

Mémoire

Auteur : De Clerck, Victor

Promoteur(s) : Billen, Roland

Faculté : Faculté des Sciences

Diplôme : Master en sciences géographiques, orientation géomatique, à finalité spécialisée en géomètre-expert

Année académique : 2024-2025

URI/URL : <http://hdl.handle.net/2268.2/23944>

Avertissement à l'attention des usagers :

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

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



Faculté des sciences
Département de géographie

Analyse de techniques d'identification automatique de matériaux de toiture par télédétection

Mémoire présenté par : **Victor DE CLERCK**

pour l'obtention du titre de

**Master en sciences géographiques, orientation géomatique, à finalité
spécialisée en géomètre-expert**

Année académique : 2024-2025

Date de défense : 3-5 septembre 2025

Président de jury :

Pr. René WARNANT

Promoteur :

Pr. Roland BILLEN

Jury de lecture :

Pr. François JONARD

Pr. Roberta RAVANELLI

Remerciements

Je tiens tout d'abord à remercier le professeur Roland Billen, mon promoteur, pour la proposition du sujet, ses conseils, son suivi et ses relectures tout au long de ce travail.

Je remercie également le Docteur Abderrazzaq Kharroubi pour son aide et la supervision de mon mémoire, notamment concernant les parties de Machine Learning.

Je tiens également à remercier Zakaria Bnoulkacem, doctorant à l'Université d'Anvers, qui a accepté de faire une réunion avec nous pour répondre à certaines questions concernant la classification automatique de matériaux de construction.

Je remercie également Coraline Wyard (ISSEP) qui a accepté de me recevoir pour m'expliquer plus en détail le projet CASMATTELE, et qui a accepté, suite à notre rencontre, de me donner les données d'entraînement sur la ville de Liège utilisées dans le cadre de ce mémoire.

Je remercie également le professeur François Jonard pour la mise à disposition d'un drone et d'un capteur LiDAR et d'un capteur multispectral pour la campagne d'acquisition de données qui a été réalisée dans le cadre de ce mémoire. Merci aussi au Docteur Jordan Bates qui a piloté le drone et qui m'a aidé dans le traitement des données drone. Je remercie également le personnel administratif des bâtiments du campus vétérinaire qui nous a autorisés à réaliser le vol.

Finalement, je remercie mon ami Benjamin, étudiant en master en IA à l'Université de Maastricht, pour son aide lors des traitements de Machine Learning.

Résumé

La production de matériaux de construction émet beaucoup de gaz à effet de serre. La mise en place d'une économie circulaire aurait le potentiel de réduire grandement ces émissions. En Wallonie, des réhabilitations massives sont nécessaires pour atteindre les objectifs climatiques fixés à l'horizon 2050. Ce processus engendrera une production importante de déchets de démolition, représentant déjà 40 % des déchets en Wallonie. Dans ce contexte, le projet Interreg « RE-USE » vise à promouvoir la construction circulaire dans la région Meuse-Rhin en réutilisant les matériaux issus de bâtiments démolis au lieu de les jeter. Ce mémoire s'inscrit dans ce cadre avec comme but de faire un état de l'art sur ce qui se fait en matière d'identification automatique de matériaux de construction.

L'état de l'art a mis en évidence la diversité des approches existantes pour la classification automatique des matériaux de construction, allant des méthodes classiques basées sur l'analyse d'images RGB à des approches intégrant le multispectral ou l'hyperspectral, les données LiDAR, la combinaison de plusieurs types de données et du LiDAR multispectral. Concernant les méthodes de classification, le ML (type SVM, RF, ...) est largement utilisé, ainsi que le DL.

Ce travail s'est focalisé sur la reconnaissance de matériaux de toiture. L'objectif a alors été d'évaluer si une précision suffisante peut être atteinte pour l'économie circulaire (> 95 %) et d'analyser la plus-value de données à plus haute résolution (drone) que les données en accès libre de la Wallonie.

Pour cela, un modèle d'identification de 11 classes de matériaux de toiture a été construit sur base des orthophotos (RGB + NIR) et du MNS de la Wallonie et de données annotées fournies par Coraline Wyard de l'ISSEP. Des caractéristiques ont été calculées : ombres, textures et pentes. Deux algorithmes de ML ont été utilisés : SVM et RF. L'Accuracy pour la meilleure combinaison de caractéristiques et d'algorithme atteint 96,5 %, démontrant la capacité d'identification des matériaux de toiture.

Ensuite ce modèle a été appliqué pour faire de la prédiction sur des données en accès libre à 25 cm de résolution et sur des données plus fines (multispectral 4,9 cm, MNS 2,5 cm) acquises en drone. Globalement, les données drone offrent de meilleurs résultats que les orthophotos en accès libre. Néanmoins, même avec les données drone, certaines erreurs localisées persistent, sûrement à cause des différentes conditions d'illuminations lors de l'acquisition. L'idéal serait d'entraîner le modèle directement sur des données drone mais cela demanderait beaucoup de ressources.

Abstract

The production of construction materials emits a large amount of greenhouse gases. The implementation of a circular economy would have the potential to greatly reduce these emissions. In Wallonia, large-scale rehabilitations are necessary to meet the climate targets set for 2050. This process will generate a large amount of demolition waste, which already represents 40% of waste in Wallonia. In this context, the Interreg « RE-USE » project aims to promote circular construction in the Meuse–Rhine region by reusing materials from demolished buildings instead of throwing them away. This thesis fits into this framework with the aim of producing a state of the art on automatic identification of construction materials.

The state of the art highlighted the diversity of existing approaches for the automatic classification of construction materials, ranging from classical methods based on RGB image analysis to approaches integrating multispectral or hyperspectral data, LiDAR data, the combination of several data types, and multispectral LiDAR. Regarding classification methods, ML (e.g., SVM, RF, ...) is widely used, as is DL.

This work focused on roof materials recognition. The objective was then to assess whether sufficient accuracy can be achieved for the circular economy ($> 95\%$) and to analyze the added value of higher-resolution (drone) data compared to the open-access data of Wallonia.

To this end, a model identifying 11 roof-material classes was built on the basis of orthophotos (RGB + NIR) and the Walloon DSM, as well as annotated data provided by Coraline Wyard from ISSEP. Features were computed : shadows, textures, and slopes. Two ML algorithms were used : SVM and RF. The accuracy for the best combination of features and algorithm reaches 96.5%, demonstrating the capacity to identify roof materials.

The model was then applied to make predictions on open-access data at 25 cm resolution and on finer data (multispectral 4.9 cm, DSM 2.5 cm) acquired by drone. Overall, the drone data offer better results than the open-access orthophotos. Nevertheless, even with the drone data, certain localized errors persist, likely due to varying illumination conditions during acquisition. Ideally, the model would be trained directly on drone data, but this requires substantial resources.

Table des matières

Remerciements	1
Résumé	2
Abstract	3
Table des matières	4
Liste des abréviations	7
1 Introduction	8
2 État de l’art	10
2.1 Données d’entrée	10
2.2 Classification basée sur des images	10
2.3 Classification basée sur de l’imagerie multispectrale et hyperspectrale . . .	11
2.3.1 Bibliothèques hyperspectrales	17
2.4 Classification basée sur du LiDAR	18
2.5 Classification basée sur des combinaisons de méthodes	22
2.6 Méthodes de classification	25
2.7 Conclusion de l’état de l’art	26
3 Question de recherche	28
4 Méthodologie	29
4.1 Construction du modèle de classification	30
4.1.1 Données utilisées	30
4.1.1.1 Données d’entraînement	30

4.1.1.1.1	Bibliothèques spectrales	30
4.1.1.1.2	Jeu de données d'entraînement du projet CASMATTELE	30
4.1.1.2	Images multispectrales	32
4.1.1.3	Modèle Numérique de Surface (MNS) - LiDAR	33
4.1.2	Prétraitements et construction des caractéristiques	33
4.1.2.1	Fusion de classes	33
4.1.2.2	Zones ombragées	34
4.1.2.3	Calcul des textures	35
4.1.2.4	Calcul des pentes médianes par échantillon	36
4.1.3	Algorithmes utilisés	38
4.1.3.1	Support Vector Machine (SVM)	38
4.1.3.2	Random Forest (RF)	42
4.1.4	Validation et évaluation des classifications	46
4.2	Application du modèle à la ville de Liège	48
4.3	Application du modèle à des données plus fines	49
4.3.1	Acquisition des données drone	49
4.3.2	Préparation des données drone	51
4.3.3	Prétraitements des données drone	52
4.3.3.1	Normalisation radiométrique	52
4.3.3.2	Zones ombragées	55
4.3.3.3	Pente	57
4.3.4	Application du modèle	57
4.3.5	Comparaison avec les données en accès libre de la Wallonie	58

5 Résultats

59

5.1	Validation et évaluation des modèles de classification	59
5.2	Application du meilleur modèle à une zone de Liège	64
5.3	Application du meilleur modèle aux données drone	67
5.3.1	Comparaison avec les données en accès libre de la Wallonie	70
5.3.2	Superficies de matériaux identifiés	73
6	Discussion	74
6.1	Échantillonnage	74
6.2	Caractéristiques prises en compte	74
6.3	Algorithmes de classification	75
6.4	Application du modèle	75
6.5	Plus-value des données drone	76
7	Conclusion	78
	Références	79
	Annexes	85

Liste des abréviations

BAI Burned Area Index.

CA Ciment-asbeste.

DL Deep Learning.

HSV Hue Saturation Value.

LiDAR Light Detection and Ranging.

ML Machine Learning.

MNS Modèle Numérique de Surface.

NIR Near Infrared = Proche infrarouge.

PICC Projet Informatique de Cartographie Continue.

RF Random Forest.

SCR Système de Coordonnées de Référence.

SVM Support Vector Machine.

SWIR Short-wave Infrared = Infrarouge à ondes courtes.

VIS Visible.

1 Introduction

La population et la richesse continuent de croître à l'échelle mondiale. On estime que la surface bâtie dans le monde devrait doubler d'ici à 2060, que 300 millions d'habitations devront être construites d'ici à 2030 et que l'on bâtit l'équivalent de la superficie de Paris tous les 5 jours (UNEP & CEA, 2023). Dans un contexte de transition écologique et de raréfaction des ressources, le secteur de la construction fait face à d'importants défis environnementaux : consommation de ressources, d'énergie et émissions de gaz à effet de serre (Barbhuiya & Das, 2023). Les émissions provenant du secteur de la construction et des bâtiments ne permettront pas, selon les projections, de respecter l'accord de Paris de 2015 fixant un objectif de hausse globale de la température mondiale à moins d'1,5 °C par rapport à la période préindustrielle (UNEP & CEA, 2023).

On distingue deux types d'émissions dans le secteur de la construction et des bâtiments :

Les émissions intrinsèques : il s'agit des émissions associées à la construction et à la déconstruction d'un bâtiment. Cela comprend l'extraction, la production de matériaux, le transport et la construction sur site.

Les émissions opérationnelles : elles correspondent aux émissions dues à l'utilisation et à la maintenance du bâtiment. Cela comprend le chauffage, la climatisation et l'éclairage, entre autres. Actuellement, les émissions intrinsèques représentent 25 % des émissions sur le cycle de vie d'un bâtiment, mais ce chiffre devrait atteindre 50 % à l'horizon 2050 pour un scénario de statu quo. Il s'agit d'une augmentation relative, car les émissions opérationnelles devraient diminuer, notamment grâce à l'amélioration de l'isolation. L'illustration des émissions au cours du cycle de vie d'un bâtiment est disponible à la Figure 1.

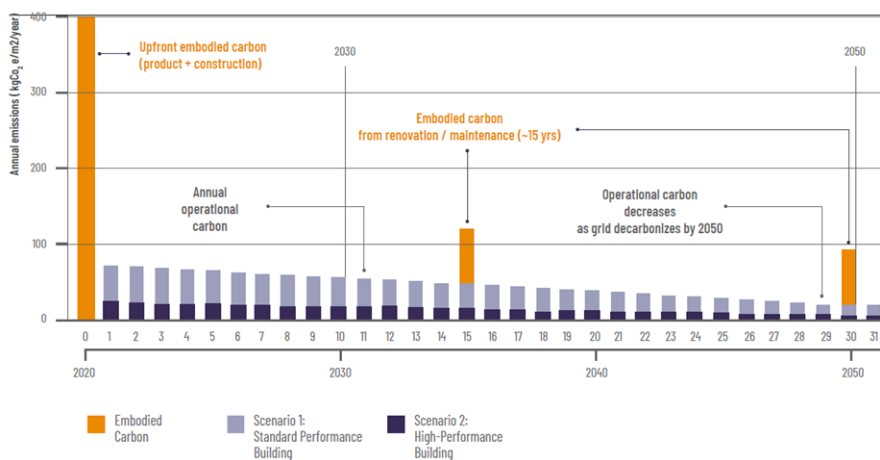


FIGURE 1 – Illustration des émissions au cours du cycle de vie d'un bâtiment (UNEP & CEA, 2023).

En effet, la production de matériaux génère une quantité importante de gaz à effet de serre. À elle seule, la fabrication du béton, de l'aluminium et de l'acier serait responsable d'environ 6 à 11 % des émissions mondiales, tandis que la production de briques et de verre contribuerait à hauteur de 3 % (UNEP, 2022 ; UNEP & CEA, 2023). Pour réduire ces émissions intrinsèques, la rénovation et la réutilisation constituent des solutions. La mise en place d'une économie circulaire aurait le potentiel de réduire les émissions liées aux matériaux de construction de 38 % d'ici 2050 (Santos et al., 2024). De plus, le secteur de la construction est un grand consommateur (environ 50 %) des matières premières (Santos et al., 2024). Et cette consommation devrait presque doubler d'ici 2060 (UNEP & CEA, 2023). Or, certaines ressources finies, comme le sable et les graviers, utilisés dans le béton, l'asphalte et le verre sont fortement exploités et connaissent déjà des problèmes d'approvisionnement ce qui mène à de l'exploitation illégale, notamment de sable de rivières (Santos et al., 2024).

En Wallonie, le parc résidentiel existant, à la fois urbain et rural, se compose majoritairement de maisons unifamiliales anciennes, souvent peu performantes sur le plan énergétique. Pour atteindre les objectifs climatiques fixés à l'horizon 2050, des réhabilitations massives sont nécessaires, notamment en améliorant l'enveloppe thermique des bâtiments. Ce processus engendrera une production importante de déchets de démolition, représentant déjà 40 % des déchets en Wallonie. Toutefois, dans une logique d'« urban mining », ces matériaux issus de la déconstruction sont perçus comme une ressource réutilisable, capable d'alimenter de nouveaux cycles de production. Actuellement en Wallonie, les études sur le gisement de matériaux contenus dans le bâti se concentrent sur quelques matériaux (comme le béton ou le sable), via des approches descendantes basées sur des données statistiques. Cependant, la diversité des matériaux présents dans le bâti ancien (bois, pierre, brique, verre, etc.) reste largement sous-documentée. Le manque de données fines et de méthodes adaptées freine l'évaluation précise du potentiel de réutilisation (Trachte et al., 2025).

Il y a donc dans ce contexte une grande demande pour la classification automatique de matériaux de construction. Notons qu'une telle classification peut également servir à tout un tas d'autres applications telles que les simulations énergétiques de bâtiments, l'étude des effets d'îlots de chaleur urbains, les simulations sismiques et la détection et l'inventaire des produits dangereux comme l'amiante ou les métaux lourds (Trachte et al., 2025 ; Wyard, Beaumont, Hallot & ISSeP, 2023 ; Wyard, Marion & Hallot, 2023 ; L. Yuan et al., 2020 ; Zahiri et al., 2022).

Ce travail s'inscrit dans ce contexte et plus particulièrement dans le cadre du projet Interreg « RE-USE ». Ce projet vise à promouvoir la construction circulaire dans la région Meuse-Rhin en réutilisant les matériaux issus de bâtiments démolis au lieu de les jeter. Le projet relève quatre grands défis : la disponibilité des données, la complexité des règles juridiques, les problèmes concrets liés à la construction et la coopération transfrontalière (Interreg Meuse - Rhine, 2025 ; Université de Liège, 2025).

2 État de l’art

Cette section a pour objectif la revue de la littérature des travaux et des techniques existantes sur la classification automatique de matériaux de construction.

2.1 Données d’entrée

Jusqu’à présent, les approches basées sur l’analyse d’images constituent la méthode la plus répandue pour la classification automatique des matériaux de construction (Yuan et al., 2020). Récemment, la classification sur base de méthodes de télédétection telles que le Light Detection And Ranging (LiDAR), l’imagerie multispectrale et hyperspectrale s’est fortement développée (Ilehag et al., 2017). Néanmoins, encore peu d’études se sont consacrées à la classification de matériaux de construction (Zahiri et al., 2021). Ces méthodes de classification ont l’avantage d’être des méthodes non destructives. Elles vont être passées en revue dans la suite de ce chapitre.

Par ailleurs, les drones sont de plus en plus utilisés, notamment pour leur mobilité, leur facilité de déploiement et la possibilité d’embarquer des capteurs de télédétection. Grâce à l’utilisation de drones, il est possible d’acquérir des données à basse altitude, offrant ainsi un niveau de détail plus élevé et des mesures moins affectées par les perturbations atmosphériques que celles obtenues par des capteurs satellitaires ou embarqués sur avion (Ilehag et al., 2017).

2.2 Classification basée sur des images

Parmi les méthodes non destructives de classification des matériaux, les approches basées sur l’analyse d’images ont été les plus utilisées jusqu’à maintenant. Ces méthodes, largement utilisées dans la littérature, s’appuient sur des techniques d’apprentissage automatique pour identifier les matériaux à partir d’images RGB (L. Yuan et al., 2020). Elles ont l’avantage d’être faciles à mettre en place car elles ne requièrent que la couleur de chaque pixel comme donnée d’entrée (Son et al., 2014). On distingue deux grands types d’approches : les méthodes basées sur les pixels, qui attribuent une classe de matériau à chaque pixel en analysant des caractéristiques comme la couleur ou la texture, et les méthodes basées sur les objets, qui classifient des blocs d’images en tant qu’objets entiers (L. Yuan et al., 2020).

Par exemple, Son et al. (2014) ont utilisé avec succès la couleur comme variable d’entrée pour identifier du béton, de l’acier et du bois. Han & Golparvar-Fard (2015) ainsi que Dimitrov & Golparvar-Fard (2014) ont utilisé des blocs carrés pour classifier des matériaux de construction courants dans des conditions réelles. Han & Golparvar-Fard (2015) ont

également généré un nuage de points grâce à la technique de photogrammétrie « Structure from Motion » (SfM).

Les méthodes de classification des matériaux basées sur l'analyse d'images présentent encore des limites importantes, en particulier dans des environnements réels. En effet, les variations d'illumination affectent fortement les valeurs de couleur dans l'espace RGB, rendant l'apparence d'un matériau instable selon l'environnement, ce qui peut dégrader la qualité des données et donc les performances de détection (Son et al., 2014 ; L. Yuan et al., 2020). Enfin, la seule information de couleur ne suffit pas toujours : certains matériaux partagent des couleurs similaires tout en ayant des textures différentes (ex. : béton et asphalte), tandis que d'autres présentent des textures proches mais des couleurs distinctes (ex. : briques et tuiles). Il est donc pertinent de combiner des caractéristiques de couleur et de texture pour améliorer la reconnaissance (Yang et al., 2016).

2.3 Classification basée sur de l'imagerie multispectrale et hyperspectrale

L'imagerie multispectrale ou hyperspectrale repose sur la capacité des matériaux à réfléchir la lumière différemment selon les longueurs d'onde du spectre électromagnétique. Cette technique constitue une méthode de télédétection passive, car elle dépend d'une source d'illumination externe, généralement le soleil.

Le spectre électromagnétique désigne l'ensemble des gammes d'ondes électromagnétiques classées selon leur longueur d'onde ou leur fréquence. Il s'étend des rayons gamma aux ondes radio. Pour la télédétection optique, les longueurs d'onde les plus couramment exploitées pour la caractérisation des matériaux se situent entre 0,4 et 2,5 μm , couvrant les domaines visible (VIS) entre 0,4 et 0,75 μm , le domaine du proche infrarouge (NIR) entre 0,75 et 1,4 μm et le domaine de l'infrarouge à ondes courtes (SWIR) entre 1,4 et 2,5 μm (voir Figure 2).

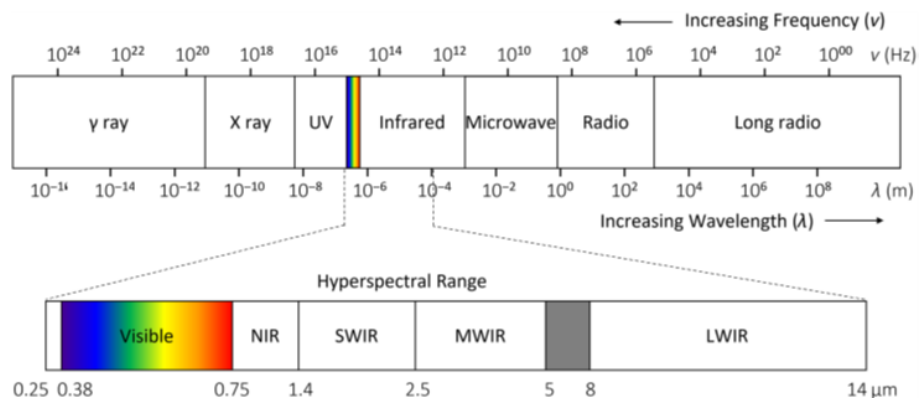


FIGURE 2 – Illustration du spectre électromagnétique avec un zoom sur la gamme de la télédétection optique (Salcido & Laefer, 2024).

La réflectance spectrale correspond à la fraction de lumière réfléchi par une surface par rapport à la lumière incidente. Cette réflectance est différente pour chaque longueur d'onde selon les matériaux, ce qui forme une signature spectrale unique à chaque matériau. Comme le soulignent Amano et al. (2018), la signature spectrale fournit des indications plus précises sur la nature des matériaux que les couleurs visibles seules, ce qui permet de distinguer plus finement les matériaux et ouvre la voie à des méthodes d'identification des matériaux plus robustes et moins sensibles aux conditions d'éclairage.

L'imagerie hyperspectrale fournit une plus grande quantité d'informations (plus grande résolution spectrale) que l'imagerie multispectrale, ce qui facilite la distinction entre les matériaux, notamment grâce à la continuité spectrale (Ilehag et al., 2019). La faible résolution spectrale du multispectral peut limiter les capacités de reconnaissance des matériaux car les caractéristiques discriminantes de leur signature spectrale peuvent n'apparaître que dans des bandes spectrales plus étroites (Salcido & Laefer, 2024). Toutefois, cette richesse en données de l'hyperspectral engendre une complexité de traitement plus élevée. Par ailleurs, l'imagerie hyperspectrale présente certains inconvénients par rapport à l'imagerie multispectrale, notamment un coût beaucoup plus élevé qui explique son utilisation encore cantonnée aux experts. Un autre inconvénient de l'hyperspectral est le poids plus important des capteurs, qui complique leur déploiement sur des drones. Néanmoins, le secteur est en train de se démocratiser, comme la fait le secteur du LiDAR ces 20 dernières années, avec des capteurs devenant de plus en plus accessibles (Salcido & Laefer, 2024 ; Zahiri et al., 2021, 2022).

L'étude des signatures spectrales a déjà prouvé son utilité pour la classification de dépôts minéraux, pour cartographier la déforestation, pour étudier la santé des végétaux, et d'autres applications diverses (Salcido & Laefer, 2024). La classification de matériaux de construction en utilisant de l'imagerie multispectrale et hyperspectrale présente un défi à cause de la complexité et de l'hétérogénéité des matériaux en milieu urbain. De plus, il peut y avoir une grande variabilité intra-classe en raison de facteurs tels que la couleur, le revêtement, les processus de fabrication des matériaux ou encore les conditions d'éclairage. En effet, l'angle entre le matériau, le soleil et le capteur influence de manière significative la variabilité spectrale (Ilehag et al., 2019 ; Salcido & Laefer, 2024). Wyard, Marion & Hallot (2023) mettent en évidence que les signatures spectrales sont fortement influencées par la couleur des matériaux de toiture, en particulier dans le domaine VIS, notamment lorsque les matériaux sont colorés ou peints. Ils soulignent donc l'importance d'inclure la couleur de surface dans la description des matériaux de construction. En revanche, le domaine spectral SWIR (1000–2500 nm) se révèle généralement plus pertinent pour différencier les types de matériaux, grâce à des variations plus marquées de leur réflectance. Une exception notable concerne les matériaux de couleur noire, qui présentent des signatures spectrales très similaires et peu contrastées, avec une réflectance faible et constante sur l'ensemble de la gamme spectrale. C'est notamment le cas des tuiles en béton noires, des ardoises de couleur anthracite (naturelles ou artificielles), des membranes EPDM noires et des membranes bitumineuses (voir Figure 3).

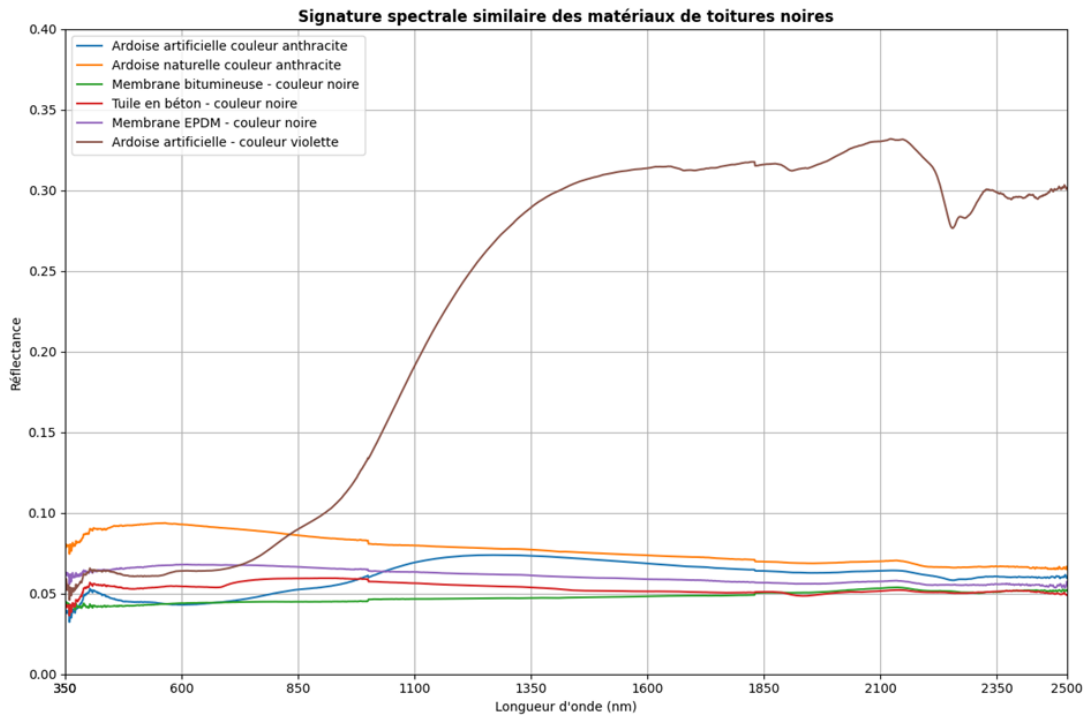


FIGURE 3 – Illustration de la similitude des signatures spectrales des matériaux de toitures noires sur base des données de Wyard, Marion & Hallot (2023).

Cette grande ressemblance des signatures spectrales de ces matériaux rend leur classification sur base de données multispectrales difficile. Souvent, des informations supplémentaires sur la texture du matériau sont requises. De leur côté, Ilehag et al. (2019) mettent en évidence que des matériaux visuellement distincts peuvent partager des signatures spectrales proches, et au contraire des matériaux de même nature peuvent avoir des signatures spectrales qui diffèrent selon la structure, la texture ou le revêtement du matériau (voir Figure 4), soulignant l'importance de combiner des informations contextuelles pour affiner la classification.

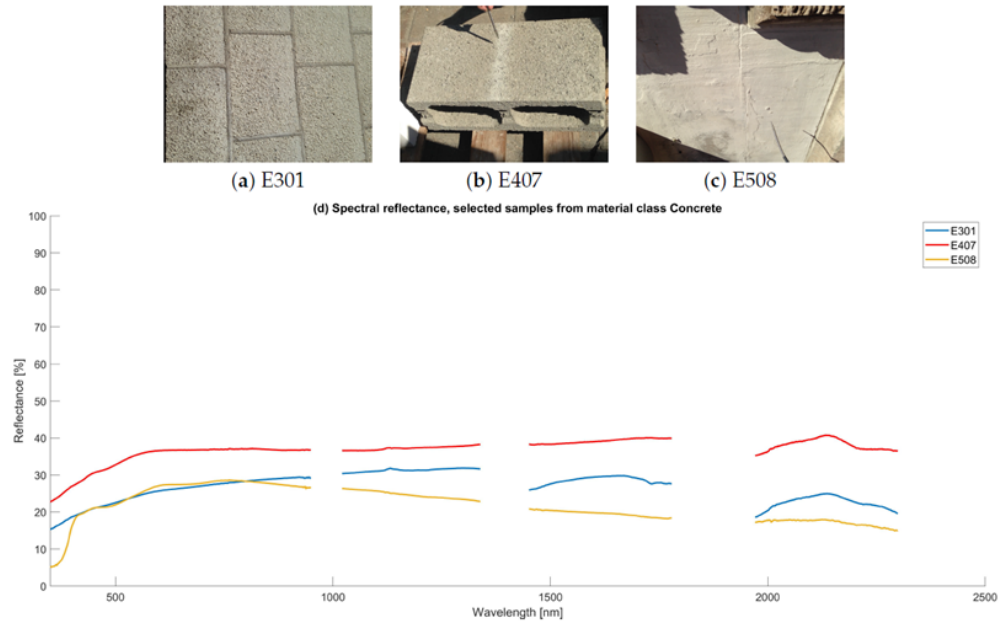


FIGURE 4 – Différence de spectre électromagnétique de trois échantillons de béton. De gauche à droite : béton clair, béton gris et béton peint (Ileahag et al., 2019).

Malgré toutes ces difficultés, la classification de matériaux de construction sur base d'imagerie multispectrale ou hyperspectrale a déjà été réalisée avec succès par plusieurs études.

Par exemple, Zahiri et al. (2021) ont utilisé de l'imagerie multispectrale pour classifier automatiquement des matériaux de façade (béton, brique, mortier). Le capteur utilisé capture des images dans cinq bandes spécifiques : bleu (0,475 μm), vert (0,56 μm), rouge (0,668 μm), RedEdge (0,717 μm) et NIR (0,84 μm). L'étude repose sur un jeu de données créé par les auteurs, constitué de 213 échantillons de matériaux. Ces échantillons ont été organisés en deux murs (calibration/validation) et scannés dans des conditions d'illumination contrôlées. Les résultats montrent un taux de classification correct moyen de 82,75 %, démontrant l'efficacité de l'imagerie multispectrale dans l'identification des matériaux.

Zahiri et al. (2022) ont comparé la capacité des approches multispectrale et hyperspectrale à classifier cinq matériaux de façade courants, en utilisant un capteur hyperspectral à 240 bandes (1,3–2,5 μm) et un capteur multispectral RedEdge à 5 bandes (0,475–0,84 μm), plus léger et plus économique. Pour cela, la classification est réalisée avec un jeu d'entraînement de 95 pixels et un jeu de validation de 65 pixels par matériau. Les résultats montrent une précision de classification de 99 % pour l'hyperspectral, contre 80 % pour le multispectral. Bien que moins performant, le capteur multispectral reste capable de fournir des résultats satisfaisants, ce qui en fait une alternative viable pour des applications à moindre coût et plus accessibles.

Dans une autre étude, Bonifazi et al. (2019) ont appliqué l'imagerie hyperspectrale dans le domaine de l'infrarouge à ondes courtes (SWIR : 1–2,5 μm) pour distinguer les matériaux contenant de l'amiante de matériaux tels que le mortier, la brique, la fibre de verre ou le bois. Leurs résultats sont bons, montrant que cette approche permet une détection fine des matériaux dangereux.

De plus, Ilehag et al. (2017) ont réussi à classifier différents matériaux urbains tels que le béton, le bois, l'asphalte ou le métal à partir d'imagerie hyperspectrale couvrant le spectre VIS, le NIR et le SWIR, soit une plage allant de 0,4 μm à 2,4 μm , en s'appuyant sur des bibliothèques spectrales existantes.

On note également l'étude de Ilehag et al. (2020) qui explore la classification de matériaux urbains en combinant des caractéristiques spectrales et texturales provenant d'une bibliothèque spectrale. Les résultats montrent que les caractéristiques spectrales sont plus discriminantes que la texture.

Finalement, le projet CASMATTELE (CAractérisation Semi-automatique des MATériaux de Toitures par TELEdéttection) de l'Institut Scientifique du Service Public de Wallonie (ISSeP) est un travail très intéressant qui a été coordonné principalement par Coraline Wyard. Le projet CASMATTELE a été réalisé en deux parties, avec un premier volet entre 2019 et 2020 et un second entre 2020 et 2023 venant améliorer le premier (Wyard, Beaumont, Hallot & ISSeP, 2023 ; Wyard, Beaumont, Palmaerts et al., 2022 ; Wyard, Beaumont, Tais Grippa et al., 2022 ; Wyard, Fauvel et al., 2023 ; Wyard, Marion & Hallot, 2023 ; Wyard et al., 2020, 2021). Le projet CASMATELLE consistait à classifier des matériaux de toitures par télédétection sur base des orthophotos multispectrales à 4 bandes (RGB + NIR) ayant une résolution de 25 cm. Ces données sont fournies par le Service Public de Wallonie (SPW) et sont en accès libre sur le géoportail de la Wallonie (WalOnMap). Leur étude s'est concentrée sur une zone de 25 km^2 centrée sur Liège. Cette zone comporte un total de 75 716 bâtiments, ce qui porte la densité à 3029 bâtiments/ km^2 . Sur la base d'observations de terrain et de la bibliothèque hyperspectrale WaRM (voir section suivante sur les bibliothèques hyperspectrales), 13 classes principales de matériaux ont été retenues pour leur étude. Ces 13 classes sont détaillées en annexe A.

Pour le projet, un jeu de données d'entraînement et de validation a été constitué avec un total de plus de 2500 échantillons qui ont été identifiés en utilisant Google Earth en raison de la résolution spatiale très fine qu'offrent ces images et de la possibilité de visualiser en 3D, qui permet de visualiser la texture des matériaux, contrairement aux orthophotos. Une validation a ensuite été effectuée par un expert comprenant une inspection des images Google Earth et une visite sur le terrain pour les échantillons problématiques (<1 %). Certaines classes présentent peu d'échantillons (<100) en raison de leur rareté dans la zone d'étude. Au total, cette étape de création du jeu de données aura pris 15 jours de travail.

Un prétraitement des données a été réalisé avant de faire la classification.

Premièrement, ils ont utilisé le Projet Informatique de Cartographie Continue (PICC) de la Wallonie pour créer un masque « bâtiments » servant à extraire l’emprise des bâtiments. Le PICC a le défaut d’être décalé par rapport aux orthophotos, il a donc fallu recalculer manuellement les orthophotos par rapport au masque bâtiment du PICC. Pour ce faire, une transformation polynomiale du troisième degré a été réalisée en considérant une dizaine de points de contrôle par image basés sur des bâtiments avec 2 étages en plus du rez-de-chaussée, car il s’agit du type de bâtiment le plus fréquent en Wallonie. Cela veut donc dire que les bâtiments n’ayant pas exactement cette hauteur n’étaient pas parfaitement calés par rapport au masque « bâtiments ». Dès lors, certains morceaux d’image ne correspondaient pas à des toitures (morceaux de façades, de jardin et de route), ce qui a nécessairement réduit la performance de la classification.

Ensuite, les parties ombrées des toitures ont été enlevées des orthophotos, car celles-ci peuvent perturber les algorithmes de classification. Pour ce faire, les auteurs de l’étude CASMATTELE ont utilisé l’indice « Burn Area Index » (BAI) qui exploite les bandes rouge et infrarouge des orthophotos pour mettre en évidence les zones chaudes et froides :

$$BAI = \frac{1}{(0.1 - RED)^2 + (0.06 - NIR)^2}$$

Une fois les orthophotos prétraitées, une segmentation a été réalisée de façon à obtenir des objets distincts.

Les auteurs ont testé plusieurs combinaisons de données pour leur travail. La classification a été testée utilisant uniquement les trois bandes RGB et en considérant également le NIR. Un indice de texture calculé sur la base des orthophotos a également été pris en compte ainsi que l’année de construction des parcelles (information fournie par l’AGDP souvent nommée le « cadastre »).

Les premières classifications réalisées ont mis en évidence les limites des orthophotos RGB + NIR pour différencier l’ensemble de ces matériaux avec des précisions¹ comprises entre 44,5 et 58,9 %. Bien que certaines classes comme les tuiles oranges et la végétation soient correctement discriminées (précision > 80 %), la majorité des autres classes présentent de fortes confusions dues à la similitude de leur signature spectrale dans le domaine du visible et du proche-infrarouge. L’ajout d’un indice de texture calculé à partir des orthophotos a amélioré partiellement la détection de certaines classes, notamment les tuiles noires, les ardoises (avec ou sans ciment amianté), les fenêtres de toit et les toitures métalliques. Parmi les tests réalisés, l’ajout de la bande proche-infrarouge constitue

1. Pour évaluer leurs classifications les auteurs du projet CASMATTELE ont utilisé la « Producer Accuracy » (PA) : la part des échantillons d’une classe réelle qui ont été correctement classés et la « User Accuracy » (UA) : la probabilité qu’un pixel de la carte représentant une certaine classe corresponde effectivement à cette classe dans la réalité. Ils ont ensuite calculé les moyennes de ces PA et UA. Finalement, la moyenne de ces deux mesures a été considérée comme la précision moyenne de la classification. Une autre mesure est généralement calculée pour évaluer une classification : l’Accuracy, qui est le rapport entre le nombre total de bonnes prédictions et le nombre total d’échantillons.

l'amélioration la plus significative, avec un gain moyen de précision d'environ 6 % par rapport à une classification utilisant uniquement les trois bandes RGB. Certaines classes, telles que les panneaux solaires (+8,2 %), les tôles ondulées en fibrociment amianté (+26 %), les graviers (+17,3 %) et la végétation (+19,7 %), ont particulièrement bénéficié de cette quatrième bande. Toutefois, la précision diminue pour les fenêtres de toit (-5 %), probablement en raison de leur variabilité spectrale ou géométrique. L'ajout de données cadastrales (année de construction et nature des parcelles) n'améliore pas significativement la précision moyenne par rapport à l'utilisation des quatre bandes seules. En effet, les données cadastrales ne sont disponibles qu'au niveau des parcelles, ce qui limite leur pertinence lorsqu'un bâtiment récent coexiste avec des constructions plus anciennes sur la même unité cadastrale.

Le plus grand problème persistant est la confusion entre les matériaux de couleur dominante similaire qui présentent des signatures spectrales proches, rendant leur distinction difficile avec les seules données RGB + NIR. Dès lors, une information spectrale plus riche, notamment dans les longueurs d'ondes du SWIR où bon nombre de matériaux se distinguent, permettrait de diminuer la confusion entre les matériaux de couleurs similaires. Mais ce type de données n'existe pas actuellement en accès libre pour la Wallonie. Notons toutefois que l'analyse des spectres complets montre que certains matériaux noirs comme les membranes noires (bituminée et EPDM), les ardoises sans CA (naturelles et artificielles), les métaux (aluminium peint en noir) absorbent toutes les longueurs d'onde mesurées (entre 0,25 et 3,5 μm). Pour ces classes de matériaux, l'usage de données spectrales seules ne sera pas suffisant pour les différencier.

Lors du deuxième volet du projet CASMATTELE, des améliorations ont été apportées et ont permis d'augmenter les performances de 20 %. On note notamment l'ajout d'une zone tampon interne de 2 pixels des orthophotos (soit 0,5 m) au niveau des bordures de tous les toits afin d'exclure un maximum de pixels mixtes et de pixels n'appartenant pas aux toits. La seconde règle est la fusion des trois classes de tuiles (oranges, brunes et noires) en une seule. Notons que pour ce deuxième volet du projet, les ombres n'ont pas été corrigées. La précision finalement obtenue est de 67 %. Toutes les classes affichent une précision supérieure ou égale à 60 %, à l'exception des ardoises sans CA (41 %) qui sont souvent confondues avec les ardoises en CA et des matériaux translucides en verre ou polymère qui sont souvent confondus avec les panneaux solaires.

2.3.1 Bibliothèques hyperspectrales

La disponibilité de bibliothèques hyperspectrales de matériaux de construction est un élément clé pour la classification à partir d'images hyperspectrales, en particulier pour distinguer des matériaux de nature différente et reconnaître un même matériau dans des conditions différentes (Salcido & Laefer, 2024). Elles peuvent être utilisées comme données d'entraînement pour la classification dans des endroits où aucune information préalable

n'est connue et où il n'est pas possible d'avoir des données de terrain (Ilehag et al., 2019). On distingue les librairies in-situ des librairies faites en conditions de laboratoires. En général, les librairies créées en laboratoires ne reflètent pas la réalité car les données sont collectées avec des conditions d'illumination particulières, et sur des matériaux neufs et propres, tandis que les bâtiments in-situ peuvent voir leur signature spectrale modifiée par le dépôt de sels ou d'autres particules issues de la pollution (Ilehag et al., 2017; Zahiri et al., 2022). Notons que les matériaux de construction peuvent varier d'une région à l'autre en fonction des disponibilités des matériaux et qu'en général les librairies hyperspectrales représentent une région en particulier (Ilehag et al., 2020; Kotthaus et al., 2014).

Il n'existe pas, à ce jour, de bibliothèque unifiée des signatures spectrales des matériaux urbains. Un récent article de synthèse proposé par Salcido & Laefer (2024) dresse un état des lieux approfondi de la disponibilité et de la qualité des bibliothèques hyperspectrales dédiées aux milieux urbains. Ils analysent les bibliothèques selon les principes FAIR : Facilité à être trouvées, Accessibilité, Interopérabilité et Réutilisabilité. Cette revue de Salcido & Laefer (2024) est résumée en Annexe B.

2.4 Classification basée sur du LiDAR

Le LiDAR est une technologie de télédétection active qui utilise des impulsions laser, généralement émises dans le proche infrarouge (NIR), pour mesurer la distance entre le capteur et une surface. En combinant le temps de retour du signal avec la position et l'orientation du capteur, il est possible de déterminer avec précision la position tridimensionnelle ainsi que certaines propriétés de la surface ciblée. Le premier signal réfléchi correspond généralement au sommet de l'objet rencontré, tandis que le dernier retour est identique au premier si la surface est plane (par exemple, un parking). En revanche, lorsqu'il s'agit d'une surface irrégulière ou semi-transparente à l'impulsion laser, comme la végétation, le faisceau peut partiellement pénétrer la matière. Dans ce cas, le dernier retour représente souvent le niveau du sol, tandis que le premier retour reflète la surface supérieure, permettant ainsi d'étudier la structure verticale des objets scannés (Herold & Roberts, 2010). La technologie du LiDAR a l'avantage, par rapport à l'imagerie passive de ne pas être dépendante aux conditions d'illuminations (L. Yuan et al., 2020).

Dans leur étude, L. Yuan et al. (2020) ont mis en œuvre une méthode de classification supervisée des matériaux de construction uniquement à partir de données LiDAR issues de scanner laser terrestre (TLS) dans des conditions réelles. Le TLS utilisé a une caméra embarquée et permet de générer un nuage de points colorisé. Le jeu de données constitué comprend plus de 94 000 points, extraits de surfaces planes représentant dix matériaux de construction couramment rencontrés tels que le béton, la brique, le bois, le métal ou encore le plâtre. Chaque point a été annoté manuellement selon le matériau auquel il appartenait. Le jeu de données a été divisé en deux : 80 % pour l'entraînement du modèle

et 20 % des points pour la validation du modèle.

Trois descripteurs physiques extraits ont été utilisés pour la classification : (1) la réflectance du matériau (ρ), (2) la couleur (en espace HSV), et (3) la rugosité de surface (R_a).

La réflectance du matériau (ρ) est dérivée de l'intensité du laser réfléchi (I_r) qui varie selon les paramètres de scannage et le matériau. L'objectif est donc d'extraire la réflectance du matériau qui est l'unique propriété intrinsèque au matériau. Il apparaît qu'il existe une relation linéaire entre I_r et ρ :

$$I_r = \rho K \frac{\cos \theta}{R^2} + b$$

où :

- K est un terme reprenant le facteur de transmission atmosphérique, l'intensité du laser émis, le diamètre d'ouverture du récepteur, le facteur de transmission du système et la surface unitaire. Ce terme est constant pour un même TLS et pour des distances inférieures à 20 m.
- θ est l'angle d'incidence du laser sur la cible.
- R est la distance entre le TLS et la cible.
- b est un terme constant.

Le calcul de la réflectance du matériau se fait sur base du voisinage de chaque point. Le voisinage de chaque point est composé de tous les points qui se trouvent dans un cube de 50 cm de côté centré sur ce point (voir Figure 5).




FIGURE 5 – Calcul du voisinage d'un point selon L. Yuan et al. (2020).

Ensuite, $\cos \theta / R^2$ est calculé pour chaque point selon la formule suivante :

$$\frac{\cos \theta}{R^2} = \frac{\sqrt{\frac{x^2+y^2}{x^2+y^2+z^2}}}{x^2 + y^2 + z^2}$$

Tandis que l' I_r est obtenu via les données LiDAR. Finalement, une régression linéaire entre I_r et $\cos \theta / R^2$ est tracée. Notons que cette relation linéaire dépend de la distance R car les TLS sont équipés de réducteurs de luminosité pour protéger le scanner d'une intensité laser réfléchiée extrêmement élevée. On observe donc des relations différentes pour les distances entre 10 et 4 m, entre 4 et 2 m et en dessous de 2 m :

$$\begin{cases} I_r = \rho K_1 \frac{\cos \theta}{R^2} + b_1, & 4 \text{ m} < R < 10 \text{ m} \\ I_r = \rho K_2 \frac{\cos \theta}{R^2} + b_2, & 2 \text{ m} < R < 4 \text{ m} \\ I_r = \rho K_3 \frac{\cos \theta}{R^2} + b_3, & R < 2 \text{ m} \end{cases}$$

Finalement, le facteur ρK est obtenu et est directement utilisé comme réflectance du matériau car il est difficile d'estimer la valeur de K .

La couleur du matériau est capturée en RGB mais exprimer la couleur dans l'espace HSV est préférable car cela permet une meilleure constance par rapport aux conditions

d'illumination. La transformation entre le système RGB et le système HSV se fait comme suit (L. Yuan et al., 2020) :

$$\left. \begin{aligned} r &= \frac{R}{255}, \quad g = \frac{G}{255}, \quad b = \frac{B}{255}, \\ Ma &= \max(r, g, b), \quad Mi = \min(r, g, b), \quad \Delta = Ma - Mi, \\ H &= \begin{cases} 0^\circ, & \text{si } Ma = Mi, \\ 60^\circ \times \frac{g-b}{\Delta} + 0^\circ, & \text{si } Ma = r \text{ et } g >> b, \\ 60^\circ \times \frac{g-b}{\Delta} + 360^\circ, & \text{si } Ma = r \text{ et } g < b, \\ 60^\circ \times \frac{b-r}{\Delta} + 120^\circ, & \text{si } Ma = g, \\ 60^\circ \times \frac{r-g}{\Delta} + 240^\circ, & \text{si } Ma = b, \end{cases} \\ S &= \begin{cases} 0, & \text{si } Ma = 0, \\ \frac{\Delta}{Ma}, & \text{sinon,} \end{cases} \\ V &= Ma \end{aligned} \right\}$$

La rugosité de surface est la mesure de l'irrégularité d'une surface. Pour calculer cette caractéristique pour un point, L. Yuan et al. (2020) ont considéré le voisinage de ce point comme les points étant à l'intérieur d'un cube de 20 cm de coté. Ensuite, ils ont calculé le plan ajusté passant par ces points. Ce plan peut être exprimé comme :

$$Ax + By + Cz + D = 0.$$

La distance entre chaque point et ce plan ajusté est calculée comme suit :

$$d_i = \frac{|Ax_i + By_i + Cz_i + D|}{\sqrt{A^2 + B^2 + C^2}}$$

Enfin, la rugosité de la surface est calculée comme étant l'écart-type de cette distance d_i .

$$R_a = \sqrt{\frac{1}{n} \sum_{i=1}^n (d_i - \mu)^2}, \quad \text{avec} \quad \mu = \frac{1}{n} \sum_{i=1}^n d_i$$

Notons que ce calcul de rugosité de surface nécessite une précision assez fine des données LiDAR (plus fine que les irrégularités que l'on veut mesurer).

Les résultats de cette étude montrent que certains matériaux ont des caractéristiques (réflectance, couleur et rugosité) assez dispersées et donc que différents matériaux peuvent avoir des caractéristiques fortement semblables. Cela peut entraîner la confusion entre les matériaux par les modèles. C'est par exemple le cas pour le mortier qui est confondu dans

7 % des cas avec de la pierre (voir Figure 6).

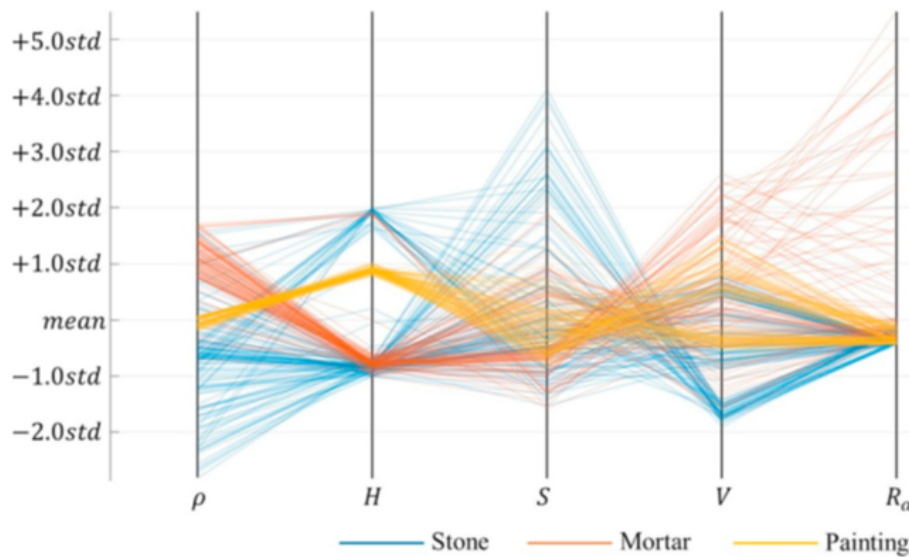


FIGURE 6 – Valeurs des caractéristiques (réflectance, couleur et rugosité) pour 3 types de matériaux (pierre, mortier et peinture) (L. Yuan et al., 2020).

L'étude de L. Yuan et al. (2020) a néanmoins quelques limitations comme le fait qu'uniquement des surfaces planes sont étudiées, ce qui permet de calculer la rugosité comme expliqué ci-dessus. Une approche possible pour calculer la rugosité sur des surfaces non-planes serait de d'abord détecter si la surface est plane ou courbe avant de procéder au calcul de la rugosité de surface. De plus, uniquement des surfaces homogènes ont été étudiées, or le fait d'avoir des points voisins constitués d'un matériau différent affecterait le calcul de réflectance et de rugosité qui se basent sur le voisinage du point. Une solution envisageable à ce problème serait de vérifier la consistance des points du voisinage sur base de la couleur car la couleur n'est pas affectée par le voisinage. Notons également que l'humidité du matériau a un impact sur l'intensité du laser réfléchi ce qui fausse l'estimation de la réflectance du matériau. Il faudrait gommer cet effet dû à l'humidité de la surface avant de calculer la réflectance du matériau. Finalement, cette étude n'identifie pas le verre des fenêtres. Pour cela, Pu & Vosselman (2009) proposent d'identifier les fenêtres comme étant les zones où la densité de points est très faible car le laser ne réfléchit que très peu sur le verre.

2.5 Classification basée sur des combinaisons de méthodes

Lors du projet CASMATTELE, des règles de post-classification ont été mises en œuvre en tenant compte de la pente des toitures, afin de mieux différencier certains matériaux difficiles à distinguer sur le seul critère spectral. L'utilisation de MNS permet d'intégrer cette information topographique. Elle facilite ainsi la séparation entre matériaux visuellement similaires, mais généralement associés à des typologies de toitures différentes :

les membranes se retrouvant majoritairement sur des surfaces plates, tandis que les tuiles et ardoises sont typiques des toits inclinés. Notons que le MNS utilisé lors du projet CASMATTELE avait une résolution spatiale de 1 m, mais qu'un nouveau MNS issu du nouveau LiDAR wallon (2021-2022) offre une meilleure résolution (0,5 m). Wyard, Beaumont, Hallot & ISSeP (2023) suggèrent que l'utilisation de ce nouveau MNS pourrait permettre d'obtenir de meilleurs résultats.

Jusqu'à récemment, la combinaison de l'imagerie multispectrale et des données LiDAR avait été peu exploitée pour la classification des matériaux de construction. Toutefois, certaines études ont déjà réussi à fusionner ces deux types de données pour cartographier des toitures contenant de l'amiante (Abbasi et al., 2022 ; Norman et al., 2020). Une autre étude proposée par Zahiri et al. (2021) combine imagerie multispectrale (5 bandes entre 0,475 et 0,84 μm) et intensité LiDAR pour classifier automatiquement des matériaux de façade (béton, brique et mortier). Leur méthodologie est la suivante : les nuages de points générés par deux scanners LiDAR terrestres ont été projetés en plans 2D afin de créer une image ayant la même dimension que les images multispectrales. Ensuite, la moyenne des intensités des points LiDAR est calculée pour chaque pixel de cette image (voir Figure 7).




FIGURE 7 – Visulisation de la méthodologie employée par Zahiri et al. (2021) pour fusionner des données LiDAR et multispectrales (Zahiri et al., 2021).

Chaque pixel de l'image multispectrale a ainsi été enrichi avec les valeurs d'intensité issues des deux capteurs LiDAR, formant un cube de données à sept dimensions (cinq bandes multispectrales + deux intensités LiDAR) (Voir Figure 8).

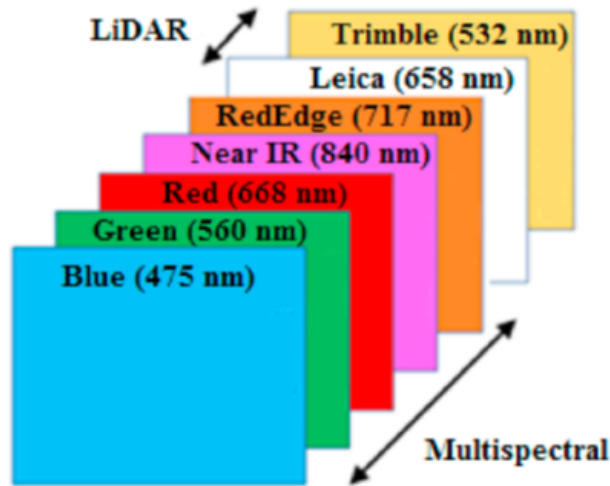


FIGURE 8 – Illustration du cube de données à sept dimensions (cinq bandes multispectrales + deux intensités LiDAR (Zahiri et al., 2021).

Notons que Zahiri et al. (2021) utilisent des échantillons ayant tous la même forme et ayant des conditions de surface identiques de façon à ce que l'intensité ne dépende que du comportement électromagnétique et non de caractéristiques géométriques des échantillons. De plus, les intensités n'ont pas été converties en réflectance, contrairement à L. Yuan et al. (2020), car la surface scannée est relativement petite et donc peu de variance dans l'intensité a été observée. Les résultats montrent un taux moyen de classification correcte de 83,07 % avec les données fusionnées, contre 82,75 % avec les seules données multispectrales. Si l'apport du LiDAR s'avère marginal sur le plan global, il améliore la classification pour certaines classes spécifiques (les briques et les mortiers), mais peut également la dégrader pour d'autres (notamment le béton). Zahiri et al. (2021) soulignent ainsi que la combinaison de différentes technologies, comme l'imagerie multispectrale et le LiDAR, est prometteuse, mais dépend des matériaux. Aussi, les recherches futures devront évaluer si les bénéfices potentiels de l'intégration des données LiDAR justifient les contraintes supplémentaires liées à l'acquisition de données issues de plusieurs capteurs, ainsi qu'au stockage et traitement supplémentaires qui en découlent.

Une méthode alternative consiste à projeter des images multispectrales/hyperspectrales sur des nuages de points 3D afin d'enrichir ces derniers avec des signatures spectrales détaillées. Chaque point du nuage est ainsi associé à des données spectrales, ce qui facilite la segmentation sémantique de scènes complexes (López et al., 2022).

Finalement, une technologie récente émergente constitue une alternative particulièrement prometteuse : le LiDAR multispectral. Cette technologie permet de collecter simultanément des données géométriques 3D et spectrales à plusieurs longueurs d'onde à partir d'un seul capteur actif. Plusieurs études montrent que la classification peut être réalisée uniquement à partir des informations issues d'un LiDAR multispectral (Ekhtari et al., 2017 ; Takhtkeshha et al., 2024). Par exemple, Morsy et al.

(2022) ont obtenu une précision allant jusqu'à 93 % pour la classification de scènes urbaines complexes en utilisant uniquement les données d'un LiDAR multispectral ayant des informations spectrales à 0,532, 1,064 et 1,55 μm . De même, Takhtkeshha et al. (2024) soulignent que, contrairement aux approches de fusion de données multispectrales et LiDAR, le LiDAR multispectral permet non seulement de surmonter les problèmes d'alignement spatial et temporel des capteurs multiples, mais permet également de s'affranchir des problèmes de conditions d'illuminations variables puisqu'il s'agit d'un capteur de télédétection active. Ce système offre donc une fiabilité accrue pour la classification des matériaux et des objets, mais reste encore très rarement disponible.

2.6 Méthodes de classification

De nombreuses études ont exploré diverses approches de classification pour l'identification des matériaux de construction à partir de données spectrales, qu'il s'agisse de méthodes de Machine Learning (ML) classiques ou d'approches plus récentes en Deep Learning (DL). Parmi les algorithmes les plus couramment utilisés en ML figurent les algorithmes de « Support Vector Machine » (SVM) et de « Random Forest » (RF) (Alaloul & Qureshi, 2021 ; Belgiu & Drăguț, 2016 ; Dimitrov & Golparvar-Fard, 2014 ; Han & Golparvar-Fard, 2015 ; Ilehag et al., 2017, 2020 ; Son et al., 2014 ; Wyard, Beaumont, Hallot & ISSeP, 2023 ; Wyard et al., 2020 ; L. Yuan et al., 2020). Dans une revue comparative, Alaloul & Qureshi (2021) ont mis en évidence la fréquence d'utilisation et la performance de ces classifieurs dans des études menées entre 2010 et 2020, montrant que l'efficacité particulière du SVM. D'autres travaux, comme ceux de Ilehag et al. (2017, 2020), ont montré que les RF peuvent surpasser le SVM. Tandis que Géron (2019) déclare que RF est l'un des algorithmes de ML les plus puissants actuellement disponibles.

En parallèle, le DL connaît un essor rapide. Plusieurs études ont mis en œuvre des réseaux de neurones convolutifs (CNN) pour améliorer la reconnaissance des matériaux. Mahami et al. (2021) ont proposé un modèle CNN entraîné sur un jeu de données composé de 1231 images couvrant 11 classes de matériaux, et ont démontré que ce type de réseau surpassait les méthodes classiques, en particulier dans des conditions d'éclairage variées. Davis et al. (2021) ont, quant à eux, utilisé un CNN pour classer les déchets de construction dans un contexte de tri en chantier, atteignant une précision de 94 % pour les images contenant un seul type de déchet, et de 92 % pour les images mixtes. Le projet CASMATELLE a en outre testé une approche en DL avec des CNN, qui ont montré des résultats supérieurs (81 %) à ceux des méthodes classiques. Notons toutefois que ces meilleurs résultats ont été obtenus uniquement sur les orthophotos RGB à plus haute résolution (5 cm) de la ville de Namur, fournies par la ville. En revanche, pour des images à plus faible résolution (25 cm), les performances du CNN étaient inférieures à celles des méthodes de ML comme le SVM. Ainsi, selon les résultats du projet CASMATELLE, l'utilisation du DL n'est donc pertinente qu'avec des données à très haute résolution

spatiale. Ainsi, lorsque les images disponibles se limitent à 25 cm de résolution, il serait plus intéressant de rester sur des méthodes de ML. Bien que de manière générale, la tendance actuelle privilégie les approches en DL, notamment les CNN, pour leur capacité à extraire automatiquement des caractéristiques pertinentes à partir d’images complexes. Toutefois, leur performance dépend fortement de la qualité et de la résolution des données d’entrée utilisées.

2.7 Conclusion de l’état de l’art

Cet état de l’art a mis en évidence la diversité des approches existantes pour la classification automatique des matériaux de construction, allant des méthodes classiques basées sur l’analyse d’images RGB à des approches intégrant le multispectral ou l’hyperspectral, les données LiDAR, la combinaisons de plusieurs types de données et du LiDAR multispectral.

Les méthodes basées sur l’imagerie RGB, bien que largement répandues en raison de leur simplicité et de leur faible coût, souffrent de limitations importantes liées à la sensibilité aux conditions d’illumination, à la variabilité intra-matériau et aux confusions fréquentes entre matériaux visuellement similaires (Son et al., 2014 ; L. Yuan et al., 2020).

Les capteurs multispectraux et hyperspectraux offrent une meilleure capacité de discrimination des matériaux grâce à leur exploitation des signatures spectrales uniques (Amano et al., 2018). L’imagerie hyperspectrale a une plus grande résolution spectrale que l’imagerie multispectrale, ce qui facilite la distinction entre les matériaux (Ilehag et al., 2019 ; Salcido & Laefer, 2024). Cependant, l’hyperspectral reste plus complexe à manipuler et plus coûteuse, ce qui fait du multispectral un compromis intéressant entre performance et accessibilité, en particulier dans le cadre de déploiements sur drones (Salcido & Laefer, 2024 ; Zahiri et al., 2021, 2022). Ces méthodes restent dépendantes des conditions d’éclairage et de la variabilité des matériaux en milieu urbain (Ilehag et al., 2019 ; Salcido & Laefer, 2024 ; Wyard, Beaumont, Hallot & ISSeP, 2023).

Les données LiDAR, issues de capteurs actifs, offrent un complément précieux grâce à leur indépendance vis-à-vis de la lumière ambiante et leur capacité à fournir des informations géométriques telles que la rugosité de surface (L. Yuan et al., 2020). Les approches combinées, fusionnant les données spectrales (multispectrales ou hyperspectrales) avec les données LiDAR, se révèlent intéressantes pour améliorer la précision de classification. Toutefois, leur mise en œuvre nécessite de résoudre des défis liés à l’alignement spatial et temporel des capteurs (Abbasi et al., 2022 ; López et al., 2022 ; Norman et al., 2020 ; Wyard, Beaumont, Hallot & ISSeP, 2023 ; Zahiri et al., 2021). Enfin, l’émergence du LiDAR multispectral représente une avancée technologique majeure. En intégrant en un seul capteur les avantages des données géométriques et spectrales, cette technologie ouvre la voie à des classifications plus robustes, indépendantes

de l'illumination et sans les contraintes liées à la fusion de capteurs multiples (Morsy et al., 2022 ; Takhtkeshha et al., 2024).

Concernant les algorithmes de classification, les méthodes de ML telles que le SVM ou le RF sont largement utilisées pour leur simplicité et leurs bons résultats dans de nombreuses études de classification de matériaux de construction (Alaloul & Qureshi, 2021 ; Belgiu & Drăguț, 2016 ; Dimitrov & Golparvar-Fard, 2014 ; Han & Golparvar-Fard, 2015 ; Ilehag et al., 2017, 2020 ; Son et al., 2014 ; Wyard, Beaumont, Hallot & ISSeP, 2023 ; Wyard et al., 2020 ; L. Yuan et al., 2020). Le DL, en particulier les CNN, offre généralement de meilleures performances grâce à l'extraction automatique de caractéristiques, mais requiert des données à haute résolution spatiale (Davis et al., 2021 ; Mahami et al., 2021 ; Wyard, Beaumont, Hallot & ISSeP, 2023).

3 Question de recherche

Ce mémoire s’inscrit dans le cadre plus large du projet Interreg « RE-USE », dont l’objectif est de promouvoir la réutilisation des matériaux de construction afin de favoriser une économie circulaire (Université de Liège, 2025). Le projet étant à ses débuts, l’un des premiers objectifs de ce mémoire est de réaliser un état de l’art sur les méthodes existantes d’identification automatique des matériaux de construction et de mettre en œuvre une première classification automatique de matériaux de construction.

Un second objectif consiste à analyser la valeur ajoutée de données acquises par drone notamment en raison de leur meilleure résolution spatiale par rapport à des images de plus faible qualité disponibles en accès libre. Notons que seule l’étude des toitures a été retenue, une analyse complète des façades dépassant le cadre de ce travail.

Dans ce contexte, une question de recherche principale (QR) a été formulée :

QR : Est-ce que l’on peut atteindre une précision d’identification des matériaux de toitures adaptée aux attentes de l’économie circulaire ($> 95\%$) sur base de données en accès libre ?

Ainsi qu’une sous-question de recherche :

Sous-QR : Est-ce possible d’appliquer un modèle entraîné sur des données à faible résolution spatiale à des données à plus haute résolution spatiale (drone). Et est-ce que cela améliore significativement l’identification automatique des matériaux de toiture ?

4 Méthodologie

L'ensemble de la méthodologie adoptée pour ce travail est présenté dans l'organigramme figurant à la Figure 9.

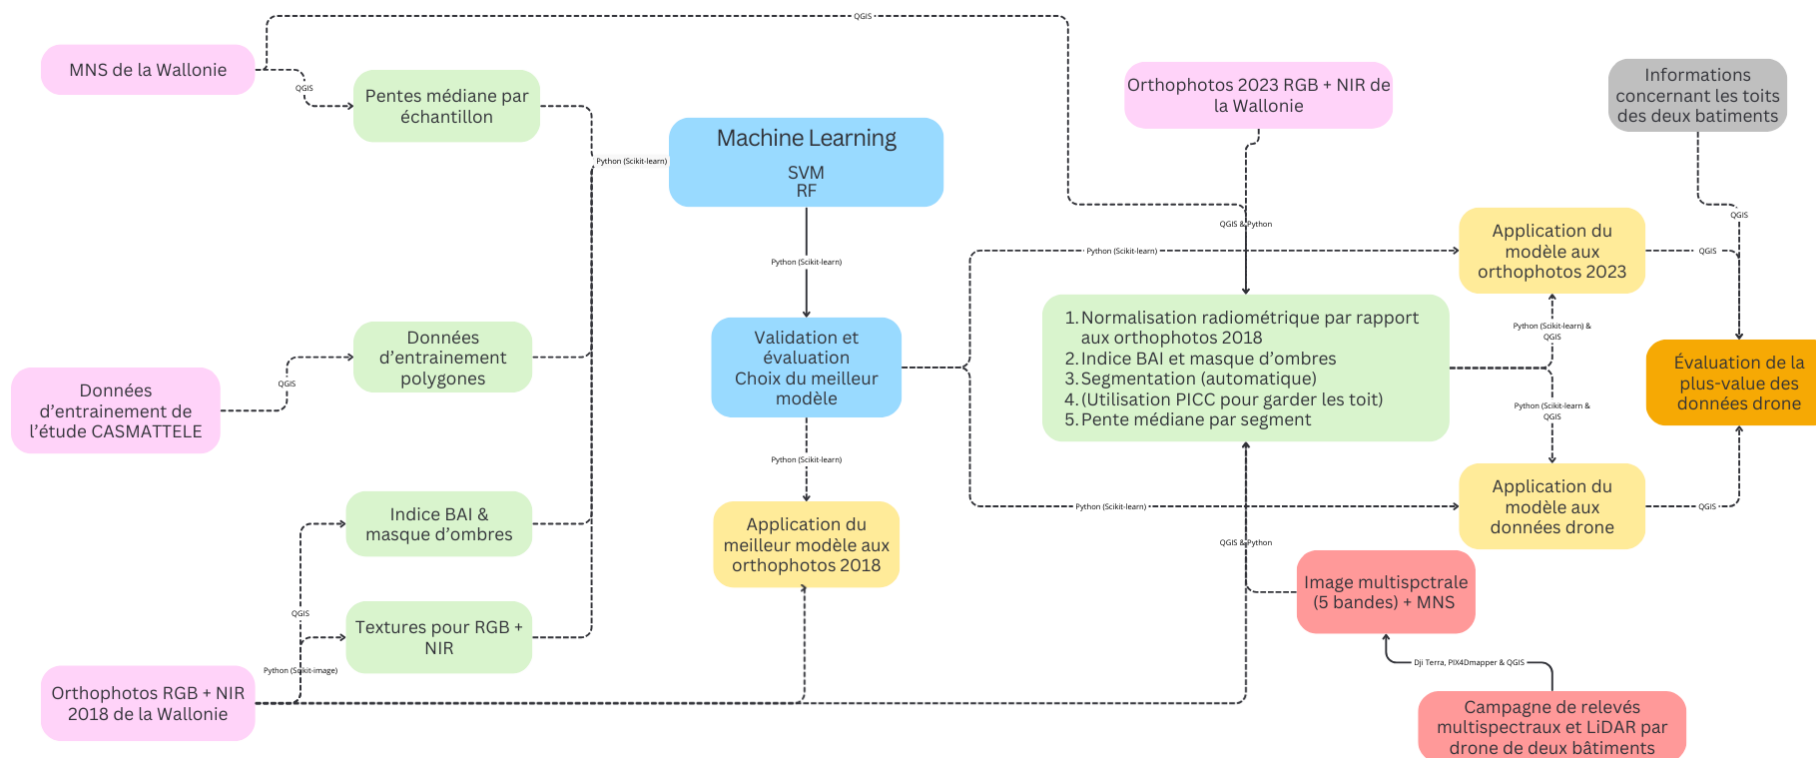


FIGURE 9 – Organigramme de la méthodologie employée lors de ce travail.

4.1 Construction du modèle de classification

4.1.1 Données utilisées

4.1.1.1 Données d'entraînement

4.1.1.1.1 Bibliothèques spectrales

Plusieurs bibliothèques hyperspectrales de matériaux de construction existent dans la littérature. Malheureusement, il n'existe pas dans la littérature de travaux qui ont tenté d'utiliser ces bibliothèques hyperspectrales pour faire de la classification sur base de données multispectrales. L'option d'utiliser des bibliothèques hyperspectrales a donc été écartée dans le cadre de ce travail.

4.1.1.1.2 Jeu de données d'entraînement du projet CASMATTELE

Un jeu de données d'entraînement sur la ville de Liège réalisé lors du projet CASMATTELE de l'ISSEP a été fourni par Coraline Wyard de l'ISSEP. Ce jeu de données consiste en un fichier Shapefile contenant 2560 points qui représentent des toitures dont le matériau a été identifié. Le Système de Coordonnées de Référence (SCR) est le Lambert belge 72 (L72) (EPSG : 31370). Treize classes ont été identifiées, il s'agit des mêmes classes utilisées lors du projet CASMETTELE. Le nombre d'échantillons par classe est présenté au Tableau 1.

TABLEAU 1 – Répartition des types de toitures et du nombre d'échantillons.

Code	Type toiture	Nombre d'échantillons
0	Panneaux solaires	181
1	Tuiles brunes	180
2	Tuiles oranges	171
3	Tuiles noires	229
4	Membranes noires	473
5	Membranes blanches	159
6	Ardoises en CA	172
7	Ardoises sans CA	161
8	Tôles ondulées en CA	159
9	Graviers	195
10	Végétation	155
11	Fenêtres de toit	163
12	Métaux	162

Malheureusement, ces points sont parfois légèrement décalés par rapport aux orthophotos, qui ne sont pas parfaitement orthorectifiées. Il arrivait alors parfois qu'un point concernant un toit se retrouve au final au dessus d'un autre composé d'un matériau différent. Une option aurait été de recaler les orthophotos par rapport aux points comme l'on fait Wyard, Beaumont, Hallot & ISSeP (2023) et Wyard et al. (2020). Néanmoins, les orthophotos sont décalés de façon hétérogène par rapport aux points, ce qui complique fortement ce recalage. C'est pourquoi dans le cadre de ce travail, l'intégralité des 2560 points a été transformée manuellement en polygones de façon à détourer exactement l'étendue du toit concerné par le point sur les orthophotos. De plus, les éléments qui se trouvent sur le toit mais qui ne font pas partie du matériau en tant que tel ont été exclus de la délimitation comme illustré à la Figure 10 de façon à garantir les meilleures données d'entraînement possible.




FIGURE 10 – Illustration de la méthodologie utilisée pour le dessin des polygones correspondant aux toitures identifiées par le projet CASMATTELE.

Au final, 2 731 polygones ont été dessinés de cette façon pour une superficie totale de 259 481, 7 m², ce qui représente 4 150 858 pixels. Les superficies par classes et le nombre de pixels correspondant sont présentées au tableau 2.

TABLEAU 2 – Répartition des types de toitures, de la superficie échantillonnée et du nombre de pixels.

Code	Type toiture	Superficie (m ²)	Nombre de pixels
0	Panneaux solaires	15 192.4	242 994
1	Tuiles brunes	6 103.9	97 604
2	Tuiles oranges	6 291.6	100 653
3	Tuiles noires	10 972.0	175 496
4	Membranes noires	47 970.7	767 244
5	Membranes blanches	2 425.0	454 703
6	Ardoises en CA	5 072.4	81 132
7	Ardoises sans CA	14 400.4	230 335
8	Tôles ondulées en CA	23 966.5	383 489
9	Graviers	22 450.3	359 128
10	Végétation	5 475.6	87 694
11	Fenêtres de toit	6 108.3	97 698
12	Métaux	67 052.7	1 072 688

4.1.1.2 Images multispectrales

Les échantillons identifiant les toits correspondent à l'année 2018 (Coraline Wyard, communication personnelle). Pour cette raison, les orthophotos 2018 de la Wallonie ont été utilisées (SPW, 2018). Les orthophotos sont des images rendues disponibles chaque année par le SPW ayant une résolution de 25 cm. Les étapes de production de ces données sont les suivantes : (1) missions aériennes de collecte par un avion volant à environ 3 000 à 4 000 m d'altitude couvrant l'ensemble de la Wallonie, (2) stéréo-préparation et construction des images Vexcel L3, (3) aérotriangulation, (4) orthorectification, (5) corrections radiométriques, (6) mosaïquage et tuilage. Ces orthophotos disposent de quatre bandes spectrales (rouge, vert, bleu et proche infrarouge). Les courbes de sensibilité du capteur utilisé, le Vexcel L3, pour chaque bande sont disponibles à la Figure 11.

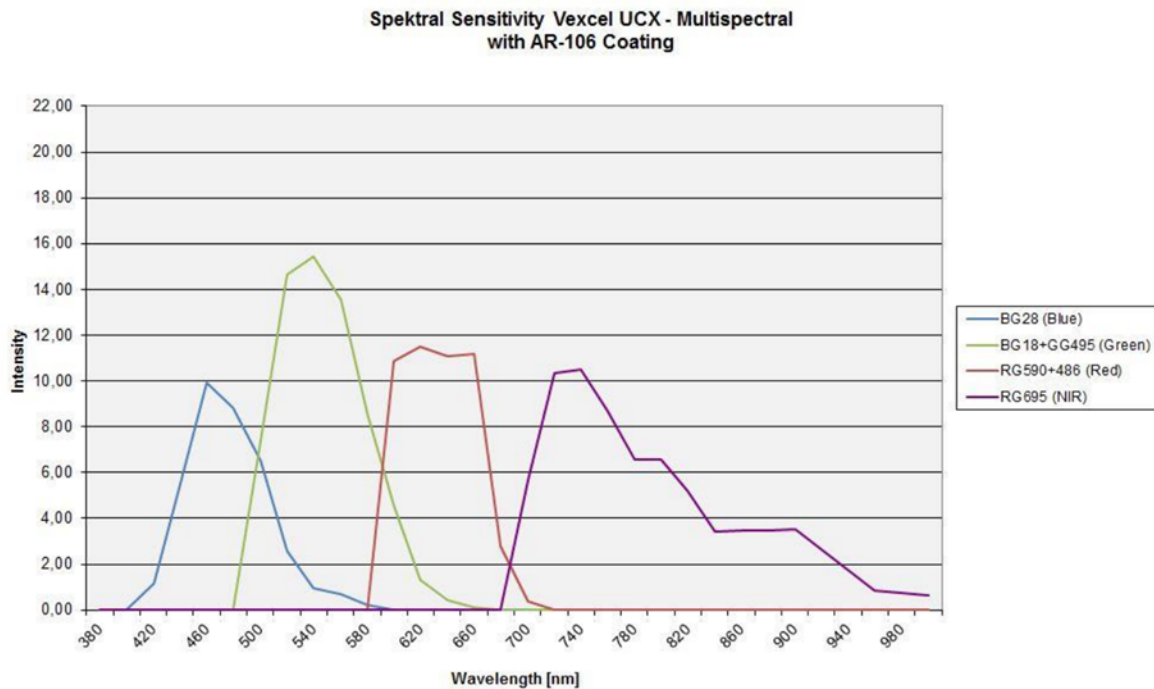


FIGURE 11 – Courbes de sensibilité du capteur Vexcel L3 pour chaque bande (RGB + NIR) (Vexcel Imaging GmbH, 2017).

De façon similaire au jeu d'entraînement, le SCR des orthophotos 2018 est le L72.

4.1.1.3 Modèle Numérique de Surface (MNS) - LiDAR

Pour enrichir les caractéristiques radiométriques des pixels, un MNS a été utilisé afin de calculer la pente des toits (ce calcul sera expliqué à la section 4.1.2.4). Le MNS exploité a été généré à partir de nuages de points issus de la campagne d'acquisition LiDAR de la Région wallonne effectuées en 2021 et 2022. Ces données sont en accès libre et accessibles sur demande via WalOnMap (SPW, 2022). La résolution spatiale du MNS est de 50 cm. La précision planimétrique est de 50 cm tandis que la précision altimétrique est de l'ordre de 12 cm. Notons que le SCR de cette donnée est le Lambert belge 2008 (EPSG : 3812).

4.1.2 Prétraitements et construction des caractéristiques

4.1.2.1 Fusion de classes

Les valeurs moyennes des bandes par classe de matériau ont été calculés et sont illustrées à la Figure 12. On voit que certaines classes se distinguent nettement des autres comme la végétation et les membranes blanches. À l'inverse, certaines classes se ressemblent fortement. Par exemple, la signature spectrale dans les 4 bandes des ardoises

en CA et des tôles ondulées en CA sont quasiment identiques. Il en va de même pour les tuiles brunes et les tuiles noires. Pour cette raison, et également suite aux premiers essais de classifications réalisés, ces deux paires de matériau ont été chacune fusionnées. Cette fusion a été réalisé car cela ne change pas la plus-value de la détection en terme d'économie circulaire des matériaux : une tuile reste une tuile et un matériau contenant de l'amiante, reste un matériau dangereux qu'il faut traiter de la même manière. À l'inverse, les fenêtres de toits et les métaux se ressemblent également assez fort mais ces classes n'ont pas été fusionnées car la distinction entre ces deux matériaux reste importante.

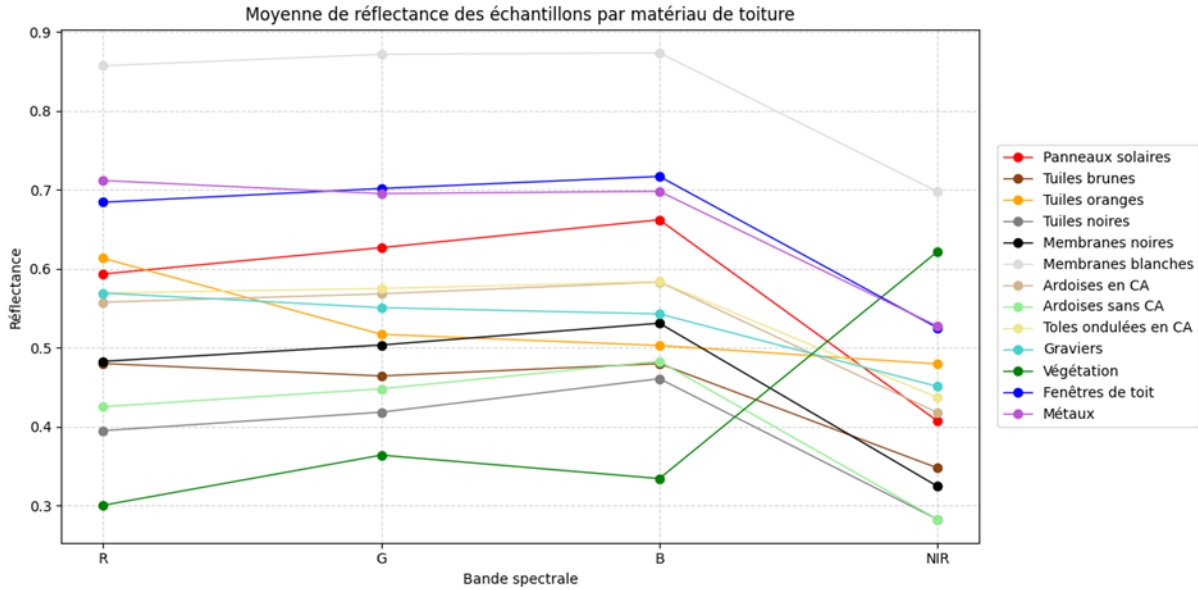


FIGURE 12 – Moyenne de réflectance des échantillons par matériau de toiture.

4.1.2.2 Zones ombragées

Les zones ombragées peuvent perturber les algorithmes de classification. Un masque des ombres a donc été calculé (voir Figure 13). Pour cela, de façon similaire à Wyard et al. (2020), l'indice BAI a été utilisé. Pour rappel, cet indice se calcule comme suit :

$$BAI = \frac{1}{(0.1 - RED)^2 + (0.06 - NIR)^2}$$

Le seuil pour considérer une zone comme ombragée a été fixé à $1,61 \times 10^{-9}$ (Les zones avec un BAI plus grand que ce seuil sont considérées comme des ombragées). Dans un premier temps, l'idée de masquer complètement les zones ombragées a été envisagée. Les pixels ombragés auraient alors été exclus du processus d'apprentissage et de prédiction. Cependant, cette approche pose un problème majeur : elle ne permet pas la classification par le modèle d'images contenant des ombres. Afin de conserver cette capacité à prédire sur des scènes partiellement ombragées, une autre solution a été retenue : l'information binaire indiquant la présence ou non d'ombre a été ajoutée comme caractéristique permettant

ainsi au modèle d'intégrer cette nuance dans son processus de décision.

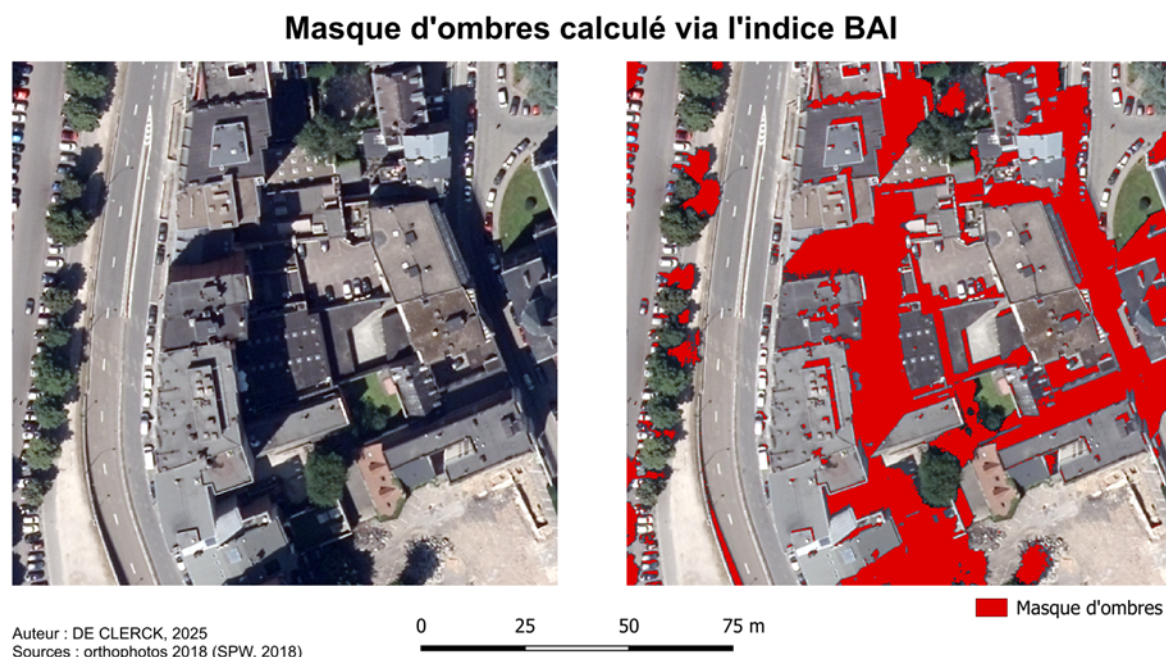


FIGURE 13 – Illustration du masque d'ombre calculé pour le travail via l'indice BAI.

4.1.2.3 Calcul des textures

Dans le but de caractériser finement les propriétés spatiales des surfaces observées, des descripteurs texturaux ont été extraits à partir des bandes spectrales du raster multispectral. Le calcul des textures repose sur la matrice de cooccurrence des niveaux de gris (GLCM, pour Gray Level Co-occurrence Matrix), une méthode couramment utilisée pour quantifier la structure spatiale locale d'une image (Haralick et al., 1973). Elle permet de décrire comment les intensités de pixels varient les unes par rapport aux autres dans un voisinage donné. Concrètement, pour chaque pixel appartenant à une zone d'entraînement (définie à partir d'un polygone vectoriel), une petite fenêtre carrée centrée sur ce pixel est extraite pour chaque bande spectrale considérée.

Ce calcul de textures a été réalisé sur les quatre composantes visibles et proche infrarouge, c'est-à-dire RGB + NIR. Chaque fenêtre locale, centrée sur le pixel cible, est d'abord quantifiée sur une échelle discrète de 64 niveaux de gris (quantification sur 6 bits). Cette réduction d'échelle vise à limiter la complexité computationnelle tout en préservant les variations locales significatives dans l'image. La taille de la fenêtre a été fixée à 3×3 pixels, ce qui correspond à une surface de $75 \text{ cm} \times 75 \text{ cm}$ étant donné la résolution spatiale de 25 cm du raster. Cette taille permet de capturer des structures texturales locales tout en conservant une bonne précision spatiale.

Sur chaque fenêtre ainsi normalisée, on calcule une matrice de cooccurrence des niveaux

de gris (GLCM). Cette matrice est une table à double entrée où chaque entrée $P(i,j)$ représente la fréquence (ou probabilité normalisée) avec laquelle un pixel de niveau de gris i est adjacent (selon une direction et une distance données) à un pixel de niveau j (voir Figure 14). Dans notre cas, on considère un décalage de 1 pixel en direction horizontale (angle = 0°), ce qui revient à comparer chaque pixel à son voisin immédiat à droite.




FIGURE 14 – Illustration du calcul d'une matrice de cooccurrence des niveaux de gris (auteur inconnu).

La mesure de contraste est ensuite extraite à partir de cette GLCM. Il est calculé comme suit :

$$\text{contraste} = \sum_{i,j=0}^{\text{niveaux}-1} P_{i,j}(i-j)^2$$

Où $P_{i,j}$ représente la probabilité normalisée d'observer une paire de valeurs de gris i et j à une distance et direction données (Scikit-image, 2025).

Cette formule accorde un poids plus élevé aux paires de pixels ayant de grandes différences de niveaux de gris (ij élevé), reflétant ainsi l'intensité des variations tonales dans la fenêtre. Les éléments situés sur la diagonale principale de la GLCM ($i=j$) correspondent à des pixels similaires (aucune différence de ton), ce qui traduit une texture homogène avec peu ou pas de contraste. À l'inverse, les valeurs situées loin de la diagonale révèlent des paires de pixels très différents, caractéristiques de textures hétérogènes. Plus la GLCM contient de valeurs éloignées de la diagonale, plus le contraste mesuré sera élevé (Hall-Beyer, 2017). Ces calculs ont été réalisés grâce à la bibliothèque Python Scikit-image développée par Walt et al. (2014).

4.1.2.4 Calcul des pentes médianes par échantillon

Un calcul de pente a été réalisé dans le Système d'Information Géographique (SIG) QGIS. La première étape pour le calcul des pentes a été de reprojeter le MNS vers le SCR

L72. Ensuite, la pente a été calculée à l'aide de la fonction « pente » d'analyse raster. Après cela, la pente médiane a été calculée pour chaque échantillon (polygone) du jeu de données d'entraînement via la fonction « statistiques de zone ». Le choix d'utiliser la pente médiane plutôt que la moyenne est justifié par le fait que les orthophotos (et donc les polygones des échantillons) sont légèrement décalés par rapport au MNS (et donc par rapport au raster de pente). L'utilisation de la médiane permet de réduire l'influence de ce décalage. Par exemple, pour le toit présenté à la Figure 15, la pente médiane est de 3 % mais certains pixels sont superposés avec de fortes pentes dues à la présence de la façade et au décalage précédemment mentionné. Si les pentes avaient été considérées pixel par pixel, cela aurait sans doute perturbé les algorithmes de classification. Par exemple, dans le cas de la Figure 15, certains pixels auraient associé une membrane noire à de fortes pentes, ce qui n'est généralement pas le cas.

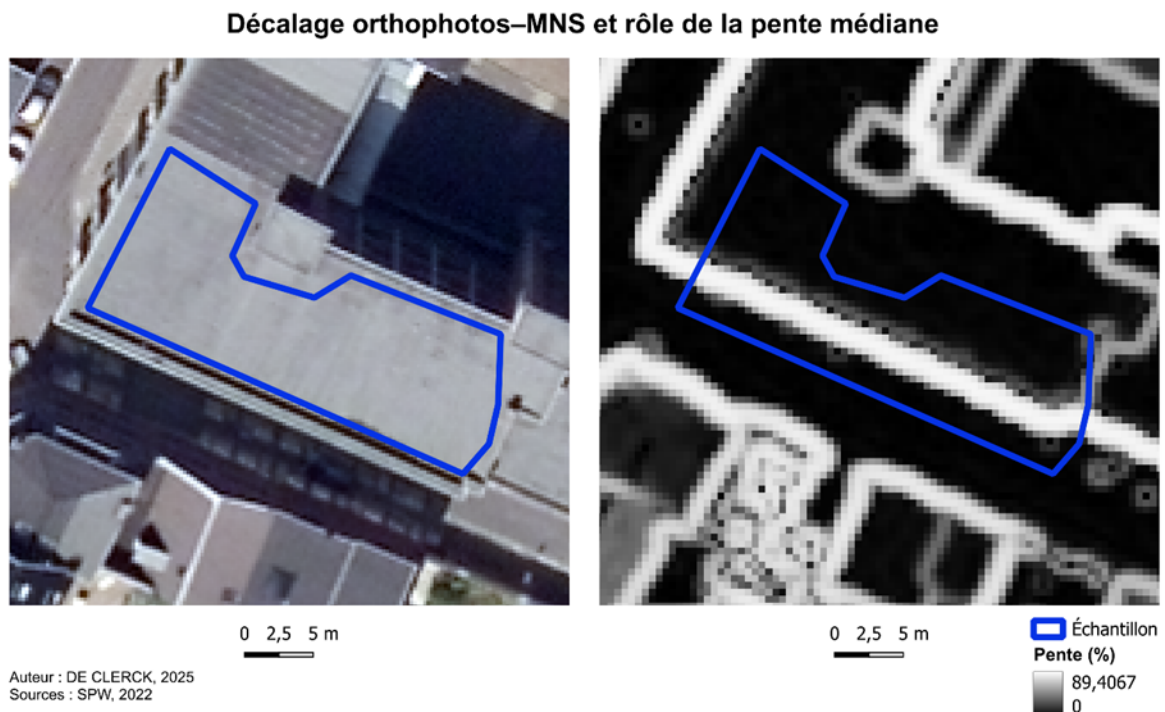


FIGURE 15 – Mise en évidence du décalage entre le MNS et les orthophotos et l'impact sur le calcul des pente des toits.

Finalement, la fonction « Rasteriser » a été utilisée pour convertir les polygones en un raster ayant la même résolution que les orthophotos et qui leur est superposable. Chaque pixel de ce raster contient comme information la pente médiane du toit auquel il appartient. La médiane par classe de matériau de toiture de la médiane de la pente par échantillon a été calculée (voir Figure 16). Il en ressort des tendances claires : les membranes noires, les membranes blanches et les graviers ont des pentes médianes faibles (8 %, 4 % et 4 % respectivement), tandis que les ardoises ou les tuiles ont des pentes bien plus prononcées (> 27 %). Notons que les deux classes tuiles brunes et tuiles noires avaient des pentes similaires avant leur fusion (32 %). En ce qui concerne les ardoises en

CA et les tôles ondulées en CA, leurs pentes différaient avant la fusion : 32 % et 19 % respectivement.




FIGURE 16 – Médiane de la pente médiane par type de toiture.

4.1.3 Algorithmes utilisés

Les algorithmes de ML utilisés ont été implémentés à l'aide de la bibliothèque Python Scikit-learn, développée par Pedregosa et al. (2011).

4.1.3.1 Support Vector Machine (SVM)

Le principe fondamental de l'algorithme Support Vector Machine (SVM) est de séparer les classes. Prenons un cas très simple pour illustrer le concept. Dans la Figure 17, les deux classes sont séparables par une droite. Mais plusieurs droites permettent de séparer les deux classes. Grâce au SVM, en plus de séparer les données, cette droite reste aussi la plus éloignée possible des instances d'entraînement (Géron, 2019).




FIGURE 17 – Illustration du principe fondamental de l'algorithme SVM (Géron, 2019).

L'algorithme fonctionne donc en cherchant un hyperplan dans l'espace des caractéristiques qui sépare les classes avec une marge maximale. L'objectif n'est pas

seulement de réussir à séparer les données, mais de choisir l'hyperplan qui maximise la distance entre les points les plus proches de chaque classe, ces derniers étant appelés vecteurs de support (entourés en rouge dans la Figure 18). Notons que l'ajout de nouvelles instances d'apprentissage en dehors de la bande formée par les pointillés dans la Figure 18 ne modifiera pas la droite de séparation. Cette méthode renforce la robustesse du modèle en minimisant considérablement les risques de surapprentissage. En général, les SVM sont particulièrement pertinents pour des jeux de données complexes de taille petite à moyenne (Géron, 2019).

Cependant, il est important de souligner que les SVM sont sensibles à l'échelle des variables. Par exemple, si une caractéristique a une plage de valeurs beaucoup plus grande qu'une autre, elle dominera dans le calcul de la marge, ce qui peut fausser la position de l'hyperplan. Dans ce cas, l'algorithme cherchera à maximiser la marge selon la direction de la variable dominante, ce qui peut conduire à une séparation non-optimale (voir Figure 18). Pour éviter ce biais, il est courant de normaliser ou de standardiser les données avant l'entraînement. En utilisant par exemple le `StandardScaler` de Scikit-learn, on s'assure que toutes les caractéristiques ont une échelle comparable. Cela permet d'obtenir une frontière de décision plus équilibrée et représentative de la structure réelle des données (Géron, 2019).




FIGURE 18 – Illustration de la nécessité de normaliser les variables pour l'algorithme SVM (Géron, 2019).

De plus, si l'on impose strictement que toutes les instances d'apprentissage se trouvent à l'extérieur de la marge et du bon côté, on parle alors de classification à marge rigide. Ce type d'approche ne fonctionne que si les données sont parfaitement séparables de manière linéaire. De plus, elle est très sensible aux valeurs aberrantes : l'ajout d'un seul point anormal peut rendre la séparation impossible ou bien fortement décaler l'hyperplan, ce qui compromet la généralisation du modèle (voir Figure 19).




FIGURE 19 – Effet d’une donnée aberrante sur l’algorithme SVM (Géron, 2019).

Pour pallier ces limites, on privilégie en pratique l’approche à marge souple (soft margin), qui permet certaines violations de la marge afin de trouver un compromis entre une séparation optimale et la tolérance aux erreurs. Cette flexibilité est contrôlée par l’hyperparamètre C . Une valeur de C faible autorise davantage de violations (et donc une marge plus large), tandis qu’une valeur élevée cherche à minimiser ces violations, au prix d’un hyperplan plus contraint (voir Figure 20). Cette capacité à ajuster le degré de tolérance permet aux SVM de mieux généraliser, en particulier dans des contextes où les données ne sont pas parfaitement séparables (Géron, 2019). Par défaut, le paramètre C est fixé à 1 (Scikit-image, 2025).

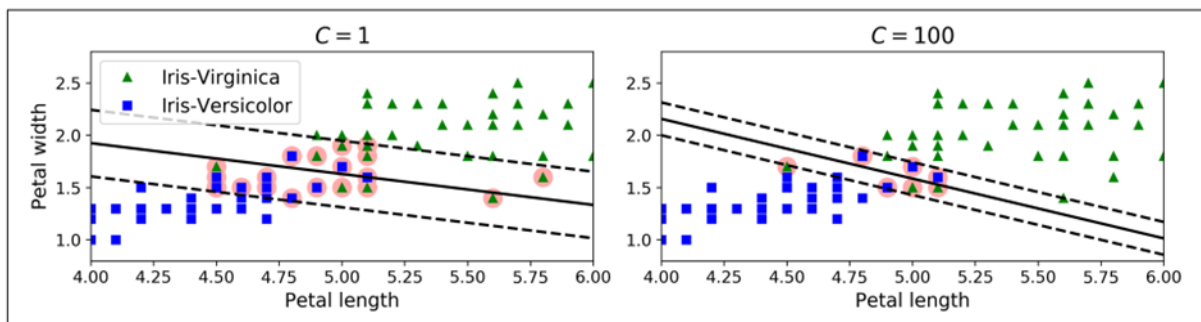


FIGURE 20 – Flexibilité dans la définition des marges via l’hyperparamètre C (Géron, 2019).

Si les données sont non séparables linéairement dans leur espace d’origine, le SVM peut recourir à une transformation via un noyau (kernel), le plus connu et utilisé étant le « Radial Basis Function » (RBF). Ce type de SVM sert à projeter les données dans un espace de dimension supérieure où la séparation linéaire devient possible. Cette approche est appelée le « kernel trick », et elle permet aux SVM de traiter efficacement des problèmes non linéaires sans avoir à construire explicitement les nouvelles dimensions. Deux paramètres sont alors importants à prendre en compte dans un SVM non linéaire : le paramètre C contrôlant le compromis entre la maximisation de la marge et la tolérance aux erreurs qui a déjà été abordé et le paramètre γ qui joue également un rôle important en déterminant l’influence de chaque point d’entraînement. Une valeur faible de γ produit une frontière de décision plus lisse, tandis qu’une valeur élevée rend le modèle plus sensible aux variations locales (voir Figure 21). Le paramètre γ agit donc comme un paramètre

de régularisation qu'il faut réduire si le modèle fait du surapprentissage et à l'inverse diminuer si le modèle fait du sous-apprentissage (Géron, 2019).

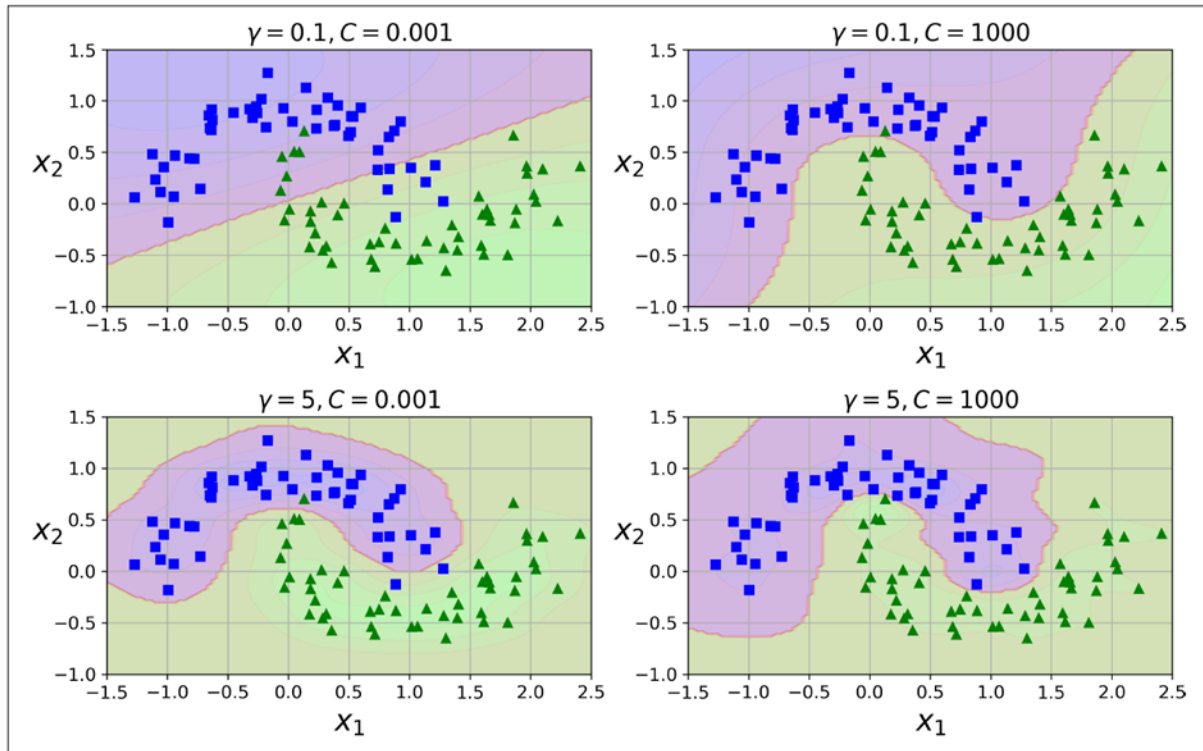


FIGURE 21 – Effets des paramètres C et γ sur l'algorithme SVM (Géron, 2019).

Lorsque le problème de classification implique plus de deux classes, l'algorithme SVM, initialement conçu pour des tâches binaires, peut être étendu à un cadre multiclasse grâce à deux stratégies principales : " one-vs-rest " (OvR) et " one-vs-one " (OvO). La stratégie OvR consiste à entraîner un classifieur pour chaque classe, en distinguant les échantillons de cette classe contre tous les autres. À la prédiction, la classe dont le classifieur présente la plus forte confiance est retenue. Cette approche est la plus souvent utilisée. Elle a l'avantage d'être rapide (peu coûteuse en termes de modèles à entraîner) et interprétable. À l'inverse, la stratégie OvO entraîne un classifieur pour chaque paire de classes possibles, ce qui peut entraîner un grand nombre de modèles :

$$\text{Nombre de modèles} = \frac{n_{\text{classes}} (n_{\text{classes}} - 1)}{2}$$

Par exemple, pour 11 classes, c'est 55 classifieurs qu'il faut entraîner. Chaque classifieur vote pour une classe, et celle qui obtient le plus de votes est la classe prédite. Cette méthode, bien que plus coûteuse, est souvent plus performante car chaque modèle est entraîné sur un sous-ensemble plus simple du problème global (Scikit-learn, 2025).

Concernant la complexité de calcul d'un SVM binaire, il existe deux implémentations principales dans Scikit-learn. La classe LinearSVC, basée sur la bibliothèque liblinear, est

optimisée pour les cas linéaires et ne supporte pas les noyaux (kernel trick). Elle a une complexité d'apprentissage approximativement linéaire en $O(m \times n)$, avec m le nombre d'échantillons et n le nombre de caractéristiques, ce qui la rend adaptée à de grands jeux de données. En revanche, la classe SVC, basée sur libsvm, prend en charge les noyaux non linéaires comme le RBF, mais au prix d'une complexité entre $O(m^2 \times n)$ et $O(m^3 \times n)$. Cela signifie qu'elle devient rapidement coûteuse en temps de calcul dès que m devient grand (au-delà de quelques milliers d'échantillons). Ce qui rend son utilisation impraticable dans notre cas.

Dans le cadre de ce travail, l'implémentation des SVM a été réalisée à l'aide de la classe LinearSVC de la bibliothèque Scikit-learn (Pedregosa et al., 2011), particulièrement adaptée au traitement de grands jeux de données avec un nombre d'échantillons largement supérieur au nombre de variables. Cette bibliothèque utilise par défaut la stratégie OvR. Afin d'assurer la convergence de l'algorithme sur ce volume de données, le paramètre `max_iter` a été fixé à 5000, ce qui augmente le nombre maximal d'itérations autorisées lors de l'optimisation. De plus, l'option `dual=False` a été retenue, ce qui est recommandé lorsque le nombre d'échantillons excède celui des caractéristiques (Géron, 2019; Scikit-learn, 2025). Avant l'entraînement, l'ensemble des variables a été standardisé grâce au StandardScaler pour garantir des échelles comparables et optimiser le positionnement de la frontière de décision comme recommandé par Géron (2019).

4.1.3.2 Random Forest (RF)

Avant d'expliquer la théorie du RF, il convient de voir ce qu'est un « Decision Tree » ou arbre de décision en français. Un arbre de décision est un modèle prédictif structuré comme un arbre binaire, où chaque nœud interne pose une question (du type la variable X est-elle supérieure à une certaine valeur ?), divisant ainsi l'espace de données en sous-groupes de plus en plus homogènes. Dans ce cadre, chaque nœud d'un arbre représente une règle de décision sur une variable donnée. Le nœud racine contient toutes les données et initie la première division. Les nœuds internes effectuent des séparations successives de l'espace de caractéristiques. Le processus se poursuit jusqu'à atteindre un nœud terminal (feuille), qui correspond à la prédiction d'une classe. L'apprentissage d'un arbre consiste à choisir à chaque étape la variable et le seuil qui permettent de mieux séparer les données. L'arbre de décision est simple à comprendre et à interpréter, mais il est sensible aux variations dans les données, ce qui peut entraîner un surapprentissage (Géron, 2019).

L'algorithme RF, ou forêt aléatoire en français, appartient à la famille des méthodes d'ensemble, c'est-à-dire des modèles qui combinent plusieurs prédicteurs pour améliorer les performances globales de la prédiction du modèle (voir Figure 22).




FIGURE 22 – Illustration du fonctionnement d’une méthode d’ensemble. Les prédictions de plusieurs modèles sont combinées pour améliorer les performances globales du modèle (Géron, 2019).

Il s’agit plus précisément d’un ensemble d’arbres de décision entraînés de manière indépendante. Le concept du RF est donc d’utiliser cet ensemble d’arbres de décision et d’agréger les prédictions par vote majoritaire (voir Figure 23).




FIGURE 23 – Illustration du principe de fonctionnement de l’algorithme RF. (Dimitriadis et al., 2018).

Pour construire un RF, l’entraînement de chacun des arbres de décision se fait sur une partie aléatoire du jeu de données. Pour cela on génère plusieurs sous-échantillons aléatoires du jeu de données d’origine. Un arbre de décision est entraîné sur chacun de ces sous-échantillons (voir Figure 24). On parle de « Bagging » version courte de « Bootstrap Aggregating » lorsqu’une instance peut être sélectionnée plusieurs fois dans le même sous-échantillon et de « Pasting » lorsque cette possibilité n’existe pas. Les algorithmes RF utilisent généralement la technique du Bagging.




FIGURE 24 – Illustration de l’entraînement de chaque arbre de décision sur une partie aléatoire du jeu de données global (Géron, 2019).

Pour accroître encore la diversité entre les arbres, une sélection aléatoire de variables à chaque nœud est appliquée : plutôt que de considérer toutes les caractéristiques possibles pour effectuer une coupure, chaque nœud ne voit qu’un sous-ensemble aléatoire de variables lors de la recherche de la meilleure séparation. Cette double forme d’aléa (au niveau des données et des variables) contribue à réduire la variance du modèle final sans trop augmenter son biais, ce qui améliore la robustesse et limite fortement le risque de surapprentissage, un problème courant avec les arbres de décision isolés (voir Figure 25). Dans un RF, les nœuds sont propres à chaque arbre de décision, car la structure dépend à la fois des échantillons et des variables sélectionnées aléatoirement (Géron, 2019).




FIGURE 25 – Illustration de la robustesse accrue de RF par rapport à un arbre de décision isolé (Géron, 2019).

L’algorithme RF bénéficie de plusieurs avantages importants. D’abord, il est capable de capturer des relations complexes non linéaires sans nécessiter de transformation préalable des variables. Un autre atout majeur est la capacité du modèle à fournir une estimation de l’importance des variables, basée sur leur fréquence d’utilisation et la réduction d’impureté qu’elles entraînent dans les différents arbres. De plus, comme chaque arbre est indépendant, l’algorithme peut être parallélisé facilement, ce qui en fait une méthode efficace même sur des jeux de données volumineux (Géron, 2019).

Dans l'implémentation de Scikit-learn, plusieurs paramètres peuvent être ajustés pour affiner les performances. Le plus important est « `n_estimators` » qui définit le nombre d'arbres dans la forêt : augmenter cette valeur tend à améliorer la robustesse du modèle, mais augmente aussi le temps de calcul. Le paramètre « `max_depth` » contrôle la profondeur maximale des arbres, influençant directement la capacité d'apprentissage : une faible profondeur peut limiter le surapprentissage, tandis qu'une profondeur illimitée laisse chaque arbre apprendre jusqu'à la pureté maximale. Ensuite, « `max_features` » détermine combien de variables sont testées à chaque division d'un nœud : une faible valeur augmente la diversité entre les arbres (et donc réduit la corrélation), tandis qu'une valeur élevée permet à chaque arbre d'avoir accès à plus d'informations mais augmente le risque de surajustement. Par défaut, la valeur est $\sqrt{n_features}$.

Pour ce travail, le nombre d'arbres de décision (`n_estimator`) a été fixé à 150 car l'analyse de l'augmentation de performance en fonction du nombre d'arbres (pour RGB + NIR + ombres + pentes) a montré que l'ajout d'arbres de décision supplémentaires n'apportait plus que de très faibles améliorations dans la classification, tout en augmentant le temps de calcul (voir Figure 26). La profondeur maximale de chaque arbre a été fixée à 100, comme l'ont fait (Ilehag et al., 2020).

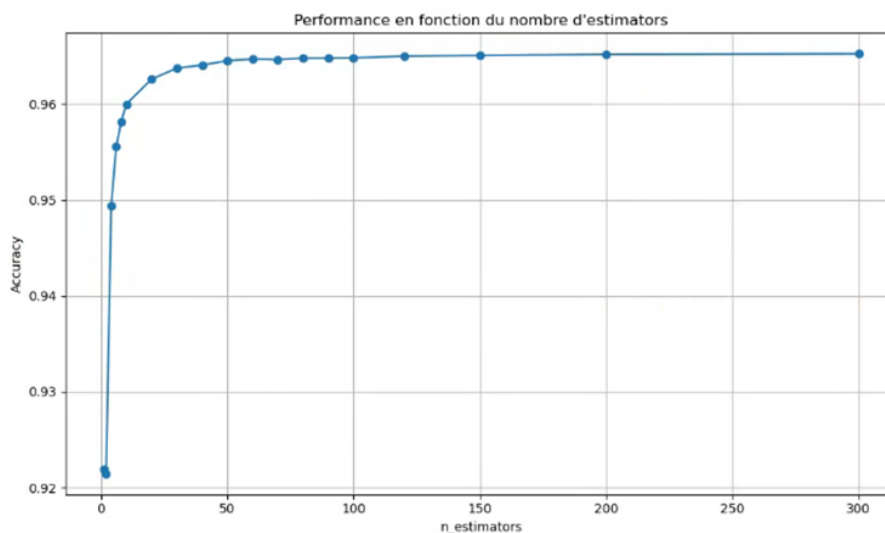


FIGURE 26 – Évolution de la précision du modèle en fonction du nombre d'arbres de décision (`n_estimators`) pour le meilleur modèle (RGB + NIR + ombres + pentes).

En ce qui concerne la complexité algorithmique, les prédictions avec un arbre de décision sont très rapides : il suffit de traverser l'arbre du nœud racine jusqu'à une feuille, ce qui nécessite généralement un nombre d'opérations proportionnel à $\log(m)$, où m est le nombre d'échantillons. Chaque nœud ne teste qu'une seule caractéristique, ce qui rend la prédiction très efficace, même sur de grands jeux de données. En revanche, l'entraînement d'un arbre est plus coûteux car il consiste à rechercher les meilleures divisions à chaque nœud en testant toutes (ou une partie, selon `max_features`) les variables sur l'ensemble des données. Cela donne une complexité d'environ $O(n \times m \log m)$, avec n le nombre de

caractéristiques.

4.1.4 Validation et évaluation des classifications

Pour évaluer les performances des modèles de classification, la méthode de validation retenue consiste à diviser le jeu de données initial en deux sous-ensembles : 70 % des données sont utilisées pour l'entraînement, et les 30 % restants servent à tester le modèle sur des données jamais vues. Cette approche, couramment utilisée, permet d'obtenir une première estimation fiable des performances du modèle sur un échantillon indépendant (Géron, 2019). Dans le cadre de ce travail, cette méthode a été systématiquement appliquée à l'ensemble des modèles testés. Étant donné la taille importante du jeu de données, cette division est suffisante pour garantir une bonne représentativité des échantillons d'apprentissage et de test, tout en limitant les temps de calcul. Pour cela, la fonction `train_test_split` de la bibliothèque Scikit-learn a été utilisée.

En complément, une validation croisée (cross-validation) a été mise en œuvre, mais uniquement sur le meilleur modèle identifié. Cette technique consiste à diviser le jeu d'entraînement en plusieurs sous-groupes (ou « folds »), à entraîner le modèle sur un de ces groupes, puis à le tester sur les groupes restants, et à répéter cette opération pour chaque sous-groupe. Elle permet d'évaluer la robustesse et la stabilité du modèle en s'assurant que les performances ne sont pas trop dépendantes d'une configuration particulière des données. La fonction `cross_val_score` de Scikit-learn a été utilisée pour réaliser la validation croisée. Il convient également de souligner que la fonction `StratifiedKFold` de Scikit-learn a été utilisée pour réaliser la validation croisée. Cette fonction garantit que chaque sous-groupe du jeu de données conserve la même proportion de classes que dans le jeu de données initial, ce qui est particulièrement important dans notre cas où les classes sont déséquilibrées. Cette stratégie permet d'obtenir des évaluations plus fiables et représentatives de la performance du modèle (Géron, 2019).

L'« Accuracy » est une première mesure simple de la performance d'un modèle de classification. Elle correspond au rapport entre le nombre de prédictions correctes et le nombre total d'échantillons. Bien qu'elle donne une vue d'ensemble globale, elle peut être trompeuse lorsque les classes sont déséquilibrées.

Pour une analyse plus fine, on utilise la matrice de confusion, qui permet de comparer les classes réelles et les classes prédites. Dans le cas d'une classe, elle distingue quatre types de résultats : les « True Positives » (TP) : correctement identifiés comme appartenant à la classe, les « False Positives » (FP), incorrectement classés comme faisant partie de la classe, les « False Negatives » (FN) qui auraient dû être classés dans la classe mais ne l'ont pas été et les « True Negatives » (TN) correctement étiquetés comme ne faisant pas partie de la classe. À partir de cette matrice, on peut calculer d'autres indices :

La « Precision » qui évalue la proportion de prédictions correctes parmi celles faites pour une classe :

$$\text{Precision} = \frac{TP}{TP + FP}$$

Le « Recall » qui évalue la proportion de vrais éléments d'une classe correctement retrouvés par le modèle :

$$\text{Recall} = \frac{TP}{TP + FN}$$

Et enfin, le score F1 qui est la moyenne harmonique entre la précision et le rappel :

$$F_1 = \frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}$$

Cette moyenne met davantage l'accent sur les faibles valeurs, ce qui signifie qu'un bon score F1 n'est obtenu que si la précision et le rappel sont toutes deux élevées.

Dans le cas de problèmes de classification multiclasse, ces métriques peuvent être agrégées de deux façons :

1. La moyenne macro calcule la moyenne non pondérée des indices de chaque classe, en leur attribuant un poids égal.
2. La moyenne pondérée (weighted average) prend en compte la fréquence de chaque classe dans le jeu de données, ce qui permet une évaluation plus représentative des performances globales du modèle lorsque les classes sont déséquilibrées.

Enfin, la matrice de confusion multiclasse offre une visualisation synthétique des performances du modèle sur l'ensemble des classes. Elle indique, pour chaque classe réelle (en ordonnée) la répartition des prédictions (en abscisse) ce qui permet d'identifier les confusions les plus fréquentes et les classes les mieux ou moins bien reconnues.

Concernant uniquement le classifieur RF, l'une de ses grandes qualités réside dans sa capacité à estimer facilement l'importance relative des variables utilisées dans le modèle. Cette estimation repose sur l'impureté des nœuds de décision, mesurée par le score de Gini. Le score de Gini d'un nœud G_i quantifie l'hétérogénéité des classes parmi les échantillons qui y parviennent. Il est minimal (0) si tous les échantillons appartiennent à une même classe (nœud pur) et tend vers 1 lorsque la répartition est parfaitement équilibrée. Cet indice est défini par la formule suivante (Géron, 2019) :

$$G_i = 1 - \sum_{k=1}^n (p_{i,k})^2$$

où :

- $p_{i,k}$ est la proportion d'échantillons de classe k dans le nœud i .
- n est le nombre total de classes.

Dans l'implémentation de Scikit-Learn, l'importance d'une variable est déterminée par la réduction moyenne du score de Gini qu'elle provoque lorsqu'elle est utilisée pour une division. Cette réduction est pondérée par le nombre d'échantillons d'apprentissage concernés par chaque nœud, et est ensuite moyennée sur l'ensemble des arbres de la forêt. Enfin, les importances sont normalisées pour que leur somme soit égale à 1. Ces scores sont accessibles via la fonction « `feature_importances_` » (Géron, 2019).

4.2 Application du modèle à la ville de Liège

Une fois le meilleur modèle identifié, celui-ci a été enregistré pour pouvoir être appliqué et faire des prédictions des matériaux de toitures sur base d'images multispectrales et de MNS. Les bandes RGB + NIR sont les mêmes que celles qui ont servi pour l'entraînement du modèle (orthophotos 2018). Le masque d'ombres est également le même, calculé sur base de l'indice BAI.

Pour le calcul de pente médiane, il a d'abord fallu segmenter l'image en différents points. Pour cela, deux options ont été testées :

1. La première façon de faire a été de réaliser une segmentation automatique de l'orthophoto via la fonction « `LargeScaleMeanShift` » dans QGIS. Les principaux paramètres de cette fonction permettent de contrôler la taille des segments et le niveau de lissage. Le paramètre « `Spatial Radius` » définit la taille du voisinage autour de chaque pixel, une valeur plus élevée produit des segments plus homogènes mais plus grands. Le « `Range Radius` » fixe le seuil de similarité radiométrique : des valeurs faibles préservent mieux les contrastes et les bords, tandis que des valeurs élevées favorisent un lissage plus uniforme. Enfin, le paramètre « `Minimum Segment Size` » impose une taille minimale aux segments, fusionnant automatiquement les plus petits avec des voisins aux caractéristiques spectrales proches pour éviter la création de zones trop fragmentées. Ces paramètres ont été ajustés de façon à obtenir une segmentation qui correspond le plus possible aux différents matériaux composant les toits. Une fois cette segmentation automatique réalisée, le PICC a été utilisé pour essayer de ne garder que les segments faisant partie des toits. Pour cela, un buffer négatif du PICC (-2 m) a été réalisé ainsi qu'une sélection par localisation (les segments qui intersecte le buffer sont conservés).

2. La seconde option a consisté à réaliser la segmentation manuellement, afin d'éviter les problèmes spécifiques liés à la segmentation automatique, dont l'analyse détaillée sortirait du cadre de ce travail.

Une fois la segmentation réalisée (automatique ou manuelle), la pente médiane par segment a été calculée sur base du MNS de la Wallonie et cette pente médiane a ensuite été associée à chaque pixel du segment comme cela a été fait lors de l'entraînement du modèle.

Ensuite, le modèle est appliqué au raster contenant les 6 caractéristiques d'entrée pour la zone choisie (RGN + NIR + ombres + pentes). Finalement, la classe majoritairement prédite par segment est conservée pour l'affichage de la prédiction finale.

4.3 Application du modèle à des données plus fines

4.3.1 Acquisition des données drone

Dans le but de regarder l'apport de données multispectrales et LiDAR avec une résolution spatiale plus fine, une campagne d'acquisition de données a été réalisée. L'acquisition a eu lieu le 15 mai 2025 entre 15h et 16h. Le drone utilisé est le « Dji Matrice 300 Series ». Deux vols ont été faits : un premier avec le capteur LiDAR « Dji Zenmuse L1 » et le second avec le capteur multispectral « RedEdge-P » de la marque MicaSense (voir Figure 27). Le capteur multispectral utilisé comporte 5 bandes (voir Tableau 3). Aucune couverture nuageuse n'a perturbé l'acquisition des données multispectrales.

TABLEAU 3 – Caractéristiques spectrales des bandes du capteur multispectral utilisé (RedEdge-P - MicaSense).

Bande	Longueur d'onde centrale (μm)	Largeur de bande (μm)
Rouge	0.668	0.014
Vert	0.560	0.027
Bleu	0.475	0.032
NIR	0.842	0.057
Red Edge	0.717	0.012

L'objectif de cette campagne d'acquisition était d'avoir des données plus fines sur des toitures. La zone d'étude choisie se trouve dans le campus vétérinaire de l'ULiège. Ce choix a été fait en raison de la proximité de la zone avec le département de géomatique, de la facilité d'obtenir les autorisations de vol et des informations concernant les matériaux composant les toitures, puisqu'il s'agit de bâtiments de l'université (voir Figure 28).



FIGURE 27 – Photos du drone « Dji Matrice 300 Series » utilisé avec le capteur LiDAR « Dji Zenmuse L1 » (à gauche) et le capteur multispectral « RedEdge-P » (à droite).




FIGURE 28 – Matériaux présents sur les toitures des deux batiments étudiés (Arnaud Thienpont, communication personnelle).

4.3.2 Préparation des données drone

Le traitement des données LiDAR a été fait par Jordan Bates dans le logiciel Dji Terra. Le capteur LiDAR a l'avantage d'avoir un récepteur GNSS-RTK intégré offrant une grande précision au positionnement du nuage de points obtenu. Le SCR des données LiDAR est le WGS84 / UTM Zone 31 N (EPSG : 32631). Un MNS a également été produit sur base de cette acquisition LiDAR (voir Figure 30).

Les données multispectrales ont été traitées personnellement via le logiciel Pix4Dmapper avec l'aide de Jordan Bates. Le problème du capteur multispectral utilisé est que les données ne sont pas géoréférencées de façon très précise. Pour remédier à ce problème, une géoréférenciation a été réalisée. Pour cela, des points de référence remarquables (coins de bâtiments, ...) ont été utilisés pour faire office de points de contrôle. Au total, 12 points de contrôle ont alors été choisis et leurs coordonnées issues de l'acquisition LiDAR ont été extraites via QGIS. Ensuite, chaque point de contrôle a dû être localisé dans un minimum de trois images. Finalement, afin de garantir la fiabilité des mesures radiométriques issues du capteur multispectral RedEdge-P, une procédure de calibration a été réalisée. Le capteur RedEdge-P, conçu par MicaSense, fournit des données brutes, qui nécessitent une conversion en réflectance pour assurer la comparabilité spatiale et temporelle des mesures. Cette calibration radiométrique a été effectuée à l'aide d'une cible de calibration spectrale fournie par le fabricant qui est composée d'une surface blanche dont les propriétés de réflectance sont précisément connues pour chaque bande spectrale (voir Figure 29).



FIGURE 29 – Cible de calibration spectrale utilisée pour calibrer les mesures multispectrales effectuées.

Une série d'images de la cible a été acquise dans les conditions d'éclairage du moment, immédiatement avant le vol. Ces images ont ensuite été utilisées pour calibrer les données acquises (MicaSense, 2024). Une fois cela fait, le logiciel peut générer

l'image multispectrale calibrée qui sera correctement géoréférencée et superposable avec les données LiDAR (voir Figure 30). La résolution spatiale de l'image multispectrale produite est de 4,9 cm tandis que celle du MNS est de 2,5 cm. La carte du nombre de chevauchements d'images, et donc des zones les plus fiables de l'image multispectrale est disponible à l'annexe C.

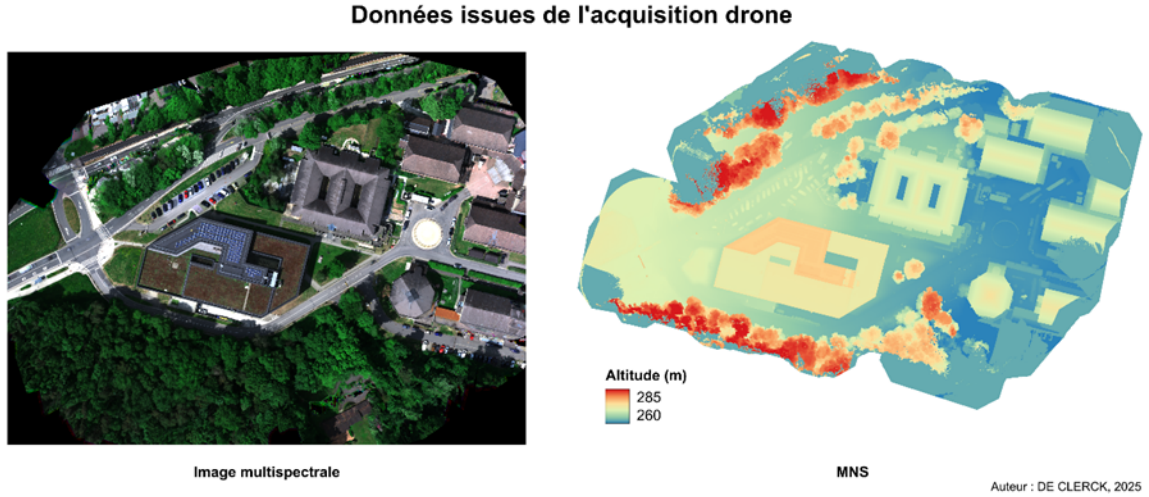


FIGURE 30 – Données issues de l'acquisition drone.

4.3.3 Prétraitements des données drone

4.3.3.1 Normalisation radiométrique

Dans le cadre de l'harmonisation radiométrique entre images acquises à des dates différentes, voire par des capteurs distincts, l'usage d'une relation linéaire est une approche classique, simple et efficace. L'objectif est alors de transformer les valeurs de l'image à corriger (cible) pour les aligner avec celles d'une image de référence.

Cette méthode repose sur l'hypothèse largement validée dans la littérature qu'il existe une relation linéaire stable entre les niveaux de gris (ou de réflectance) des images à normaliser (Moghimi et al., 2024 ; Pudale & Bhosle, 2007 ; Vicente-Serrano et al., 2008 ; D. Yuan & Elvidge, 1996). La formule générale de normalisation radiométrique linéaire est la suivante (D. Yuan & Elvidge, 1996) :

$$X_{\text{cible},k,\text{corrigé}} = a_k \cdot X_{\text{cible},k} + b_k$$

où :

- $X_{\text{cible},k}$ et $X_{\text{cible},k,\text{corrigé}}$ sont les valeurs initiales et corrigées de la cible, respectivement, pour la bande k.

Une de ces méthodes de normalisation utilise la moyenne et l'écart type de chaque bande. Les coefficients de la formule générale sont alors :

$$a_k = \frac{\sigma_{\text{cible},k}}{\sigma_{\text{Ref},k}}, \quad b_k = \mu_{\text{Ref},k} - a_k \mu_{\text{cible},k}$$

où :

- $\mu_{\text{cible},k}$ et $\mu_{\text{Ref},k}$ sont les moyennes des valeurs de la cible et de la référence, respectivement, pour la bande k .
- $\sigma_{\text{cible},k}$ et $\sigma_{\text{Ref},k}$ sont les écarts-types des valeurs de la cible et de la référence, respectivement, pour la bande k .

Cette formule peut se réécrire comme suit :

$$X_{\text{cible},k,\text{corrigé}} = \left(\frac{X_{\text{cible},k} - \mu_{\text{cible},k}}{\sigma_{\text{cible},k}} \right) \cdot \sigma_{\text{Ref},k} + \mu_{\text{Ref},k}$$

La sélection des zones (pixels) à échantillonner constitue une étape clé dans l'estimation des paramètres de régression utilisés pour la normalisation radiométrique. Il est en effet essentiel d'identifier des réflecteurs constants entre différentes acquisitions, en supposant que les variations de réflectance observées chez ces cibles sont principalement dues à des perturbations non liées à la surface (telles que des différences d'illumination ou de capteur). Ces zones, appelées « Pseudo-Invariant Features » (PIFs), correspondent à des zones dont la réflectance reste globalement stable dans le temps. La méthode la plus courante pour les identifier repose sur une sélection visuelle, qui consiste à repérer manuellement des surfaces stables et peu sujettes à variation. Pour être considérées comme fiables, les PIFs doivent présenter peu ou pas de végétation, afin d'éviter les changements saisonniers ou phénologiques, se situer dans des zones relativement planes, pour minimiser les effets d'illumination, et couvrir une large gamme de valeurs de réflectance, allant des zones sombres aux zones très claires pour garantir la robustesse de la transformation linéaire (Vicente-Serrano et al., 2008). Des surfaces telles que le sable, l'asphalte, les toitures homogènes non végétalisées ou les plans d'eau sont fréquemment utilisées comme PIFs en raison de leur stabilité spectrale apparente. Récemment, Moghimi et al. (2024) ont montré qu'il était possible d'adapter la normalisation linéaire à des situations où les images ne sont pas parfaitement coregistrées spatialement, en utilisant des PIFs extraites visuellement. Cette approche permet une normalisation robuste même entre des jeux de données multisources.

Afin d'assurer la transférabilité du modèle de classification RF entraîné sur les orthophotos de référence, une normalisation radiométrique relative a été appliquée au raster cible. En effet, ces deux rasters ne sont pas codés de la même façon (entre 0 et 65535 pour les orthophotos et entre 0 et 1 pour les données drone) et les acquisitions ne se sont pas faites avec les mêmes conditions d'illuminations (cette portion de l'orthophoto a été acquise le 26 juin 2018 à 11h47, tandis que l'image drone correspondante a été

capturée le 15 mai 2025 entre 15h et 16h). Une large zone commune a donc été utilisée pour extraire les statistiques (moyenne et écart-type) bande par bande (voir Figure 31).

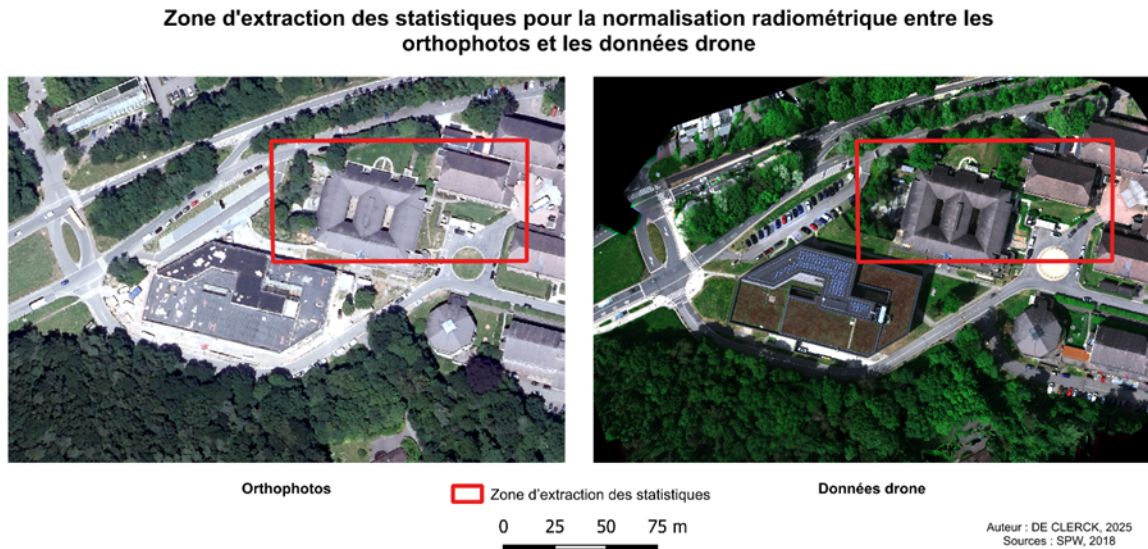


FIGURE 31 – Zone d'extraction des statistiques pour la normalisation radiométrique entre les orthophotos et les données drone

La zone commune a été choisie de façon à représenter la diversité radiométrique présente sur l'ensemble de la scène (toitures, ombres, végétation) tout en assurant une stabilité des coefficients de normalisation. Malgré la présence de végétation, les résultats de classification obtenus ont montré des résultats cohérents. Vu que les acquisitions ont eu lieu à des périodes proches (26 juin et 15 mai), la période dans le cycle phénologique est comparable, ce qui garantit un état de végétation relativement similaire lors des deux acquisitions. En revanche, la partie de la scène correspondant au bâtiment en construction en 2018 mais achevé en 2025 (voir Figure 31) a été exclue de la zone utilisée, car elle constitue une surface différente entre les deux images et risquait de compromettre la validité de la normalisation. Pour tenter d'évaluer la réussite et la cohérence de la normalisation radiométrique, la moyenne des pixels d'une zone du toit d'un des deux bâtiments de la zone d'étude (voir Figure 32) a été calculée pour chacune des bandes des deux rasters afin de voir si les valeurs des orthophotos sont comparables aux valeurs des données drone normalisées. Les moyennes montrent des valeurs assez similaires (voir Tableau 4).

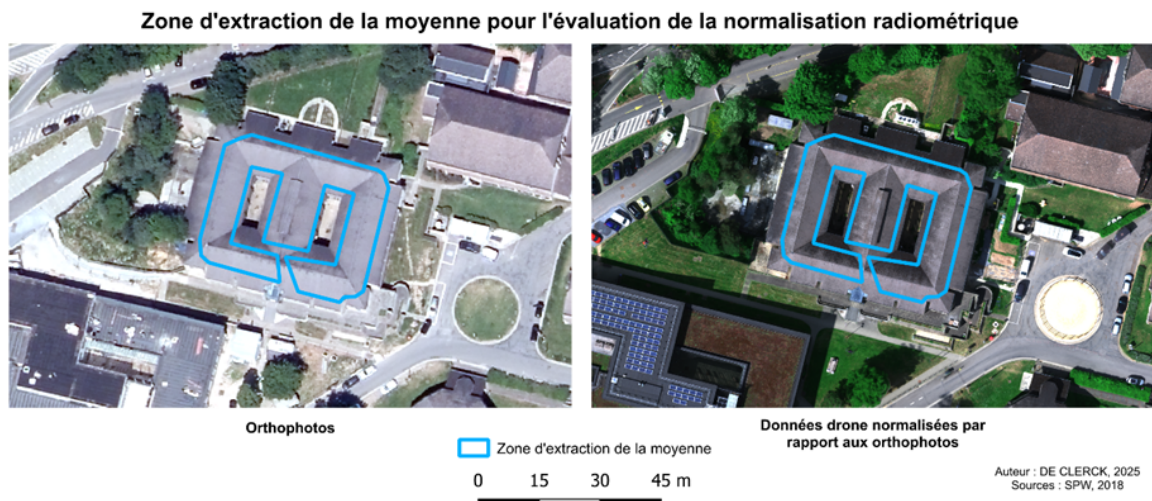


FIGURE 32 – Zone d'extraction de la moyenne pour l'évaluation de la normalisation radiométrique.

TABLEAU 4 – Moyennes des bandes spectrales pour l'image drone normalisée radiométriquement et les orthophotos 2023.

Bande	Drone	Orthophotos
R	35 474	35 840
G	34 446	35 399
B	37 028	37 798
NIR	24 017	21 573

4.3.3.2 Zones ombragées

Puisque le modèle de classification attend en entrée l'information de si le pixel est ombragé ou non, un masque d'ombres pour l'image drone a été calculé. Pour cela, l'indice BAI a de nouveau été utilisé. Afin de déterminer la valeur limite de BAI au-delà de laquelle on considère qu'il s'agit d'ombres, des zones ombragées ont été visuellement sélectionnées afin de comparer leur histogrammes avec ceux des autres pixels (voir Figure 33).

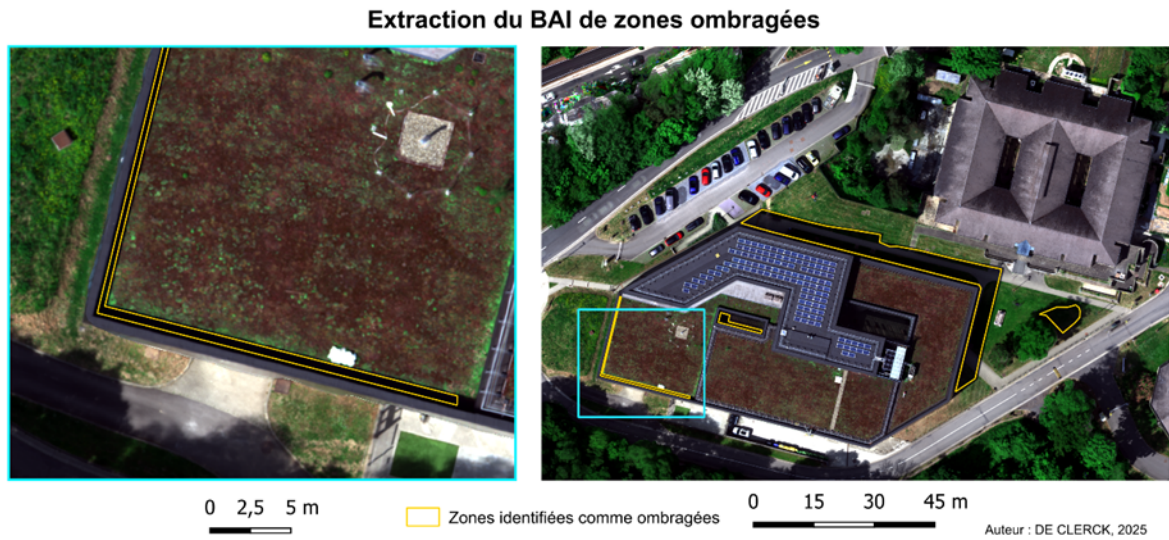


FIGURE 33 – Zones d'extraction du BAI des zones ombragées.

L'analyse des histogrammes des zones ombragées et des autres pixels montre que la limite pour considérer les ombres se trouve vers $8,25 \times 10^{-10}$ (voir Figure 34).




FIGURE 34 – Détermination visuelle de la limite de l'indice BAI des pixels ombragés.

Un masque d'ombres a alors été calculé sur base de cette limite (voir Figure 35).

Masque d'ombres calculé pour l'image drone




FIGURE 35 – Masque d’ombres calculé pour l’image drone.

4.3.3.3 Pente

De façon similaire à l’application du modèle sur une zone de Liège, deux segmentations (automatique et manuelle) ont été réalisées. Pour la segmentation automatique, la fonction `LargeScaleMeanShift` de QGIS a de nouveau été utilisée. La segmentation a été réalisée sur base de la pente, calculée grâce au MNS issu de l’acquisition drone. La pente médiane a finalement été calculée sur ces segments sur base de ce même MNS. Finalement, cette pente médiane est associée à tous les pixels du segment correspondant grâce à la fonction « Rasteriser ».

4.3.4 Application du modèle

Le modèle est ensuite appliqué à ce raster 6 bandes (RGN + NIR + ombres + pentes) et la classe majoritaire de chaque segment est conservée comme prédiction finale.

4.3.5 Comparaison avec les données en accès libre de la Wallonie

De façon à pouvoir comparer les résultats obtenus via les données drone à des résultats obtenus via des données en accès libre de la Wallonie, les orthophotos 2023 (SPW, 2023) ont été utilisées en plus du MNS déjà utilisé lors de l’entraînement ou de l’application du modèle sur une zone de Liège. En effet, cette comparaison est impossible via les orthophotos 2018 car la construction d’un des deux bâtiments étudiés n’était pas encore achevée.

Pour ce faire, la même méthodologie que pour les données drone a été appliquée (normalisation radiométrique, masque d’ombres, segmentation de l’orthophoto, calcul de la pente médiane par segment et application du modèle). Les détails de ces étapes sont disponibles à l’Annexe D.

Enfin, les superficies de chaque matériau identifié ont été calculées dans QGIS, puis comparées aux superficies réelles connues des matériaux afin d’évaluer l’apport des données à plus haute résolution spatiale.

5 Résultats

5.1 Validation et évaluation des modèles de classification

L'analyse comparative des performances entre les algorithmes SVM et RF selon différentes combinaisons de caractéristiques montre des écarts significatifs (voir Tableau 5, Figures 36 et 37 et Annexes E à J).

TABLEAU 5 – Résultats des classifications selon les différentes combinaisons de caractéristiques et d'algorithmes.

		SVM		RF	
		Macro	Weighted	Macro	Weighted
RGB + NIR + ombres	Accuracy	0,513		0.824	
	Precision	0.593	0.556	0.816	0.821
	Recall	0.385	0.513	0.776	0.824
	F1 score	0.386	0.461	0.79	0.82
RGB + NIR + ombres + textures	Accuracy	0.515		0.828	
	Precision	0.588	0.553	0.83	0.827
	Recall	0.389	0.515	0.777	0.828
	F1 score	0.392	0.465	0.795	0.824
RGB + NIR + ombres + pentes	Accuracy	0.653		0.965	
	Precision	0.7	0.664	0.961	0.965
	Recall	0.545	0.653	0.954	0.965
	F1 score	0.554	0.62	0.957	0.965
RGB + NIR + ombres + textures + pentes	Accuracy	0.654		0.96	
	Precision	0.653	0.652	0.957	0.96
	Recall	0.547	0.654	0.947	0.96
	F1 score	0.57	0.622	0.951	0.96

De manière générale, les performances du classifieur RF surpassent nettement celles du SVM pour toutes les configurations testées. Pour chaque ensemble de caractéristiques, les métriques calculées (Accuracy, Precision, Recall, score F1) sont systématiquement plus élevées avec l'algorithme RF.

L'ajout des caractéristiques texturales aux données d'entrée n'a pas systématiquement conduit à des améliorations marquées des performances de classification. En observant les résultats des modèles RF entraînés avec « RGB + NIR + ombres » et avec « RGB + NIR + ombres + textures », on remarque que les gains sont modestes, voire parfois négligeables. Par exemple, la classe tuiles oranges reste au même niveau de performance (92 %) avec ou sans textures, et les ardoises sans CA subissent même une dégradation

(de 49,8 % à 47,9 %). Ces résultats suggèrent que les textures extraites ne capturent pas suffisamment de variation discriminante pour certaines classes, probablement en raison de la faible résolution spatiale des images. De plus, certains types de toitures, bien que différents en nature, peuvent présenter des textures proches en raison de leur grain fin ou de leur régularité, rendant difficile leur séparation par des descripteurs de texture simples.

L'ajout de l'information de pente dans les modèles d'apprentissage, notamment avec l'algorithme RF, a permis une nette amélioration des performances, en particulier pour des classes souvent confondues auparavant comme les membranes noires, les tuiles et les ardoises. En comparant les matrices de confusion entre la configuration RGB + NIR + ombres (Figure 36) et celle enrichie avec RGB + NIR + ombres + pentes (Figure 37), on constate des gains significatifs. Par exemple, la classe des membranes noires passe de 87,5 % à 97,3 % de bonne classification, réduisant fortement les confusions avec les ardoises ou les métaux. De même, les tuiles brunes/noires atteignent 93,1 % avec la pente contre seulement 64,5 % sans. Avant l'ajout de la pente, les tuiles noires/brunes étaient confondues dans 15,2 % des cas avec les membranes noires. Les ardoises/tôles en CA voient leur taux de classification correcte grimper de 77,8 % à 95,7 %, montrant une baisse importante des erreurs avec les membranes noires et les graviers. De plus, les ardoises sans CA étaient confondues avec des membranes noires dans 26,9 % des cas. L'ajout de l'information sur la pente a réduit ce chiffre à 0,9 %. Ces résultats montrent que l'intégration de données LiDAR, et en particulier des informations de pente dérivées d'un MNS, permet de mieux distinguer certains matériaux, là où les seules données spectrales se révélaient insuffisantes pour les différencier efficacement. Ces améliorations s'expliquent par le fait que la pente joue un rôle discriminant dans l'implantation des matériaux de toiture : certains types de matériaux sont plus couramment posés sur des toits à pente forte ou faible.




FIGURE 36 – Matrice de confusion du modèle RF - RGB + NIR + ombres.




FIGURE 37 – Matrice de confusion du modèle RF - RGB + NIR + ombres + pentes.

De toutes les combinaisons testées, le modèle le plus performant est celui utilisant comme caractéristiques les bandes RGB + NIR, les ombres et les pentes avec l'algorithme RF. Ce modèle obtient une Accuracy de 0,965, une Precision et un Recall de 0,965, ainsi qu'un score F1 également de 0,965 en moyenne pondérée, ce qui témoigne d'une justesse des prédictions pour toutes les classes. L'analyse de la matrice de confusion de ce modèle montre que toutes les classes ont plus de 90 % de leur entités correctement classées, sauf les fenêtres de toit qui sont confondues avec plusieurs autres classes. Comme expliqué dans la méthodologie, ce meilleur modèle a également été validé et évalué par validation croisée. Les résultats sont similaires à ceux obtenus via la validation sur 30 % du jeu de données (voir Tableau 6).

TABLEAU 6 – Validation croisée du meilleur modèle (RF - RGB + NIR + ombres + pentes) (moyennes macro et pondérée).

Métrique	Macro	Weighted
Accuracy		0,96
Precision	0,96	0,96
Recall	0,95	0,96
F1 score	0,96	0,96

L’analyse de l’importance des variables dans le modèle RF utilisant les caractéristiques RGB, NIR, ombres et pentes met en évidence le rôle central joué par certaines variables dans le processus de décision (voir Figure 38). Parmi les variables testées, la pente ressort nettement comme la plus discriminante, avec une importance relative de 0,325. Ce résultat confirme les analyses précédentes selon lesquelles la pente constitue une information clé pour distinguer différents matériaux de toiture, notamment les membranes, les ardoises ou les tuiles. La bande NIR (0,199) et les composantes RGB (entre 0,129 et 0,182) conservent également un rôle majeur dans la classification. En revanche, la variable ombres affiche une importance extrêmement faible (0,002), ce qui peut s’expliquer par le fait qu’elle ne concerne qu’une faible proportion du jeu de données d’entraînement. En effet, seulement 2,55 % des pixels annotés étaient ombragés, ce qui a probablement limité la capacité du modèle à apprendre des règles spécifiques à cette condition.




FIGURE 38 – Importance des variables dans le modèle RF - RGB + NIR + ombres + pentes.

Notons que la profondeur moyenne des arbres de décision est de 48,5 avec un minimum de 43 et un maximum de 56. Afin d’illustrer concrètement la manière dont le modèle RF prend ses décisions, les 4 premiers niveaux de profondeur d’un des 150 arbres composant le modèle ont été extraits et visualisés (voir Figure 39). Cette représentation permet de voir concrètement des exemples de discriminations faites par l’algorithme à partir des différentes variables (pente, bandes spectrales, ombre). Chaque couleur représente une

classe, plus celle-ci est saturée et plus la pureté est élevée. À l'inverse, un nœud clair représente un nœud avec un mélange de classes encore élevé.

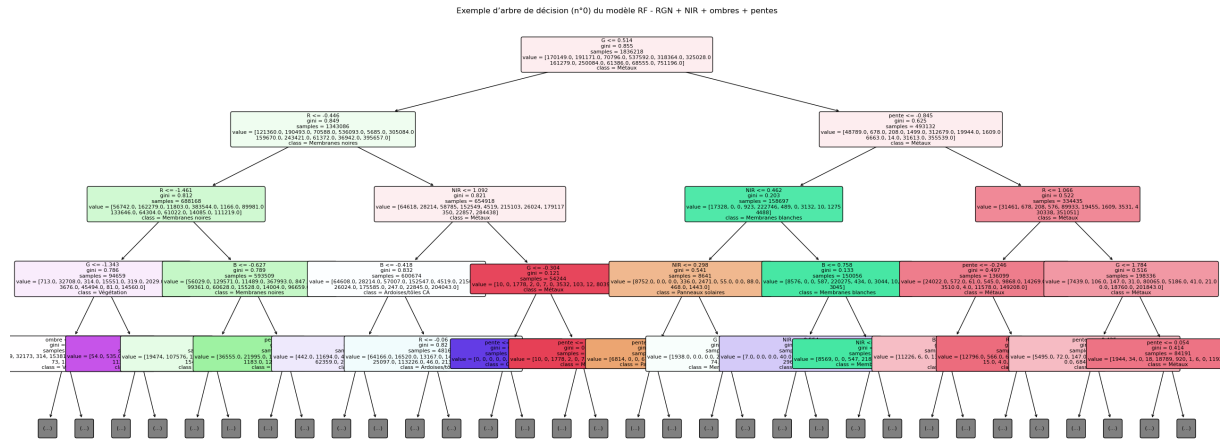


FIGURE 39 – Illustration d'un arbre de décision du modèle RF.

5.2 Application du meilleur modèle à une zone de Liège

Concernant l'application du modèle à une zone de Liège, les visualisations des résultats sont disponibles aux Figures 40 et 41. Il est malheureusement impossible de vérifier les prédictions de façon objective, mais une analyse visuelle montre que, dans l'ensemble, les prédictions ont l'air cohérentes.

Résultats de la classification sur une zone de Liège Segmentation automatique




FIGURE 40 – Résultats de la classification sur une zone de Liège avec la segmentation automatique.

Résultats de la classification sur une zone de Liège Segmentation manuelle



Matériaux de toiture identifiés

- Panneaux solaires
- Tuiles brunes/noires
- Tuiles oranges
- Membranes noires
- Membranes blanches
- Ardoises/tôles CA
- Ardoises sans CA
- Gravier
- Végétation
- Fenêtres de toit
- Métaux

0 15 30 45 m



Auteur : DE CLERCK, 2025
Sources : SPW, 2018

FIGURE 41 – Résultats de la classification sur une zone de Liège avec la segmentation manuelle.

5.3 Application du meilleur modèle aux données drone

Concernant l'application du modèle aux données drone, les résultats sont affichés aux Figures 42 et 43. On voit que l'identification sur base des données drone est assez fine. Tous les panneaux solaires sont identifiés distinctivement par rapport à la membrane noire en dessous. Le toit végétalisé est reconnu avec succès comme étant des graviers, où pousse de la végétation. Par contre, la toiture du bâtiment du haut est erronément identifiée comme des tuiles brunes/noires et/ou des métaux selon la segmentation.

Résultats de la classification sur base des données drone Segmentation automatique



Matériaux de toiture identifiés


- Panneaux solaires
- Tuiles brunes/noires
- Tuiles oranges
- Membranes noires
- Membranes blanches
- Ardoises/tôles CA
- Ardoises sans CA
- Graviers
- Végétation
- Fenêtres de toit
- Métaux

0 15 30 45 m

Auteur : DE CLERCK, 2025
Sources : SPW, 2018

FIGURE 42 – Résultats de la classification sur base des données drone avec la segmentation automatique.

Résultats de la classification sur base des données drone Segmentation manuelle



Matériaux de toiture identifiés

- Panneaux solaires
- Tuiles brunes/noires
- Tuiles oranges
- Membranes noires
- Membranes blanches
- Ardoises/tôles CA
- Ardoises sans CA
- Graviers
- Végétation
- Fenêtres de toit
- Métaux

0 15 30 45 m

Auteur : DE CLERCK, 2025
Sources : SPW, 2018

FIGURE 43 – Résultats de la classification sur base des données drone avec la segmentation manuelle.

5.3.1 Comparaison avec les données en accès libre de la Wallonie

Enfin, les résultats de la classification sur la même zone d'étude que celle de l'acquisition drone sont présentés aux Figures 44 et 45. Globalement, ils sont assez proches de ceux obtenus à partir des données drone. Néanmoins, on observe que la membrane noire est confondue avec les panneaux solaires voisins. Il pourrait s'agir d'un effet lié à la résolution du MNS, qui augmenterait artificiellement la pente de la membrane noire. La toiture du bâtiment situé en haut de l'image est de nouveau mal identifiée, avec une classification erronée en tuiles brunes/noires et/ou en métaux selon la segmentation. La différence principale entre les données drone et les données de la Wallonie en segmentations manuelles réside dans la proportion finale de pixels attribués à chaque classe. Cependant, les deux classifications identifient malgré tout des tuiles brunes/noires et des métaux sur cette même toiture.

Résultats de la classification sur base des orthophotos et MNS de la Wallonie Segmentation automatique





FIGURE 44 – Résultats de la classification sur base des orthophotos et MNS de la Wallonie avec la segmentation automatique.

Résultats de la classification sur base des orthophotos et MNS de la Wallonie Segmentation manuelle



Matériaux de toiture identifiés

- Panneaux solaires
- Tuiles brunes/noires
- Tuiles oranges
- Membranes noires
- Membranes blanches
- Ardoises/tôles CA
- Ardoises sans CA
- Gravier
- Végétation
- Fenêtres de toit
- Métaux

0 15 30 45 m

Auteur : DE CLERCK, 2025
Sources : SPW, 2018

FIGURE 45 – Résultats de la classification sur base des orthophotos et MNS de la Wallonie avec la segmentation manuelle.

5.3.2 Superficies de matériaux identifiés

L'analyse des superficies des matériaux identifiés (Tableau 7, Figure 46) montre que, globalement, les données drone produisent de meilleurs résultats. Il faut toutefois noter que les trois grandes barres avoisinant 1750 m² correspondent à la toiture du bâtiment situé en haut de l'image, qui a été mal classée par les deux méthodes. La différence entre les deux approches réside principalement dans la classe majoritaire attribuée à cette toiture, ce qui explique l'écart important observé dans les résultats finaux.

TABLEAU 7 – Comparaison des superficies identifiées par classe entre vérité terrain, données drone et orthophotos (en m²).

Classe	Vérité	Drone (auto.)	Drone (man.)	Ortho (auto.)	Ortho (man.)
Panneaux solaires	211,7	243,7	222,2	803,9	769,2
Tuiles brunes/noires	0,0	1 231,1	1 759,3	919,2	0,0
Membranes noires	586,8	621,0	586,8	201,2	0,0
Membranes blanches	0,0	0,0	0,0	0,0	3,2
Ardoises/tôles en CA	1 759,3	0,0	0,0	224,6	0,0
Ardoises sans CA	0,0	55,2	0,0	264,2	0,0
Graviers	1 751,9	1 879,8	1 751,9	1 815,1	1 654,8
Végétation	0,0	0,0	0,0	47,9	0,0
Fenêtres de toit	22,4	35,6	20,5	0,0	0,0
Métaux	0,0	464,1	1,9	1 114,2	1 714,3




FIGURE 46 – Superficies de matériaux identifiés (vérité terrain, données drone et orthophotos (segmentations manuelles)).

6 Discussion

6.1 Échantillonnage

Ce travail aura permis la création d'un jeu de données d'entraînement (polygones) annotées correspondant aux orthophotos 2018. Les données d'entrée pour la classification ont été traitées de façon manuelle, ce qui permet de ne pas devoir dépendre d'une segmentation. Les données sont donc « plus propres », et n'incluent pas de pixels ne faisant pas partie de la toiture comme des bouts de voiries ou de façades.

6.2 Caractéristiques prises en compte

Les résultats de ce travail montrent qu'il est possible d'identifier des matériaux de toiture avec une Accuracy de 82,4 % avec l'algorithme RF en se basant uniquement sur les données spectrales et l'information binaire de l'ombre. L'ajout de l'information texturale sur ces quatre bandes (RGB + NIR) n'a que très peu amélioré les résultats que ce soit avec l'algorithme SVM ou RF. Malgré ces premiers bons résultats sur base des données spectrales, des confusions persistent, particulièrement entre les différents matériaux de couleur noire. Ceux-ci présentent des signatures spectrales très proches et peu contrastées, avec une réflectance faible et constante sur l'ensemble de la gamme spectrale. Les tuiles brunes/noires, ardoises, membranes noires et même certains métaux peints en noir apparaissent très similaires en spectre RGB + NIR. De plus, l'analyse des spectres complets (0,25–3,5 μm) montre que ces matériaux absorbent pratiquement toutes les longueurs d'onde, rendant leur différenciation impossible sur base des seules données spectrales, même dans le SWIR (Wyard, Marion & Hallot, 2023). Face à ces limites, l'intégration de la pente issue du MNS de la Wallonie s'est révélée particulièrement utile permettant de distinguer des toitures spectralement similaires mais typiquement associées à des types de toitures différentes : les membranes étant généralement posées sur des toits plats, tandis que tuiles et ardoises équipent des toitures inclinées. L'apport de l'intégration de l'information de pente avait déjà été démontré par le projet CASMATTELE. Dans cette étude, l'utilisation d'un MNS à 1 m de résolution spatiale avait déjà permis de réduire significativement certaines confusions en utilisant des règles post-classification. Les auteurs avaient alors suggéré que l'utilisation du nouveau MNS issu du LiDAR wallon (résolution spatiale de 0,5 m) devrait permettre d'améliorer encore la classification (Wyard, Beaumont, Hallot & ISSeP, 2023). Effectivement, l'intégration de ces données de pente médiane par échantillon grâce à ce nouveau MNS a permis d'améliorer significativement les résultats jusqu'à une Accuracy de 96,5 %. De plus, l'analyse de l'importance des variables du modèle RF montre que la pente est clairement la variable la plus discriminante (0,325).

6.3 Algorithmes de classification

L’algorithme RF a obtenu des valeurs d’Accuracy systématiquement supérieures ($> 0,3$) à celles du SVM avec les mêmes variables. Cela démontre clairement la robustesse et l’efficacité de RF, qui est l’un des meilleurs algorithmes de ML actuellement disponibles (Géron, 2019). Les faibles performances du SVM s’expliquent probablement par l’absence de frontières linéaires nettes entre les différentes classes de matériaux à distinguer. En effet, seul un SVM linéaire a pu être utilisé ici, car l’implémentation d’un SVM non linéaire était tout simplement impossible compte tenu du nombre d’échantillons (Géron, 2019).

6.4 Application du modèle

L’application du modèle à d’autres zones ou images révèle des limites. Ces limites rappellent que la classification des matériaux par analyse d’images reste un défi en milieu urbain dense et varié, typique des villes post-industrielles du Sillon Sambre et Meuse. Cette hétérogénéité se traduit par des signatures spectrales très variées, même dans une même classe de matériau, compliquant la distinction des matériaux.

Les données en accès libre montrent certaines limites dues à leur plus faible résolution spatiale, et également à cause du décalage entre les orthophotos et le MNS, qui peut dans certains cas fausser le calcul de pente, qui joue un rôle très important dans la classification.

En outre, les conditions d’acquisition des images induisent des facteurs de variabilité importants. Les variations d’illumination, les ombres, et l’angle entre le matériau, le soleil et le capteur modifient significativement la signature spectrale apparente, en particulier dans l’espace RGB (Ilebag et al., 2019 ; Salcido & Laefer, 2024 ; Son et al., 2014 ; L. Yuan et al., 2020). Cette variabilité intra-classe peut fortement dégrader les performances de détection. Comme on le voit sur la Figure 47, au niveau de la zone d’étude, le modèle détecte des métaux ou des tuiles brunes/noires en fonction de l’orientation du pan de toit par rapport au soleil. Les zones exposées vers le soleil tendent à être classées comme métaux, tandis que les zones à l’ombre, ou sur la face opposée au soleil tendent plus à être classées comme des tuiles brunes/noires. On note que les données drone permettent la détection de plus de pixels d’ardoises/tôles en CA (le matériau correct du toit) que les orthophotos 2023 et le MNS de la Wallonie. Wyard et al. (2020) avaient déjà relevé ce problème de classification qui diffère en fonction des pans de toit et de l’exposition du soleil au moment de l’acquisition. Notons d’ailleurs que les résultats du projet CASMATTELE classaient également la toiture de ce même bâtiment comme étant des métaux (Coraline Wyard, communication personnelle) ce qui suggérerait que ce bâtiment en particulier pose problème.

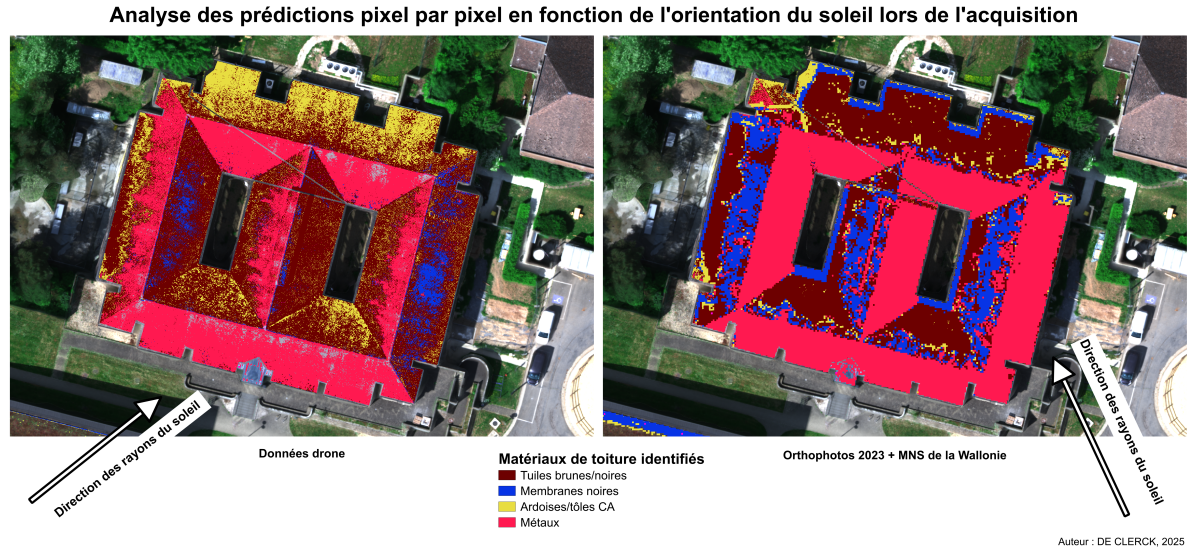


FIGURE 47 – Analyse des prédictions pixel par pixel en fonction de l’orientation du soleil lors de l’acquisition.

De plus, la qualité des prédictions est conditionnée par la précision des étapes préliminaires : segmentation, normalisation radiométrique, masquage des ombres et calcul des pentes. Les segmentations automatiques peuvent induire des erreurs en fusionnant des surfaces hétérogènes ou en incluant des zones ne faisant pas partie de toitures. Les résultats montrent d’ailleurs que l’ajustement manuel de la segmentation améliore localement la qualité des prédictions, mais cette approche n’est pas réalisable à grande échelle. Un travail à part entière sur la segmentation sera donc nécessaire pour automatiser la chaîne de traitement et permettre la classification sur des zones plus vastes. Enfin, il faut rappeler que les échantillons de matériaux utilisés pour l’entraînement ont été prélevés sur des toitures « non ambiguës », c’est-à-dire facilement reconnaissables et homogènes qui ont été échantillonnés principalement via Google Earth par Wyard et al. (2020). Il apparaît donc logique que la classification de ces échantillons, et donc les résultats obtenus lors de la validation du modèle, atteignent de meilleures performances que la classification de toitures plus complexes ou atypiques qui ne ressemblent pas exactement aux données d’entraînement. Cela pourrait expliquer que certaines erreurs persistent malgré des scores obtenus très élevés.

6.5 Plus-value des données drone

L’analyse des superficies des matériaux identifiés montre que, globalement, les données drone offrent de meilleurs résultats que les orthophotos en accès libre. La résolution spatiale plus fine du drone permet en effet une meilleure segmentation automatique des toitures, grâce notamment au MNS à haute résolution spatiale parfaitement calé avec l’image multispectrale. De plus, le calcul de la pente médiane est plus précis et permet de

mieux distinguer les panneaux solaires de la membrane noire sous-jacente. Les données en accès libre, en raison de leur résolution spatiale plus faible, entraînaient en effet davantage de confusion à ce niveau.

Néanmoins, même avec les données drone, certaines erreurs localisées persistent. En effet, la toiture du bâtiment situé en haut de la zone d'étude, est mal identifiée dans les deux approches, ce qui démontre que les données drone sont également vulnérables aux conditions d'illuminations. Notons également que les étapes de normalisation radiométriques rajoutent des incertitudes, là où un modèle directement entraîné sur des données drone n'aurait pas ce problème. Malheureusement, un tel modèle nécessiterait de nombreuses données, et donc de nombreuses campagnes d'acquisitions, ce qui demande beaucoup de ressources.

7 Conclusion

Ce travail aura permis d'établir un état de l'art sur la classification automatique de matériaux de construction (et plus particulièrement de toiture).

Grâce à une rencontre avec Coraline Wyard de l'ISSEP, des données d'entraînement ont été obtenues. Celles-ci ont été retravaillées et ont permis, avec les orthophotos 2018 et le MNS de la Wallonie d'établir un modèle de classification permettant de distinguer 11 classes de matériaux de toiture. Plusieurs caractéristiques ont été testées (RGB + NIR, ombres, textures, pentes) ainsi que deux algorithmes de ML (SVM et RF). La combinaison RGB + NIR + ombres + pentes avec RF offre les meilleurs résultats avec une Accuracy de 96,5 %. Ces résultats sont très prometteurs et atteignent des taux de classification correcte attendus dans un contexte d'économie circulaire de matériaux de construction.

Il apparait qu'avoir des données à plus haute résolution spatiale permet d'obtenir de meilleurs résultats. Néanmoins, certaines confusions persistent, surement à cause des différentes conditions d'illuminations lors de l'acquisition.

Notons que le DL, l'imagerie hyperspectrale ou le LiDAR multispectral, constituent des approches prometteuses qui n'ont pas été explorées dans le cadre de ce travail mais qui mériteraient d'être explorées à l'avenir.

À terme, de tels modèles de classification pourraient contribuer à la mise en place d'outils fiables pour l'identification automatisée des matériaux à grande échelle. Cela faciliterait la planification de la rénovation énergétique, l'évaluation des gisements de matériaux et leur potentiel de réutilisation, ainsi que la valorisation des déchets de démolition dans une logique d'économie circulaire.

Références

- Abbasi, M., Mostafa, S., Vieira, A. S., Patorniti, N., & Stewart, R. A. (2022). Mapping Roofing with Asbestos-Containing Material by Using Remote Sensing Imagery and Machine Learning-Based Image Classification : A State-of-the-Art Review. *Sustainability*, 14(13), 8068. <https://doi.org/10.3390/su14138068>
- Alaloul, W. S., & Qureshi, A. H. (2021, mars). Material Classification via Machine Learning Techniques : Construction Projects Progress Monitoring. In *Deep Learning Applications*. IntechOpen. <https://doi.org/10.5772/intechopen.96354>
- Amano, K., Lou, E. C. W., & Edwards, R. (2018). Integration of point cloud data and hyperspectral imaging as a data gathering methodology for refurbishment projects using building information modelling (BIM). *Journal of Facilities Management*, 17(1), 57-75. <https://doi.org/10.1108/JFM-11-2017-0064>
- Baldrige, A. M., Hook, S. J., Grove, C. I., & Rivera, G. (2009). The ASTER spectral library version 2.0. *Remote Sensing of Environment*, 113(4), 711-715. <https://doi.org/10.1016/j.rse.2008.11.007>
- Barbhuiya, S., & Das, B. B. (2023). Life Cycle Assessment of construction materials : Methodologies, applications and future directions for sustainable decision-making. *Case Studies in Construction Materials*, 19, e02326. <https://doi.org/10.1016/j.cscm.2023.e02326>
- Belgiu, M., & Drăguț, L. (2016). Random forest in remote sensing : A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24-31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Bonifazi, G., Capobianco, G., & Serranti, S. (2019). Hyperspectral Imaging and Hierarchical PLS-DA Applied to Asbestos Recognition in Construction and Demolition Waste. *Applied Sciences*, 9(21), 4587. <https://doi.org/10.3390/app9214587>
- Davis, P., Aziz, F., Newaz, M. T., Sher, W., & Simon, L. (2021). The classification of construction waste material using a deep convolutional neural network. *Automation in Construction*, 122, 103481. <https://doi.org/10.1016/j.autcon.2020.103481>
- Deshpande, S. S., Inamdar, A. B., & Vin, H. M. (2019). Spectral Library and Discrimination Analysis of Indian Urban Materials. *Journal of the Indian Society of Remote Sensing*, 47(5), 867-877. <https://doi.org/10.1007/s12524-019-00942-6>
- Dimitriadis, S. I., Liparas, D., & Initiative, f. t. A. D. N. (2018). How random is the random forest ? Random forest algorithm on the service of structural imaging biomarkers for Alzheimer's disease : from Alzheimer's disease neuroimaging initiative (ADNI) database. *Neural Regeneration Research*, 13(6), 962. <https://doi.org/10.4103/1673-5374.233433>
- Dimitrov, A., & Golparvar-Fard, M. (2014). Vision-based material recognition for automated monitoring of construction progress and generating building

- information modeling from unordered site image collections. *Advanced Engineering Informatics*, 28(1), 37-49. <https://doi.org/10.1016/j.aei.2013.11.002>
- Ekhtari, N., Glennie, C., & Fernandez-Diaz, J. C. (2017). Classification of multispectral lidar point clouds. *2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2756-2759. <https://doi.org/10.1109/IGARSS.2017.8127568>
- Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow* (2ème). O'Reilly. <https://www.oreilly.com/library/view/hands-on-machine-learning/9781492032632/>
- Hall-Beyer, M. (2017). GLCM Texture : A Tutorial v. 3.0 March 2017. <http://hdl.handle.net/1880/51900>
- Han, K. K., & Golparvar-Fard, M. (2015). Appearance-based material classification for monitoring of operation-level construction progress using 4D BIM and site photologs. *Automation in Construction*, 53, 44-57. <https://doi.org/10.1016/j.autcon.2015.02.007>
- Haralick, R. M., Shanmugam, K., & Dinstein, I. (1973). Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3(6), 610-621. <https://doi.org/10.1109/TSMC.1973.4309314>
- Herold, M., & Roberts, D. A. (2010). The Spectral Dimension in Urban Remote Sensing. In T. Rashed & C. Jürgens (Éd.), *Remote Sensing of Urban and Suburban Areas* (p. 47-65). Springer Netherlands. https://doi.org/10.1007/978-1-4020-4385-7_4
- Herold, M., Roberts, D. A., Gardner, M. E., & Dennison, P. E. (2004). Spectrometry for urban area remote sensing—Development and analysis of a spectral library from 350 to 2400 nm. *Remote Sensing of Environment*, 91(3), 304-319. <https://doi.org/10.1016/j.rse.2004.02.013>
- Hossler, K., & Kelsey, S. (2017). Urban Materials Spectral Library v1.0. *Urban Materials Spectral Library*. https://corescholar.libraries.wright.edu/spectral_data/1
- Ilehag, R., Leitloff, J., Weinmann, M., & Schenk, A. (2020). Urban material classification using spectral and textural features retrieved from autoencoders. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, V-1-2020, 25-32. <https://doi.org/10.5194/isprs-annals-V-1-2020-25-2020>
- Ilehag, R., Weinmann, M., Schenk, A., Keller, S., Jutzi, B., & Hinz, S. (2017). Revisiting existing classification approaches for building materials based on hyperspectral data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-3-W3, 65-71. <https://doi.org/10.5194/isprs-archives-XLII-3-W3-65-2017>
- Ilehag, R., Schenk, A., Huang, Y., & Hinz, S. (2019). KLUM : An Urban VNIR and SWIR Spectral Library Consisting of Building Materials. *Remote Sensing*, 11(18), 2149. <https://doi.org/10.3390/rs11182149>
- Interreg Meuse - Rhine. (2025). RE-USE. <https://www.interregmeuserhine.eu/en/projects/re-use/>
- Kokaly, R. F., Clark, R. N., Swayze, G. A., Livo, K. E., Hoefen, T. M., Pearson, N. C., Wise, R. A., Benz, W., Lowers, H. A., Driscoll, R. L., & Klein, A. J. (2017).

- USGS Spectral Library Version 7* (rapp. tech. N° 1035). U.S. Geological Survey. <https://doi.org/10.3133/ds1035>
- Kotthaus, S., Smith, T. E. L., Wooster, M. J., & Grimmond, C. S. B. (2014). Derivation of an urban materials spectral library through emittance and reflectance spectroscopy. *ISPRS Journal of Photogrammetry and Remote Sensing*, *94*, 194-212. <https://doi.org/10.1016/j.isprsjprs.2014.05.005>
- López, A., Jurado, J. M., Jiménez-Pérez, J. R., & Feito, F. R. (2022). Generation of hyperspectral point clouds : Mapping, compression and rendering. *Computers & Graphics*, *106*, 267-276. <https://doi.org/10.1016/j.cag.2022.06.011>
- Mahami, H., Ghassemi, N., Darbandy, M. T., Shoeibi, A., Hussain, S., Nasirzadeh, F., Alizadehsani, R., Nahavandi, D., Khosravi, A., & Nahavandi, S. (2021). Material Recognition for Automated Progress Monitoring using Deep Learning Methods. <https://doi.org/10.48550/arXiv.2006.16344>
- Meerdink, S. K., Hook, S. J., Roberts, D. A., & Abbott, E. A. (2019). The ECOSTRESS spectral library version 1.0. *Remote Sensing of Environment*, *230*, 111196. <https://doi.org/10.1016/j.rse.2019.05.015>
- MicaSense. (2024). How do calibrated reflectance panels improve my data? <https://support.micasense.com/hc/en-us/articles/220154947-How-do-calibrated-reflectance-panels-improve-my-data>
- Moghim, A., Sadeghi, V., Mohsenifar, A., Celik, T., & Mohammadzadeh, A. (2024). LIRRN : Location-Independent Relative Radiometric Normalization of Bitemporal Remote-Sensing Images. *Sensors*, *24*(7), 2272. <https://doi.org/10.3390/s24072272>
- Morsy, S., Shaker, A., & El-Rabbany, A. (2022). Classification of Multispectral Airborne LiDAR Data Using Geometric and Radiometric Information. *Geomatics*, *2*(3), 370-389. <https://doi.org/10.3390/geomatics2030021>
- Norman, M., Shafri, H. Z. M., Mansor, S., Yusuf, B., & Radzali, N. A. W. M. (2020). Fusion of multispectral imagery and LiDAR data for roofing materials and roofing surface conditions assessment. <https://doi.org/10.1080/01431161.2020.1754493>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, É. (2011). Scikit-learn : Machine Learning in Python. *J. Mach. Learn. Res.*, *12*, 2825-2830.
- Pu, S., & Vosselman, G. (2009). Knowledge based reconstruction of building models from terrestrial laser scanning data. *ISPRS Journal of Photogrammetry and Remote Sensing*, *64*(6), 575-584. <https://doi.org/10.1016/j.isprsjprs.2009.04.001>
- Pudale, S. R., & Bhosle, U. V. (2007). Comparative Study of Relative Radiometric Normalization Techniques for Resourcesat1 LISS III Sensor Images. *International Conference on Computational Intelligence and Multimedia Applications (ICCIMA 2007)*, *3*, 233-239. <https://doi.org/10.1109/ICCIMA.2007.158>
- Salcido, J. M. O., & Laefer, D. F. (2024). Urban hyperspectral reference data availability and reuse : State-of-the-practice review. *The Photogrammetric Record*, *39*(188), 894-928. <https://doi.org/10.1111/phor.12508>

- Santos, P., Cervantes, G. C., Zaragoza-Benzal, A., Byrne, A., Karaca, F., Ferrández, D., Salles, A., & Bragança, L. (2024). Circular Material Usage Strategies and Principles in Buildings : A Review. *Buildings*, 14(1), 281. <https://doi.org/10.3390/buildings14010281>
- Scikit-image. (2025). Skimage.feature – Feature extraction. <https://scikit-image.org/docs/0.25.x/api/skimage.feature.htm>
- Scikit-learn. (2025). User Guide. https://scikit-learn.org/stable/user_guide.html
- Serbin, S., DuBois, S., Jablonski, A., Desai, A., Kruger, E., & Townsend, P. (2015). UW-BNL NASA HypsIRI California airborne campaign ground target spectra [dataset]. <https://ecosis.org/package/uw-bnl-nasa-hypsi-ri-california-airborne-campaign-ground-target-spectra>
- Service Public de Wallonie (SPW). (2018). Orthophotos 2018. <http://geodata.wallonie.be/id/71cb59f2-fb18-41bc-9dbf-00ab93f69850>
- Service Public de Wallonie (SPW). (2022). Modèle Numérique de Surface 2022. <https://metawal.wallonie.be/geonetwork/srv/fre/catalog.search#/metadata/5a4c28fe-d30c-493e-861e-a80ebc703b64>
- Service Public de Wallonie (SPW). (2023). Orthophotos 2023. <https://metawal.wallonie.be/geonetwork/srv/fre/catalog.search#/metadata/ad55c2ce-62ad-4c3c-b3cf-8fbc270a6b6e>
- Son, H., Kim, C., Hwang, N., Kim, C., & Kang, Y. (2014). Classification of major construction materials in construction environments using ensemble classifiers. *Advanced Engineering Informatics*, 28(1), 1-10. <https://doi.org/10.1016/j.aei.2013.10.001>
- Takhtkeshha, N., Mandlbürger, G., Remondino, F., & Hyypä, J. (2024). Multispectral Light Detection and Ranging Technology and Applications : A Review. *Sensors*, 24(5), 1669. <https://doi.org/10.3390/s24051669>
- Trachte, S., Romboux, A., Noël, O., Schreurs, A., Sosnowska, P., & Hallot, P. (2025). Projet URMIBALI : Comment les outils numériques de documentation du patrimoine peuvent renforcer la connaissance et le réemploi des matériaux constituant le bâti traditionnel ancien, dans une approche d’Urban Mining. <https://orbi.uliege.be/handle/2268/330009>
- United Nations Environment Programme & Yale Center for Ecosystems + Architecture (UNEP & CEA). (2023). *Building Materials and the Climate : Constructing a New Future*. United Nations Environment Programme. <https://wedocs.unep.org/20.500.11822/43293>
- United Nations Environment Programme (UNEP). (2022). 2022 Global status report for building and construction. <https://www.unep.org/resources/publication/2022-global-status-report-buildings-and-construction>
- Université de Liège. (2025). Interreg VI Meuse-Rhin : 6 projets financés à l’ULiège dans le cadre du 2e appel à projets. https://www.recherche.uliege.be/cms/c_20356590/fr/interreg-vi-meuse-rhin-6-projets-finances-a-l-uliege-dans-le-cadre-du-2e-appel-a-projets?id=c_20356590

- Vexcel Imaging GmbH. (2017). Calibration report : UltraCam Xp, serial UC-SXp-1-20415191.
- Vicente-Serrano, S. M., Pérez-Cabello, F., & Lasanta, T. (2008). Assessment of radiometric correction techniques in analyzing vegetation variability and change using time series of Landsat images. *Remote Sensing of Environment*, 112(10), 3916-3934. <https://doi.org/10.1016/j.rse.2008.06.011>
- Walt, S. v. d., Schönberger, J. L., Nunez-Iglesias, J., Boulogne, F., Warner, J. D., Yager, N., Gouillart, E., & Yu, T. (2014). scikit-image : image processing in Python. *PeerJ*, 2, e453. <https://doi.org/10.7717/peerj.453>
- Wan, Z., Ng, D., & Dozier, J. (1994). Spectral emissivity measurements of land-surface materials and related radiative transfer simulations. *Advances in Space Research*, 14(3), 91-94. [https://doi.org/10.1016/0273-1177\(94\)90197-X](https://doi.org/10.1016/0273-1177(94)90197-X)
- Wyard, C., Beaumont, B., Hallot, E., & ISSeP. (2020). *Projet CASMATTELE 1 : Caractérisation semi-automatique des matériaux de toiture par télédétection. Rapport final. 1er volet.* (rapp. tech.).
- Wyard, C., Beaumont, B., Hallot, E., & ISSeP. (2023). *Projet CASMATTELE 2 : Caractérisation semi-automatique des matériaux de toiture par télédétection. Rapport final. 2ème volet.* (rapp. tech.).
- Wyard, C., Beaumont, B., Marion, R., Roupioz, L., Grippa, T., & Hallot, E. (2021). Roof Material Mapping : Application Over Liège Using Open-Source Object-Based Supervised Classification Algorithms. https://www.researchgate.net/publication/350373949_Roof_Material_Mapping_Application_Over_Liege_Using_Open-Source_Object-Based_Supervised_Classification_Algorithms
- Wyard, C., Beaumont, B., Palmaerts, B., Fauvel, H., Van Driessche, A., & Hallot, E. (2022). The CASMATTELE project : mapping the roof materials of entire Wallonia using EO data and AI techniques. <https://doi.org/10.13140/RG.2.2.34251.87844/1>
- Wyard, C., Beaumont, B., Tais Grippa, Gilles-Antoine Nys, Fauvel, H., & Hallot, E. (2022). Mapping roof materials using WV3 imagery and a state-of-the-art OBIA processing chain : application over Liège, Belgium. <https://doi.org/10.13140/RG.2.2.19567.51363>
- Wyard, C., Fauvel, H., Palmaerts, B., Beaumont, B., & Hallot, E. (2023). From DL approach conception to operational product design : identifying roof materials for policy makers. *2023 Joint Urban Remote Sensing Event (JURSE)*, 1-4. <https://doi.org/10.1109/JURSE57346.2023.10144142>
- Wyard, C., Marion, R., & Hallot, E. (2023). WaRM : A Roof Material Spectral Library for Wallonia, Belgium. *Data*, 8(3). <https://doi.org/10.3390/data8030059>
- Yang, J., Shi, Z.-K., & Wu, Z.-Y. (2016). Towards automatic generation of as-built BIM : 3D building facade modeling and material recognition from images. *International Journal of Automation and Computing*, 13(4), 338-349. <https://doi.org/10.1007/s11633-016-0965-7>

- Yuan, D., & Elvidge, C. D. (1996). Comparison of relative radiometric normalization techniques. *ISPRS Journal of Photogrammetry and Remote Sensing*, 51(3), 117-126. [https://doi.org/10.1016/0924-2716\(96\)00018-4](https://doi.org/10.1016/0924-2716(96)00018-4)
- Yuan, L., Guo, J., & Wang, Q. (2020). Automatic classification of common building materials from 3D terrestrial laser scan data. *Automation in Construction*, 110, 103017. <https://doi.org/10.1016/j.autcon.2019.103017>
- Zahiri, Z., Laefer, D. F., & Gowen, A. (2021). Characterizing building materials using multispectral imagery and LiDAR intensity data. *Journal of Building Engineering*, 44, 102603. <https://doi.org/10.1016/j.jobbe.2021.102603>
- Zahiri, Z., Laefer, D. F., Kurz, T., Buckley, S., & Gowen, A. (2022). A comparison of ground-based hyperspectral imaging and red-edge multispectral imaging for façade material classification. *Automation in Construction*, 136, 104164. <https://doi.org/10.1016/j.autcon.2022.104164>
- Zambrano-Prado, P., Josa, A., Rieradevall, J., Pérez-Aragüés, F., Marchan, J. F., Gassó-Domingo, S., & Gabarrell, X. (2020). Laboratory-based spectral data acquisition of roof materials. *International Journal of Remote Sensing*, 41(23), 9180-9205. <https://doi.org/10.1080/01431161.2020.1798548>

Annexes

A Classes de matériaux de toiture utilisées pour le projet CASMATTELE

1. Panneaux solaires : comprend les panneaux photovoltaïques et les panneaux solaires thermiques. Ils peuvent être installés sur tous les types de bâtiments et sur des toits plats ou en pente. Les panneaux solaires sont souvent orientés vers le sud. C'est une classe de matériaux rare.
2. Tuiles brunes : comprend les tuiles en céramique et les tuiles en béton (plus rare) de couleur brune. Elles recouvrent exclusivement des toits en pente. C'est une classe de matériaux fréquente que l'on retrouve principalement sur des bâtiments résidentiels avec des toitures de moins de 100 m².
3. Tuiles oranges : comprend les tuiles en céramique. Comme les tuiles brunes, cette classe de matériau très fréquente recouvre exclusivement les toitures en pente et se retrouve sur des bâtiments résidentiels avec des petites surfaces de toiture (<100 m²).
4. Tuiles noires : comprend les tuiles en céramique, en béton et en acier (rare) de couleur noire. Ces tuiles noires se retrouvent principalement sur les toits en pente et sur des toitures de moins de 100 m².
5. Membranes noires : comprend les membranes bitumineuses et les membranes en élastomère style EPDM. Ces membranes sont constituées de longues bandes parallèles lisses. Les formats de ces bandes sont différents entre les bitumineuse et les élastomères, ce qui permet de les différencier. Ces membranes recouvrent presque exclusivement des toitures plates. On retrouve cette classe sur tous types de bâtiments, il s'agit de la classe la plus fréquente dans la zone d'intérêt de l'étude CASMATTELE.
6. Membranes blanches : comprend les membranes en EPDM blanches. C'est une classe de matériau très rare que l'on retrouve dans les mêmes applications que les membranes noires.
7. Ardoises en ciment-asbeste (CA) : comprend les ardoises faites en fibrociment contenant de l'amiante. Ces ardoises recouvrent exclusivement les toits en pente et sont principalement utilisées sur les maisons unifamiliales rénovées/construites entre les années 1960 et 1990. L'aspect visuel est caractérisé par la présence de mousse et de lichens.
8. Ardoises sans asbeste : comprend les ardoises naturelles et les ardoises artificielles sans amiante (principalement de couleur anthracite). On retrouve ces ardoises sans amiante sur les toits en pente. On retrouve beaucoup cette classe sur les maisons unifamiliales ou sur les églises et autres bâtiments historiques construits avant le

20e siècle. Présence de mousse et de lichens.

9. Tôles ondulées en ciment-asbeste (CA) : ces tôles ondulées en fibrociment contenant de l'amiante se retrouvent exclusivement sur des toits en pente et recouvrent souvent de grandes surfaces tels que des hangars, des entrepôts et autres construits ou rénovées entre les années 1960 et 1990. Présence de mousse et de lichens.
10. Gravier : l'utilisation de graviers se retrouve principalement avec l'objectif de lester des membranes recouvrant des toitures plates, aussi bien sur des maisons unifamiliales que sur des immeubles à appartement ou des bâtiments commerciaux.
11. Métaux : comprend les matériaux en aluminium, en acier, en zinc et en plomb. L'aspect peut être naturel ou patiné. Les toitures en métal recouvrent exclusivement des toitures en pente. Elles se retrouvent le plus souvent sur de grands bâtiments industriels, agricoles ou commerciaux. Le zinc est également fréquemment utilisé sur des toits de bâtiments résidentiels.
12. Végétation : les toits végétalisés se retrouvent sur des toitures plates de manière complète ou partielle.
13. Matériaux translucides en verre ou polymère : il s'agit des matériaux transparents en verre ou polymère (plastique au sens courant). Il s'agit souvent d'éléments ponctuels qui ne recouvrent pas toute la toiture. On les retrouve sur tous les types de toits. Les tailles peuvent aller du simple vélux sur un bâtiment résidentiel à des pans de toits entiers sur des bâtiments industriels, commerciaux ou agricoles.

Des photos de ces 13 classes sont visibles à la Figure 48

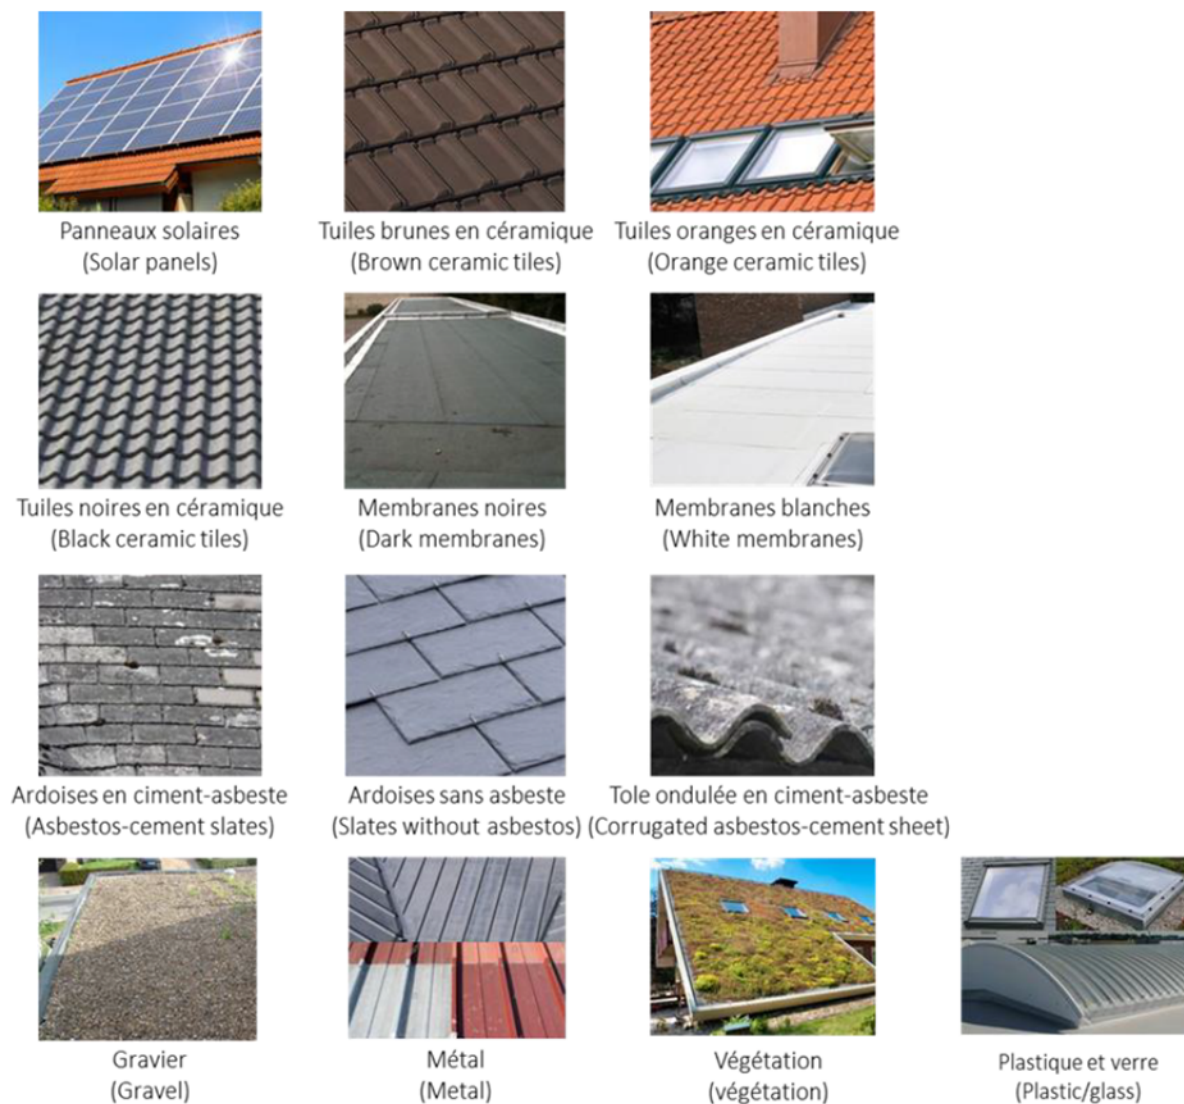


FIGURE 48 – Photos des 13 classes de matériaux de toiture utilisées lors du projet CASMATTELE (Wyard, Beaumont, Hallot & ISSeP, 2023).

B Résumé de la revue de littérature de Salcido & Laefer (2024)

Au total, il existe 11 bibliothèques hyperspectrales pertinentes, fiables et en accès libre pour des matériaux urbains (voir Tableau 8).

1. La bibliothèque « ECOSTRESS (v1.0) » a été réalisé par Meerdink et al. (2019), elle est une extension de la bibliothèque ASTER précédemment mise au point par Baldridge et al. (2009). Il s'agit d'une bibliothèque généraliste contenant plus de 3000 spectres mesurés en laboratoire allant de 0,35 à 15,4 μm pour des minéraux, des roches, des sols lunaires et terrestres, des matériaux anthropiques, de la végétation, et autres matériaux. Au final, la bibliothèque contient 72 signatures spectrales de matériaux anthropiques, dont 45 dans le domaine de la télédétection optique (0,35 à 2,5 μm) (Salcido & Laefer, 2024).
2. Une autre bibliothèque généraliste est la « USGS Spectral Library v7 » réalisée par Kokaly et al. (2017). Cette bibliothèque contient presque 2500 spectre dont 12 % sont des matériaux urbains. La gamme principalement étudiée est située entre 0,35 et 2,5 μm . L'acquisition s'est faite en laboratoire et in-situ. Les échantillons sont accompagnés de métadonnées qui peuvent inclure des photos.
3. La bibliothèque « Moderate Resolution Imaging Spectroradiometer University of California, Santa Barbara Emissivity Library », développée par Wan et al. (1994), fait partie des premières bibliothèques spectrales à avoir été constituées. Elle contient 46 spectres de matériaux anthropiques, mesurés en laboratoire et in-situ, dans la gamme du LWIR (3,3 à 14,5 μm) (Salcido & Laefer, 2024 ; Wyard, Marion & Hallot, 2023).
4. Herold et al. (2004) ont mis au point la Santa Barbara Urban Spectral Library, une bibliothèque composée de 1065 échantillons mesurés in situ, couvrant une plage spectrale allant de 0,35 à 2,4 μm (Salcido & Laefer, 2024).
5. La « Spectral Library of Urban Materials » du « London Urban Micrometeorological data Archive » proposée par Kotthaus et al. (2014) est une bibliothèque comprenant 74 échantillons représentatifs de surfaces couramment rencontrées dans l'environnement urbain londonien tels que le béton, la brique, l'asphalte, la tuile, le métal ou encore le PVC. Cette librairie combine des mesures de réflectance entre 0,35 et 2,5 μm et des mesures d'émissivité thermique dans le domaine LWIR entre 8 et 14 μm acquises en conditions de laboratoire.
6. La bibliothèque « UW-BNL » (ou HypSIRI) a été réalisée par Serbin et al. (2015) et est le résultat d'une collaboration entre l'Université du Wisconsin (UW) et le Brookhaven National Laboratory (BNL). Elle contient 64 échantillons mesurés in-situ entre 0,35 et 2,5 μm . On note 8 échantillons d'asphalte, 15 de béton et 2 de peinture.
7. La bibliothèque « Urban Materials Spectral Library Version 1.0 » de Hossler &

Kelsey (2017) comporte 60 échantillons entre 0,45 et 0,95 μm . Parmi ces 60 spectres, 32 sont de l'asphalte et 28 sont des briques. Les mesures ont été faites in-situ et des métadonnées sur les conditions météorologiques et le lieu sont disponibles.

8. La bibliothèque nommée « Tarang » et développée par Deshpande et al. (2019) contient 1350 échantillons de spectres compris entre 0,35 et 2,5 μm . Les mesures ont été faites in-situ. Salcido & Laefer (2024) notait au moment de l'écriture de leur article que seulement 107 échantillons étaient accessible via le site dédié à la bibliothèque. En avril 2025, le site est malheureusement inaccessible.
9. De leur côté, Ilehag et al. (2019) ont développé la bibliothèque « Karlsruhe Library of Urban Materials ». Cette bibliothèque est dédiée aux matériaux de construction collectés in-situ dans l'environnement urbain de Karlsruhe, au sud de l'Allemagne. Elle se concentre sur les façades contrairement à la plupart des autres bibliothèques existantes qui se concentrent sur des surfaces horizontales, notamment les toitures ou les revêtements routiers. L'acquisition a été réalisée grâce à un capteur hyperspectral monté sur un drone. Cette bibliothèque contient 181 échantillons mesurés dans la gamme 0,35 à 2,5 μm , dont 97 échantillons dédiés aux façades. Les matériaux sont classés en 12 catégories principales (béton, mortier, céramique, plâtre, bois, métal, etc.) et annotés avec des métadonnées précises incluant la couleur, l'état de surface, et l'angle d'incidence du soleil. Des traitements ont été réalisés sur les données, notamment la correction radiométrique avancée, ce qui rend cette bibliothèque particulièrement pertinente.
10. La « Spectral Library of Rooftop Urban Materials » crée par Zambrano-Prado et al. (2020). Elle contient 39 spectres (0,4 à 1 μm) de matériaux de toitures fort présents sur le pourtour méditerranéen (céramique, béton, métal, plastique, pierre et bois). Chaque échantillon a été mesuré en laboratoire sous 4 angles de vue différents, permettant de prendre en compte l'effet des différents angles de vue (Salcido & Laefer, 2024).
11. Finalement, la bibliothèque « Walloon Roof Material » a été développée par Wyard, Marion & Hallot (2023) et l'ISSEP. Cette bibliothèque regroupe 62 signatures spectrales entre 0,35 et 2,5 μm représentant 26 matériaux de toiture utilisés en Wallonie (ex. : tuile de béton noire, tuile de béton brune, membrane EPDM, aluminium brut, aluminium peint en noir, ...). Les signatures spectrales ont été classées selon la classe de matériau (7 classes), la couleur et le degré de dégradation (apprécié visuellement). Ces données ont été acquises en conditions de laboratoire.

TABLEAU 8 – Bibliothèques hyperspectrales et leurs caractéristiques sur base de Salcido & Laefer (2024).

Bibliothèque	Référence	Lieu	Gamme (μm)	Capteur	Acquisition	Échantillons urbains
ECOSTRESS	Meerdink et al. (2019), Baldrige et al. (2009)	États-Unis	0,4–15,4	ASD FieldSpec 3 ; Beckman UV5240 ; Nicolet 520 FTIR ; Perkin-Elmer Lambda 900	Lab.	72
USGS	Kokaly et al. (2017)	États-Unis	0,35–2,5	ASD FieldSpec Hi-Res NG ; Beckman 5270 ; Nicolet FTIR ; AVIRIS	Lab.	302
MODIS	Wan et al. (1994)	États-Unis	3,3–14,5	MIDAC M2510-C FTIR	Lab.	46
SBUSL	Herold et al. (2004)	Californie, États-Unis	0,35–2,5	ASD FieldSpec 3	In-situ	1065
LUMA SLUM	Kotthaus et al. (2014)	Londres, Royaume-Uni	0,35–15,4	SV HR-1024i ; MIDAC M2000 FTIR	Lab.	74
UW-BNL	Serbin et al. (2015)	Californie, États-Unis	0,35–2,5	Spectral Evolution PSM-3500	In-situ	64
UMSL	Hossler & Kelsey (2017)	Ohio, États-Unis	0,45–0,95	Ocean Optics JAZ-EL350	In-situ	60
Tarang	Deshpande et al. (2019)	Inde	0,35–2,5	ASD FieldSpec 3 ; SV GER 1500	In-situ	1350
KLUM	Ilehag et al. (2019)	Karlsruhe, Allemagne	0,35–2,5	ASD FieldSpec 4 Hi-Res	In-situ	181
SlyRUM	Zambrano-Prado et al. (2020)	Pourtour méditerranéen	0,4–1	AISA Eagle II	Lab.	39
WaRM	Wyard, Marion & Hallot (2023)	Wallonie, Belgique	0,35–2,5	ASD FieldSpec 3 Hi-Res	Lab.	26

La revue de Salcido & Laefer (2024) met en évidence le contenu de ces 11 bibliothèques hyperspectrales disponibles en accès libre. Les gammes de longueur d’ondes couvertes par les différents instruments utilisés pour la création des 11 bibliothèques sont illustrées à la Figure 49.

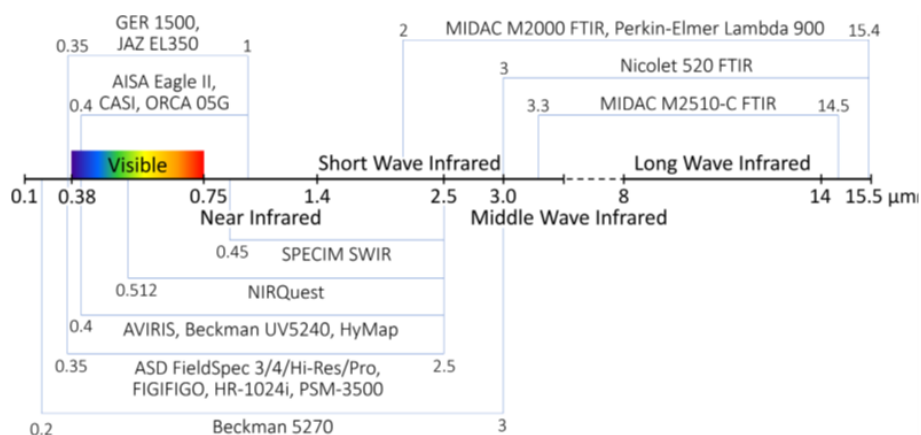


FIGURE 49 – Gammes de longueur d’ondes couvertes par les différents instruments utilisés pour la création des 11 bibliothèques (Salcido & Laefer, 2024)

Le contenu de ces 11 bibliothèques hyperspectrales disponibles en accès libre a été classé en 11 catégories :

1. Bois : comprend les bois bruts et traités.
2. Couverture naturelle : inclut la végétation, le sol, le sable et d'autres matières organiques.
3. Céramique : comprend principalement les briques en argiles et les tuiles.
4. Matériau cimentaire : rassemble les ciments, bétons et mortiers.
5. Pierre : reprend les pierres taillés ou non.
6. Métal : comprend les métaux.
7. Asphalte : comprend l'asphalte ainsi que ses composants comme le bitume ou le goudron.
8. Revêtement : contient des pigments de peinture ainsi que des enduits opaques comme le plâtre.
9. Plastiques : contient les polymères.
10. Standard : les matériaux de référence utilisés pour la calibration de capteurs.
11. Divers : comprend tous les autres matériaux (cendres, produits chimiques, verre, caoutchouc, textiles, ainsi que les matériaux ne disposant pas de métadonnées suffisantes pour permettre une catégorisation selon leur composition)

Au total, 2036 échantillons de signature spectrale sont pertinents et leur répartition selon les différentes classes de matériaux est visible à la Figure 50.




FIGURE 50 – Nombre d'échantillons par classe et par bibliothèque (Salcido & Laefer, 2024).

On remarque qu'il n'existe pas de matériaux présents dans toutes les bibliothèques et qu'il n'existe pas de bibliothèque reprenant tous les types de matériaux. De plus,

il existe des déséquilibres dans la répartition des données : le bois, la céramique, le métal et le plastique ont chacun moins de 100 échantillons dans l'ensemble des 11 bibliothèques. À l'inverse, les matériaux cimentaires et l'asphalte ont respectivement 241 et 284 échantillons. Ces sous-représentations de certaines classes de matériaux présentent un défi au vu de la variabilité intra-classe qu'il peut y avoir que ce soit au niveau intra-matériau (composition, couleur, conditions et texture) ou extra-matériau (lieu, conditions d'illuminations, ...) comme illustré à la Figure 51 (Salcido & Laefer, 2024). Selon Salcido & Laefer (2024), cette variabilité intra-classe rend souvent les bibliothèques inadéquates pour les pratiques courantes d'identification des matériaux. De plus, il est difficile de comparer des données captées par des capteurs différents (Salcido & Laefer, 2024). Néanmoins, on note Ilehag et al. (2017) qui classifient avec succès des matériaux de construction sur base de la bibliothèque SBUSL et de leur propre jeu de données. Ilehag et al. (2020) quant à eux se basent sur la bibliothèque KLUM pour classifier des matériaux urbains.




FIGURE 51 – « Signatures spectrales représentatives d'asphalte routier issues de 8 des 11 bibliothèques spectrales en libre accès, illustrant les variations des plages d'échantillonnage et des résolutions (Salcido & Laefer, 2024).

Par ailleurs, aucune standardisation des métadonnées n'existe actuellement pour les bibliothèques hyperspectrales, et celles-ci présentent une grande hétérogénéité dans la manière dont les informations sont structurées et documentées. Cette absence d'uniformité complique fortement les comparaisons directes entre les bibliothèques et limite leur interopérabilité (Salcido & Laefer, 2024).

C Carte du nombre d'images superposées pour l'acquisition multispectrale

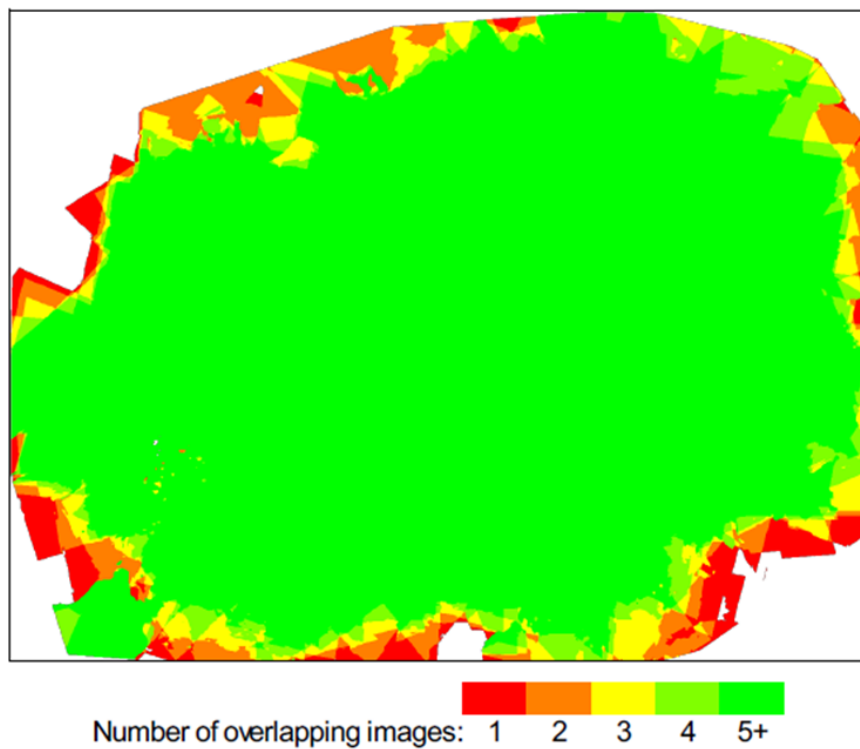


FIGURE 52 – Carte du nombre d'images superposées pour l'acquisition multispectrale

D Détails de la méthodologie pour les orthophotos 2023

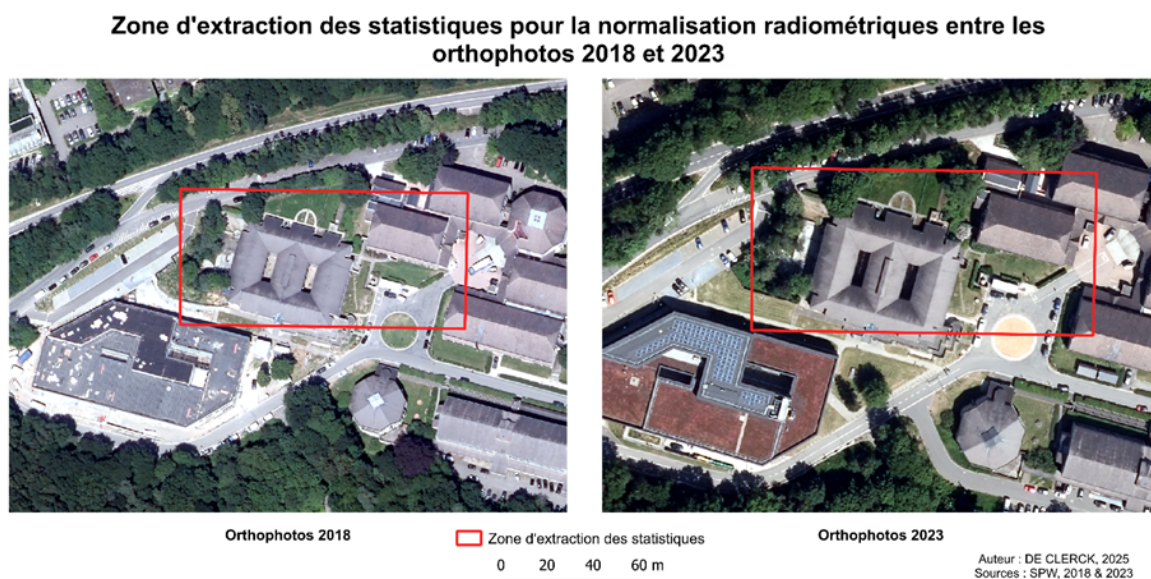


FIGURE 53 – Zone d'extraction des statistiques pour la normalisation radiométrique entre les orthophotos 2018 et 2023.

De façon similaire à ce qui a été fait pour les données drone, la moyenne du bâtiment du haut a été calculée de façon à vérifier que la normalisation radiométrique entre les deux rasters produit des résultats cohérents (voir Tableau 9).

TABLEAU 9 – Moyennes des bandes spectrales pour les orthophotos de 2018 normalisées radiométriquement et les orthophotos 2023.

Bande	Orthophotos 2018	Orthophotos 2023
R	35 840	36 435
G	35 399	35 832
B	37 798	37 843
NIR	21 573	23 580

Des zones ombragées ont été sélectionnées manuellement de façon à déterminer visuellement la limite de l'indice BAI pour considérer qu'un pixel est ombragé ou non (voir Figure 54).

Extraction du BAI de zones ombragées pour les orthophotos 2023




FIGURE 54 – Zones d'extraction du BAI de zones ombragées pour les orthophotos 2023.

La limite est alors finalement fixée visuellement à $1,3 \times 10^{-9}$ (voir Figure 55).




FIGURE 55 – Détermination visuelle de la limite de l'indice BAI des pixels ombragés des orthophotos 2023.

Un masque d'ombres est finalement produit pour les orthophotos 2023 (voir Figure 56).

Masque d'ombres pour les orthophotos 2023




FIGURE 56 – Masque d'ombres calculé pour les orthophotos 2023.

E Matrice de confusion - RF - RGB + NIR + ombres + textures

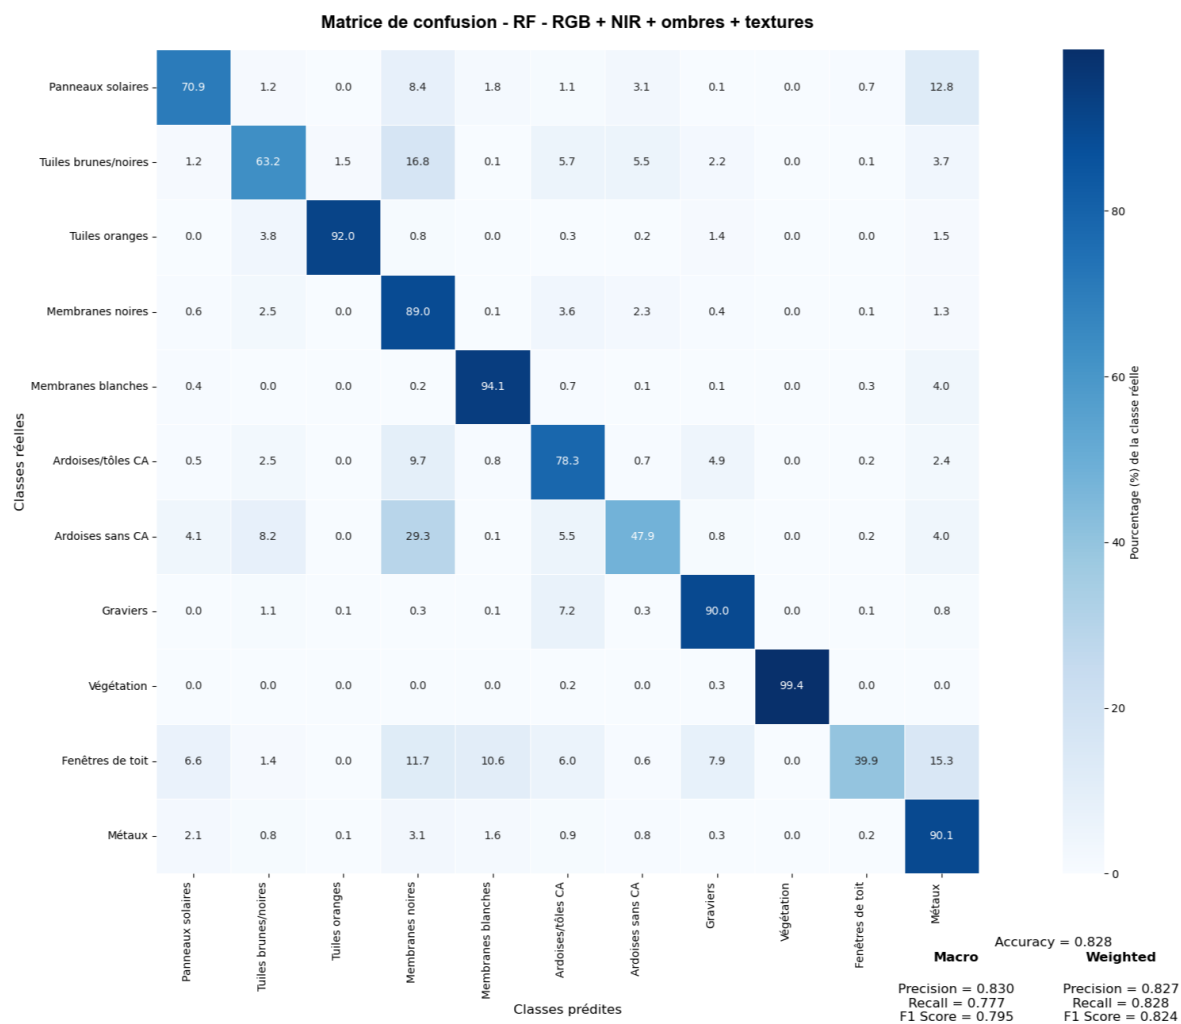


FIGURE 57 – Matrice de confusion du modèle RF - RGB + NIR + ombres + textures.

F Matrice de confusion - RF - RGB + NIR + ombres + textures + pentes

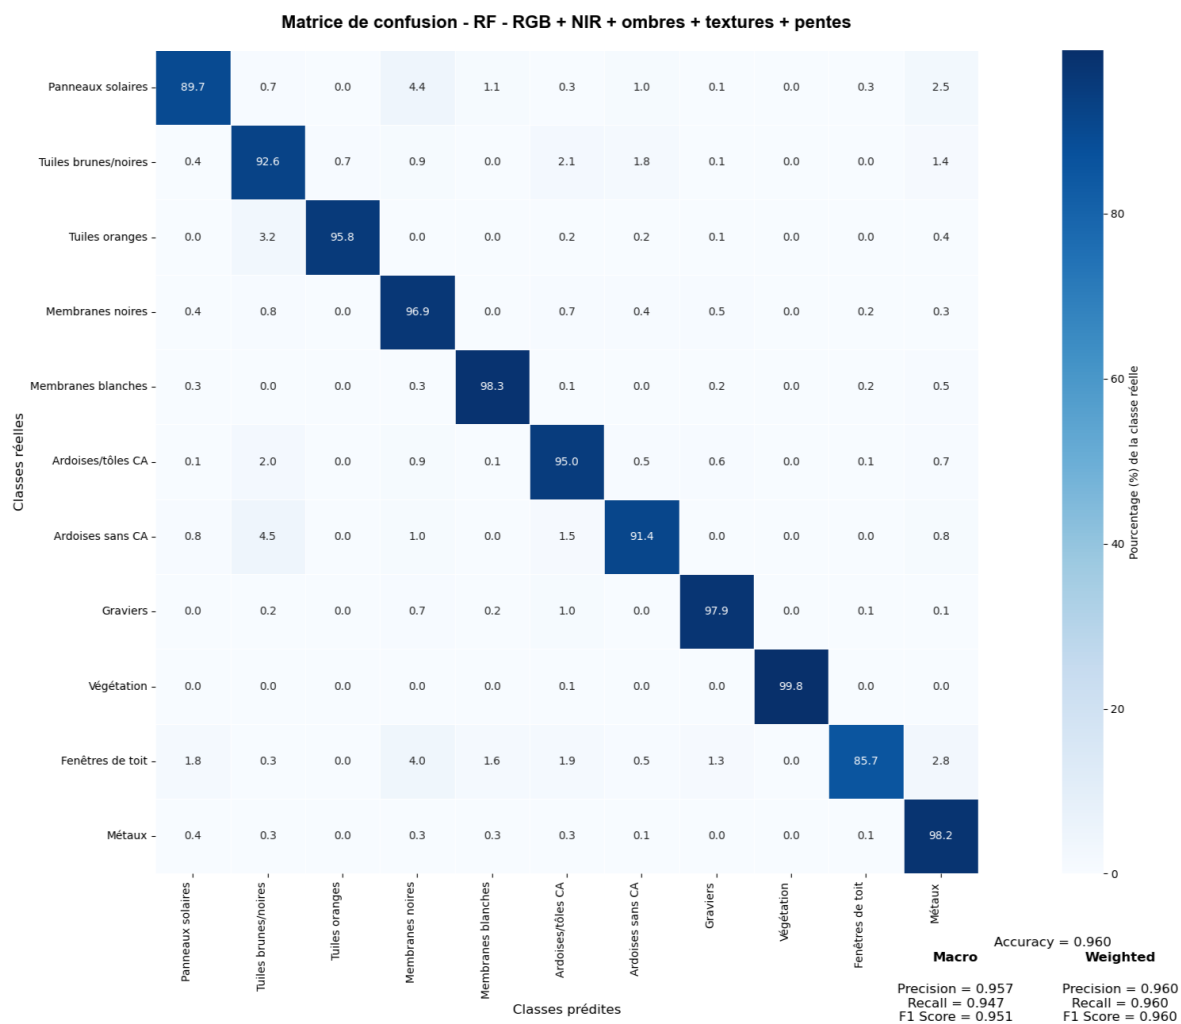


FIGURE 58 – Matrice de confusion du modèle RF - RGB + NIR + ombres + textures + pentes.

G Matrice de confusion - SVM - RGB + NIR + ombres




FIGURE 59 – Matrice de confusion du modèle SVM - RGB + NIR + ombres.

H Matrice de confusion - SVM - RGB + NIR + ombres + textures




FIGURE 60 – Matrice de confusion du modèle SVM - RGB + NIR + ombres + textures.

I Matrice de confusion - SVM - RGB + NIR + ombres + pentes + pentes

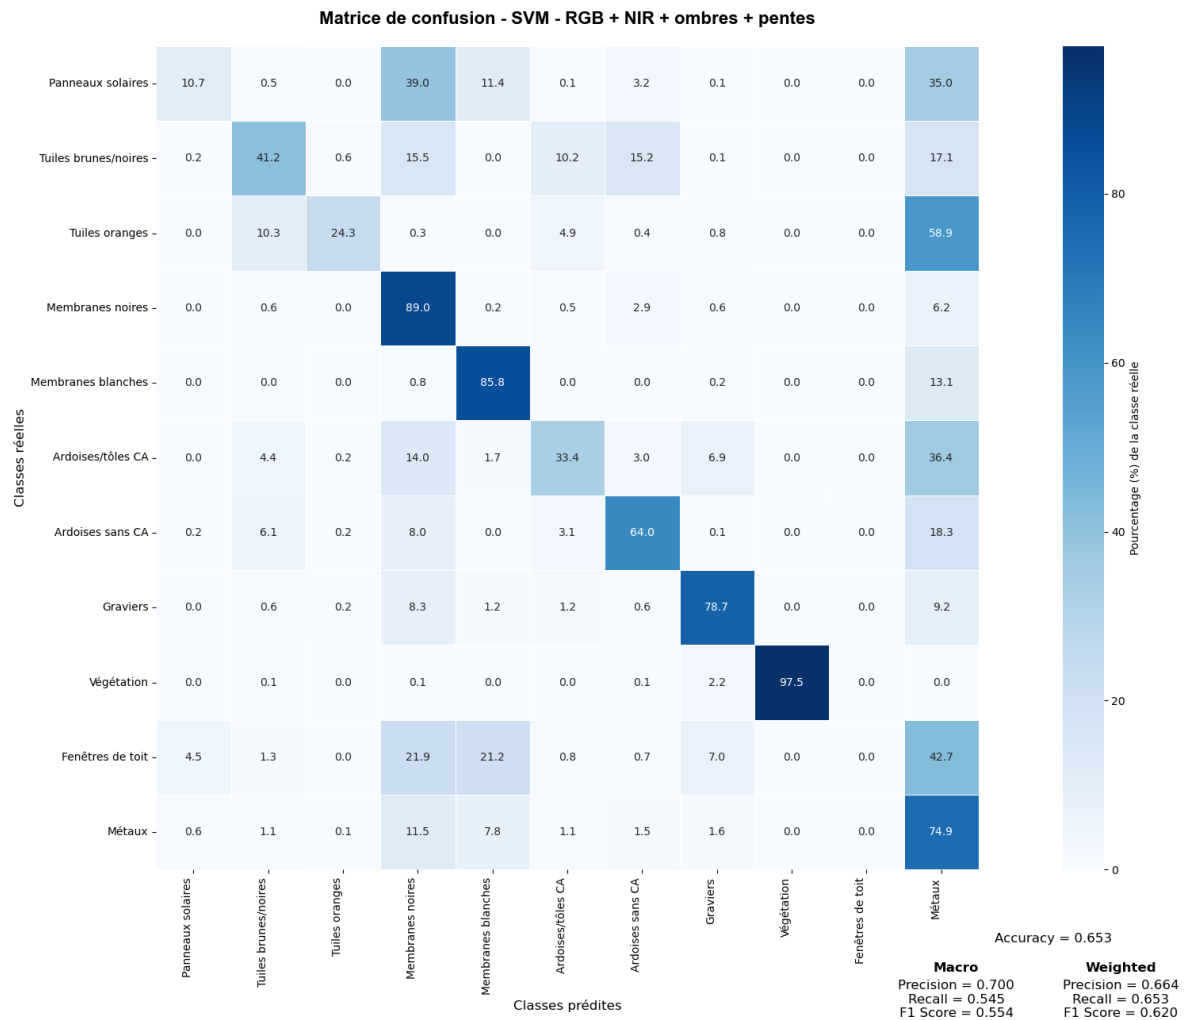


FIGURE 61 – Matrice de confusion du modèle SVM - RGB + NIR + ombres + pentes.

J Matrice de confusion - SVM - RGB + NIR + ombres + textures + pentes




FIGURE 62 – Matrice de confusion du modèle SVM - RGB + NIR + ombres + textures + pentes.