,344	824,64	941,80	44,8	34,5
	RF (ntree=500 ; nsize= 5 ; mtry= 1)	0,575	0,106	900,53	1099,23	48,9	40,3
	SVM linéaire (C=5)	0,589	0,358	857,56	1012,86	46,6	37,1
	SVM radial (sigma= 0,025 ; C= 0,5)	0,428	0,263	1008,08	1037,53	54,8	38,0

Tableau 27 - Performances des modèles d'estimation de la biomasse de la MicaSense à partir des 4 IV_{RGB}, des 4 IV_{MS} et des métriques de hauteur (modèles 20).

Matériel	Modèle	R2 calib. [-]	R2 valid. [-]	RMSE calib. [kgMS/ha]	RMSE valid. [kgMS/ha]	rRMSE calib. [%]	rRMSE valid. [%]
MicaSense	Stepwise (6 var.)	0,685	0,334	756,99	964,05	41,1	35,3
	Forward (6 var.)	0,685	0,334	756,99	964,05	41,1	35,3
	Backward (8 var.)	0,713	0,273	691,26	1039,47	37,6	38,1
	PCR (ncomp=3)	0,660	0,368	804,87	943,93	43,7	34,6
	PLS (ncomp=3)	0,662	0,345	802,36	949,55	43,6	34,8
	RF (ntree=500 ; nsize= 5 ; mtry= 1)	0,551	0,106	925,63	1118,35	50,3	41,0
	SVM linéaire (C=5)	0,585	0,261	757,90	1063,56	41,2	39,0
	SVM radial (sigma= 0,075 ; C= 1)	0,490	0,0588	1002,15	1086,88	54,5	39,8