

Faculté des bioingénieurs

# Discrimination des peuplements forestiers en Forêt de Soignes : Apports des images hyperspectrales PRISMA et EnMAP

|                  |                                            |
|------------------|--------------------------------------------|
| Auteur           | Cédric Peten                               |
| Promoteur        | Pierre Defourny (SST/ELI/ )                |
| Lecteurs         | Julien Radoux (SST/ELI/ )<br>Hugues Titeux |
| Année Académique | 2024 - 2025                                |

Mémoire de fin d'études présenté en vue de l'obtention du diplôme de Bioingénieur en Sciences et technologies de l'environnement



---

# Remerciements

Je tiens à exprimer ma profonde gratitude à mon promoteur de mémoire, le Professeur Pierre Defourny, pour ses précieux conseils, son encadrement éclairé et son soutien tout au long de l'élaboration de ce mémoire de master.

J'adresse mes remerciements les plus chaleureux à Maxime Troiani pour sa collaboration et les nombreuses discussions constructives que nous avons partagées, lesquelles ont joué un rôle déterminant dans l'avancement de ce travail.

Je suis également particulièrement reconnaissant envers ma famille pour son soutien indéfectible et ses encouragements constants, qui m'ont accompagné tout au long de ce parcours académique.

Je souhaite aussi remercier l'ensemble de mes proches qui m'ont soutenu durant cette aventure universitaire, et plus particulièrement mes co-mémorants, dont la collaboration et les échanges ont contribué à tirer le meilleur de moi-même dans le cadre de ce projet.

Enfin, je tiens à exprimer ma gratitude envers les lecteurs de ce mémoire, M. Hugues Titeux et M. Julien Radoux, pour le temps et l'attention qu'ils ont consacrés à sa lecture et à son évaluation. J'espère que vous trouverez cet écrit aussi enrichissant et captivant que l'a été son processus de réalisation.

---

# TABLE DES MATIÈRES

|          |                                                                                                   |           |
|----------|---------------------------------------------------------------------------------------------------|-----------|
| <b>1</b> | <b>Introduction &amp; contexte</b>                                                                | <b>1</b>  |
| <b>2</b> | <b>Zone d'étude</b>                                                                               | <b>2</b>  |
| 2.1      | La Forêt de Soignes . . . . .                                                                     | 2         |
| 2.1.1    | Identité de la forêt . . . . .                                                                    | 2         |
| 2.1.2    | Historique forestier . . . . .                                                                    | 3         |
| 2.1.3    | Description abiotique . . . . .                                                                   | 4         |
| 2.1.4    | Description des essences forestières . . . . .                                                    | 6         |
| 2.1.5    | Gestion et enjeux . . . . .                                                                       | 7         |
| <b>3</b> | <b>État de l'art</b>                                                                              | <b>9</b>  |
| 3.1      | Téledétection . . . . .                                                                           | 9         |
| 3.1.1    | Types de téledétection . . . . .                                                                  | 10        |
| 3.1.2    | Caractéristiques des capteurs . . . . .                                                           | 11        |
| 3.1.3    | Vue d'ensemble des capteurs hyperspectraux . . . . .                                              | 13        |
| 3.1.4    | Avantages et limites des données HRS satellite . . . . .                                          | 14        |
| 3.2      | Applications forestières . . . . .                                                                | 16        |
| 3.2.1    | La reconnaissance d'essences forestières développée à partir de données multispectrales . . . . . | 17        |
| 3.2.2    | La reconnaissance d'essences forestières développée à partir de données hyperspectrales . . . . . | 18        |
| 3.3      | Conclusion . . . . .                                                                              | 25        |
| <b>4</b> | <b>Objectifs et hypothèses</b>                                                                    | <b>26</b> |
| <b>5</b> | <b>Matériel et Méthode</b>                                                                        | <b>27</b> |
| 5.1      | Données satellites . . . . .                                                                      | 28        |
| 5.1.1    | Satellites EnMAP, PRISMA et Sentinel-2 . . . . .                                                  | 28        |
| 5.1.2    | Choix des images . . . . .                                                                        | 29        |
| 5.1.3    | Traitement des images . . . . .                                                                   | 32        |

|          |                                                                              |           |
|----------|------------------------------------------------------------------------------|-----------|
| 5.2      | Données de terrain . . . . .                                                 | 35        |
| 5.2.1    | Sélection des peuplements homogènes . . . . .                                | 37        |
| 5.2.2    | Variation du nombre de classes et quantité de données disponibles . . . . .  | 40        |
| 5.3      | Modèle de classification . . . . .                                           | 41        |
| 5.3.1    | Calibration du modèle . . . . .                                              | 41        |
| 5.3.2    | Évaluation de l'importance des bandes spectrales . . . . .                   | 41        |
| 5.3.3    | Validation du modèle . . . . .                                               | 42        |
| <b>6</b> | <b>Résultats</b>                                                             | <b>45</b> |
| 6.1      | Périodes d'acquisition et signatures spectrales . . . . .                    | 45        |
| 6.1.1    | Phase de dormance hivernale du mélèze . . . . .                              | 46        |
| 6.1.2    | Phase de dormance hivernale du hêtre . . . . .                               | 47        |
| 6.1.3    | Période de production végétale maximale (NDVI maximale) . . . . .            | 50        |
| 6.1.4    | Phase de sénescence . . . . .                                                | 51        |
| 6.1.5    | Comparaison des spectres selon les dates d'acquisition des données . . . . . | 53        |
| 6.2      | Nombre de classes et quantité de données disponibles . . . . .               | 54        |
| 6.3      | Combinaison de plusieurs dates d'acquisition . . . . .                       | 56        |
| 6.4      | Résultats obtenus sur base de données multispectrales . . . . .              | 59        |
| <b>7</b> | <b>Discussion</b>                                                            | <b>62</b> |
| 7.1      | Périodes d'acquisition . . . . .                                             | 62        |
| 7.2      | Comparaison du nombre de classe . . . . .                                    | 65        |
| 7.3      | Comparaison de la combinaison d'images . . . . .                             | 66        |
| 7.4      | Comparaison des résultats obtenus a partir d'images HRS et MS . . . . .      | 67        |
| <b>8</b> | <b>Conclusion</b>                                                            | <b>70</b> |
|          | Bibliographie . . . . .                                                      | 72        |
|          | Infographie . . . . .                                                        | 75        |
|          | <b>Annexe</b> . . . . .                                                      | <b>78</b> |
| A        | Composition de la futaie en Forêt de Soignes bruxelloise . . . . .           | 78        |
| B        | Représentation des peuplements d'arbres étudiés en Forêt de Soignes. . . . . | 80        |
| C        | Classification : 2021/03/29 - PRISMA - Combinaison A . . . . .               | 81        |
| D        | Classification : 2022/03/11 - PRISMA - Combinaison A . . . . .               | 82        |
| E        | Classification : 2022/04/21 - PRISMA - Combinaison A . . . . .               | 83        |
| F        | Classification : 2022/03/11 & 2022/04/21 - PRISMA - Combinaison A . . . . .  | 84        |
| G        | Classification : 2023/06/24 - PRISMA - Combinaison A . . . . .               | 85        |
| H        | Classification : 2023/04/21 - EnMAP - Combinaison A . . . . .                | 86        |
| I        | Classification : 2023/05/03 - EnMAP - Combinaison A . . . . .                | 87        |
| J        | Classification : 2023/04/21 & 2023/05/03 - EnMAP - Combinaison A . . . . .   | 88        |
| K        | Classification : 2022/04/21 - PRISMA - Combinaison B . . . . .               | 89        |
| L        | Classification : 2023/05/03 - EnMAP - Combinaison B . . . . .                | 90        |
| M        | Classification : 2022/04/21 - PRISMA - Combinaison C . . . . .               | 91        |
| N        | Classification : 2023/05/03 - EnMAP - Combinaison C . . . . .                | 92        |

|   |                                                                                                             |    |
|---|-------------------------------------------------------------------------------------------------------------|----|
| O | Pouvoir de discrimination des bandes spectrales dans la classification des peuplements forestiers . . . . . | 93 |
|---|-------------------------------------------------------------------------------------------------------------|----|

---

# TABLE DES FIGURES

|      |                                                                                                                                                                                                                               |    |
|------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| 2.1  | Carte représentant la Forêt de Soignes bruxelloise. . . . .                                                                                                                                                                   | 3  |
| 2.2  | Carte topographique de la Forêt de Soignes. . . . .                                                                                                                                                                           | 5  |
| 2.3  | Coupe géologique N-S à travers la Forêt de Soignes. (Stéphane et al., 2003) . . . . .                                                                                                                                         | 5  |
| 3.1  | Spectre électromagnétique. (Passy, 2021) . . . . .                                                                                                                                                                            | 10 |
| 3.2  | Différence entre capteur actif et passif utilisé en télédétection. (Tempfli et al. (2009))                                                                                                                                    | 11 |
| 3.3  | Types de capteurs utilisés en télédétection en fonction de la gamme de longueur d’onde<br>détectée. (Source : Tempfli et al., 2009) . . . . .                                                                                 | 12 |
| 3.4  | Comparaison entre les données MS et HRS. (Source : Feng et al., 2020) . . . . .                                                                                                                                               | 12 |
| 3.5  | Signature spectrale utilisée comme référence d’analyse mixte de données AVIRIS . . .                                                                                                                                          | 17 |
| 5.1  | Synthèse de la méthode appliquée . . . . .                                                                                                                                                                                    | 27 |
| 5.2  | Tuiles acquises par les capteurs EnMAP et PRISMA . . . . .                                                                                                                                                                    | 29 |
| 5.3  | Représentation des valeurs NDVI et des sites d’entraînement à la date du 25 avril 2021<br>(Copernicus, 2024). . . . .                                                                                                         | 30 |
| 5.4  | Détection des nuages sur une image PRISMA obtenue le 21/04/2021 avec en rouge les<br>nuages détectés. . . . .                                                                                                                 | 33 |
| 5.5  | Représentation des modifications effectuées au spectre (Image PRISMA : 23/07/2021)                                                                                                                                            | 34 |
| 5.6  | Dataset 1 : Shapefile de polygones comprenant les informations d’occupation des sols                                                                                                                                          | 35 |
| 5.7  | Dataset 2 : Shapefile de points représentant l’inventaire permanent forestier mis à jour<br>le 13 mai 2024. . . . .                                                                                                           | 36 |
| 5.8  | Dataset 3 : Shapefile de points représentant l’inventaire des arbres objectifs déterminé<br>par les gestionnaires, Bruxelles Environment. . . . .                                                                             | 37 |
| 5.9  | Représentation du nombre de pixels obtenus par classe et par méthode . . . . .                                                                                                                                                | 38 |
| 5.10 | Parcelles de peuplements forestiers homogènes. . . . .                                                                                                                                                                        | 39 |
| 6.1  | Signature spectrale moyenne et lissée des peuplements forestiers obtenue sur la base<br>des valeurs absolues de réflectance des pixels inclus dans les polygones de peuplements<br>homogènes. (PRISMA : 29/03/2021) . . . . . | 47 |

|     |                                                                                                                                                                                                                                                                                                             |    |
|-----|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| 6.2 | Signature spectrale moyenne et lissée des peuplements forestiers obtenue sur la base des valeurs absolues de réflectance des pixels inclus dans les polygones de peuplements homogènes. (PRISMA : 21/04/2022) . . . . .                                                                                     | 48 |
| 6.3 | Signature spectrale moyenne et lissée des peuplements forestiers obtenue sur la base des valeurs absolues de réflectance des pixels inclus dans les polygones de peuplements homogènes. (EnMAP, Annexe H : 21/04/2023 et Annexe I : 03/05/2023) . . . . .                                                   | 49 |
| 6.4 | Signature spectrale moyenne et lissée des peuplements forestiers obtenue sur la base des valeurs absolues de réflectance des pixels inclus dans les polygones de peuplements homogènes. (PRISMA : 24/06/2023) . . . . .                                                                                     | 51 |
| 6.5 | Signature spectrale moyenne et lissée des peuplements forestiers obtenue sur la base des valeurs absolues de réflectance des pixels inclus dans les polygones de peuplements homogènes. (PRISMA : 10/11/2021) . . . . .                                                                                     | 52 |
| 6.6 | Signature spectrale moyenne et lissée des peuplements forestiers étudié sur base des images PRISMA. Phase de dormance hivernale du mélèze : 29/03/2021, Phase de dormance hivernale du hêtre : 21/04/2022, Période de production végétale maximale : 24/06/2023, Phase de sénescence : 10/11/2021 . . . . . | 53 |
| 6.7 | Prédiction des peuplements forestiers sur l'ensemble du site d'étude sur base de la combinaison des données EnMAP acquise les 21 avril et 3 mai 2023. . . . .                                                                                                                                               | 58 |
| 6.8 | Prédiction des peuplements forestiers sur l'ensemble du site d'étude sur base des données Sentinel-2 acquises le 20 avril 2022 . . . . .                                                                                                                                                                    | 61 |
| 7.1 | Étude de cas (EnMAP : 03/05/2023) . . . . .                                                                                                                                                                                                                                                                 | 63 |
| 7.2 | Importance des variables pendant le processus de classification des peuplements forestiers.                                                                                                                                                                                                                 | 65 |
| 7.3 | F1-scores en fonction des combinaisons de classes. . . . .                                                                                                                                                                                                                                                  | 66 |
| 7.4 | Représentation des F1-scores obtenu sur base d'images EnMAP combinées. . . . .                                                                                                                                                                                                                              | 67 |
| 7.5 | Représentation du F1-score obtenu pour chaque classe en fonction de la période phénologique. . . . .                                                                                                                                                                                                        | 67 |

---

# LISTE DES TABLEAUX

|     |                                                                                                                                                              |    |
|-----|--------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| 2.1 | Principales essences d'arbres et leur taux de composition de la Forêt de Soignes. . . .                                                                      | 7  |
| 3.1 | Principaux capteurs hyperspectraux sur satellite et leurs caractéristiques . . . . .                                                                         | 14 |
| 3.2 | Comparaison des principales études sur la classification des espèces forestières par imagerie hyperspectrale provenant de satellite . . . . .                | 22 |
| 5.1 | Comparaison des caractéristiques des capteurs EnMAP et PRISMA. (Sources : CEOS (2024) ; Segl et al. (2012)) . . . . .                                        | 28 |
| 5.2 | Dates des images disponibles et les différents stades phénologiques observables correspondant. . . . .                                                       | 31 |
| 5.3 | Date d'acquisition des images utilisées dans cette étude. . . . .                                                                                            | 31 |
| 5.4 | Avantage et inconvénient des méthodes de sélection de pixels homogène . . . . .                                                                              | 39 |
| 5.5 | Répartition du nombre de pixels dans chaque classe en fonction de la combinaison des données appliquées. . . . .                                             | 40 |
| 5.6 | Valeur des hyperparamètres testés lors de la validation croisée imbriquée. . . . .                                                                           | 41 |
| 5.7 | Tableau des métriques de performance de la classification par classe avec i le nombre de classe . . . . .                                                    | 43 |
| 6.1 | Nombre de pixels utilisés pour calculer les spectres moyens de chaque peuplement étudié.                                                                     | 46 |
| 6.2 | Mesures de performance des différentes classes de peuplements forestiers (EnMAP : 2023/05/03) . . . . .                                                      | 49 |
| 6.3 | Matrice de confusion (EnMAP 21/04/2021) . . . . .                                                                                                            | 50 |
| 6.4 | F1-score et Support pour différentes combinaisons et classes à partir de l'image PRISMA acquise le 21/04/2022. . . . .                                       | 55 |
| 6.5 | Comparaison des performances de classification des différentes combinaisons et classes à partir de l'image EnMAP acquise le 03/05/2023. . . . .              | 56 |
| 6.6 | Scores F1 obtenus à partir des classifications des images EnMAP acquises les 21 avril et 3 mai 2023, traitées individuellement ou en combinaison. . . . .    | 57 |
| 6.7 | Scores F1 obtenus à partir des classifications des images PRISMA acquises les 11 mars et 21 avril 2022, traitées individuellement ou en combinaison. . . . . | 59 |

|     |                                                                                                                                            |    |
|-----|--------------------------------------------------------------------------------------------------------------------------------------------|----|
| 6.8 | Mesures de performance des différentes classes de peuplements forestiers (Sentinel-2 : 20/04/2022).                                        | 60 |
| 6.9 | Matrice de confusion issus de la classification sur base des données Sentinel-2.                                                           | 60 |
| 7.1 | Score f1 obtenus sur base des classifications faites lors des différentes stades phénologiques                                             | 64 |
| 7.2 | F1-score et Support obtenus à partir des classifications faites sur base des données hyperspectrales PRISMA et multispectrales Sentinel-2. | 68 |

# Liste des acronymes

- LiDAR : Light Detection and Ranging
- SAR : Synthetic Aperture Radar
- HRS : Hyperspectrale
- MS : Multispectrale
- EnMAP : Environmental Mapping and Analysis Program
- AVIRIS : Airborne Visible/Infrared Imaging Spectrometer
- CHRIS : Compact High Resolution Imaging Spectrometer
- DESIS : DLR Earth Sensing Imaging Spectrometer
- NDVI : Normalized difference vegetation index
- RSB : Rapport Signal/Bruit
- SWIR : Ondes courtes infrarouge
- VNIR : Ondes visibles et proche infrarouge
- TIR : Ondes infrarouge thermiques
- MFT : Fonction de Transfert de Modulation
- SVM : Support Vector Machines
- RF : Random Forest
- CAT : CatBoost
- GBC : Gradient Boosting Classifier
- XGB : XGBoost
- ACP : Analyse en Composante Principales
- Bi : Bande spectral numéro i
- S2 : Sentinel-2

---

---

# CHAPITRE 1

---

## INTRODUCTION & CONTEXTE

La cartographie et la caractérisation précise des essences d'arbres dans les forêts sont essentielles pour la gestion durable et la recherche en sciences de l'environnement. La protection de la biodiversité, la gestion des espèces envahissantes et l'amélioration des pratiques de gestion forestière sont des enjeux stratégiques reconnus par les Nations Unies (2024), qui considèrent la diversité biologique comme un patrimoine commun à préserver pour les générations futures. La Forêt de Soignes, avec ses 4 384 hectares, constitue un exemple emblématique de hêtraie cathédrale en Belgique et joue un rôle écologique crucial dans un contexte de forte pression urbanistique.

Les changements climatiques accentuent les défis pour la conservation de la Forêt de Soignes. Les phénomènes météorologiques extrêmes, les sécheresses récurrentes et l'introduction d'espèces envahissantes (par exemple le chêne rouge d'Amérique) perturbent l'équilibre de cet écosystème. Les hêtres, représentant plus de 64 % de la composition de la forêt, sont particulièrement vulnérables aux stress hydriques accrus et aux violentes tempêtes qui amplifient le risque de chablis (Monbaliu et al., 2003). En Forêt de Soignes, les sols caractérisés par la présence de Fragipan limitent le développement racinaire et augmentent l'instabilité des arbres. Dans ce contexte, un inventaire forestier rigoureux est un excellent outil d'aide à la gestion. Cela peut être fait par l'utilisation de la télédétection. Goetz et al. (1985) ; Monbaliu et al. (2003) ainsi que Shrestha et al. (2021) mentionnent dans leurs travaux que les données hyperspectrales permettent d'identifier les espèces et d'évaluer l'état de santé des arbres. Des initiatives locales et internationales, comme le programme de reforestation au Canada (Mike (2013)), utilisent ces données pour planifier des interventions ciblées et améliorer la résilience des forêts.

En utilisant les données issues de la télédétection, ce projet vise à améliorer la cartographie des essences forestières dans la Forêt de Soignes, afin de mieux comprendre les dynamiques écologiques et d'optimiser les pratiques de gestion. Les résultats attendus ont comme objectif de contribuer au développement de méthodologies applicables à d'autres régions forestières soumises à des pressions environnementales similaires.

---

---

# CHAPITRE 2

---

## ZONE D'ÉTUDE

### 2.1 La Forêt de Soignes

La Forêt de Soignes est l'une des principales forêts belges. Remarquable pour sa riche histoire et son taux de conservation exceptionnel, elle joue un rôle essentiel dans les paysages Bruxellois et Brabançons où elle représente une utilité publique. Avec ses 4 384 hectares boisés, elle s'étend sur trois régions : Bruxelles, la Flandre et la Wallonie. Sa situation géographique et la spéculation foncière lui font subir une forte pression urbaine. La Forêt de Soignes subit une forte affluence du fait de sa proximité avec des zones à forte densité de population. Les variations climatiques affectent cet écosystème stable, façonné par une longue histoire. Pour ces raisons, la Forêt de Soignes bruxelloise avec ses lisières et ses domaines boisés avoisinants constituent aujourd'hui une « Zone Spéciale de Conservation » (ZSC) reconnue par l'Europe. De manière à garantir une gestion cohérente sur l'ensemble du massif soinién intégré au réseau Natura 2000, un plan directeur appelé « Schéma de Structure » vise depuis 2008 un cadre commun aux trois régions gestionnaires (Stéphane et al., 2003, p.12).

#### 2.1.1 Identité de la forêt

La Forêt de Soignes est une forêt périurbaine située au Sud-Est de Bruxelles et s'étend sur les trois régions belges selon les proportions suivantes : 37,7 % en Région de Bruxelles-Capitale, 56 % en Région flamande et 6,3 % en Région wallonne (Stéphane et al., 2003, p.15). Du fait que les données utilisées dans cette étude portent uniquement sur la zone bruxelloise, seule cette partie de la Forêt de Soignes y sera développée. La Forêt de Soignes bruxelloise couvre une superficie de 1.659 ha et se répartit comme suit entre différentes communes ( Carte 2.1 ) :

- Uccle : 508 ha (31 %)
- Watermael-Boitsfort : 747 ha (45 %)
- Auderghem : 344 ha (21 %)
- Woluwe-Saint-Pierre : 60 ha (4 %)

Au niveau du Plan Régional d’Affectation (“PRAS - Plan Régional d’Affectation du Sol”, 2001), l’ensemble de la Forêt de Soignes bruxelloise est située en zone forestière. Elle est propriété de la Région de Bruxelles-Capitale qui a confié sa gestion à Bruxelles Environnement. Bruxelles Environnement est un organisme d’intérêt public placé sous l’autorité du Ministre chargé de la compétence « Environnement » (Stéphane et al., 2003, p.26).

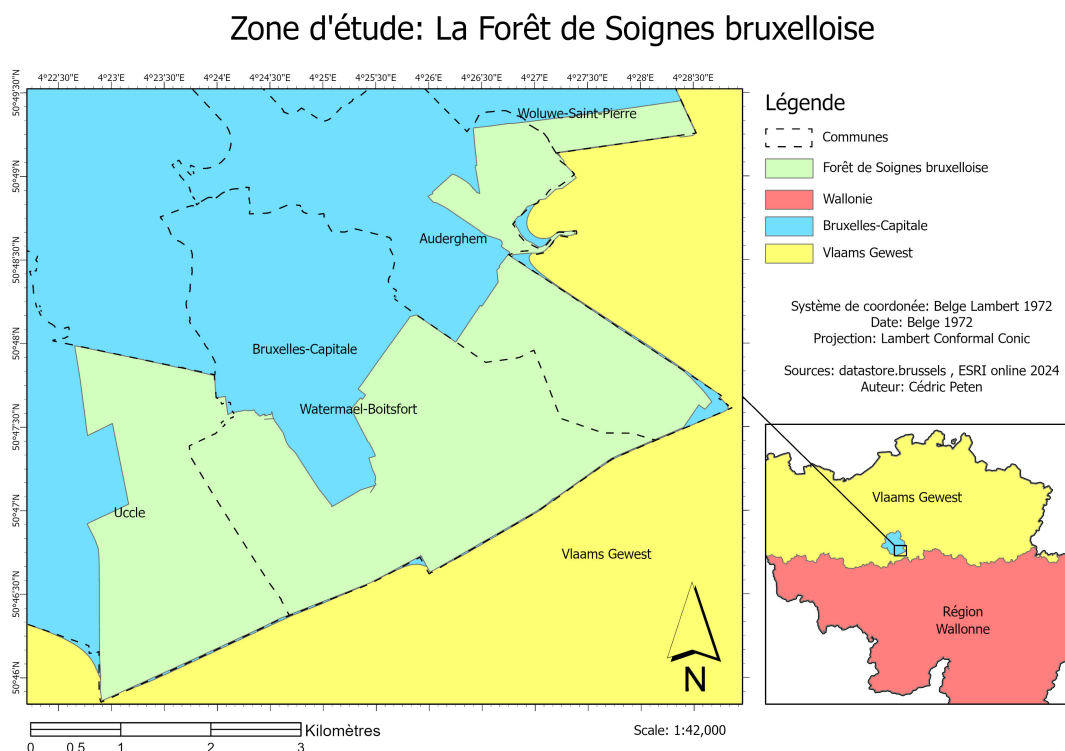


Figure 2.1 – Carte représentant la Forêt de Soignes bruxelloise.

### 2.1.2 Historique forestier

La Forêt de Soignes s’est formée à la fin de la dernière glaciation, il y a 12 000 ans, à partir d’une toundra constituée de mousses, de lichens et de bruyères (Frederik et al., 2017). Après le retrait des glaciers, la végétation s’est progressivement installée dans la région. Les premiers arbres à coloniser la zone étaient des bouleaux, des pins et des saules, espèces pionnières adaptées aux conditions froides et sèches de l’époque. Suite au réchauffement du climat, différentes essences forestières se sont imposées en Forêt de Soignes durant l’Antiquité et le Moyen Âge. Elles ont mené à la formation d’une chênaie-charmée<sup>1</sup> (Pierron, 1905). Le hêtre était alors déjà présent, mais c’est seulement à partir du XVI<sup>e</sup> siècle qu’il a pris le dessus sur les autres espèces végétales. Aujourd’hui, le hêtre constitue 65 % de la surface de la Forêt. Le reste de cette surface est encore constitué en majorité de chênes et de charmes.

L’histoire de la Forêt de Soignes est marquée par de nombreux changements dus aux évolutions sociales. Se situant dans une région à forte activité humaine, la Forêt de Soignes a subi de nombreux impacts visibles par des vestiges datant de 5 000 ans. Ces impacts sont dus à des activités telles que

1. Une forêt chênaie-charmée est une formation végétale composée principalement de chêne pédonculé et/ou sessile et accompagnée de l’érable et du charme (Jacquemart, 2024).

la combustion de bois en charbon de bois et le défrichement d'une grande partie de la forêt à des fins de production de bois. Au début du XVIII<sup>e</sup> siècle, seule la partie appartenant aux ducs du Brabant fut préservée en raison de son usage pour la chasse. À la fin du XVIII<sup>e</sup> siècle, une campagne de restauration a été lancée pour réparer les dommages causés par l'activité humaine. Le hêtre fut choisi comme essence principale pour redonner à la forêt son apparence d'origine. Des centaines d'hectares de terres majoritairement en friche furent ainsi reboisés, accentuant la prédominance actuelle du hêtre.

Au XVIII<sup>e</sup> siècle, la Forêt de Soignes couvrait encore 12 000 hectares. Aujourd'hui, ayant perdu près des deux tiers de sa superficie, elle s'étend sur seulement 4 384 hectares. Cette réduction est majoritairement due à la privatisation de soixante pour cent du domaine après l'indépendance de la Belgique en 1830. Les nouveaux propriétaires exploitèrent intensivement leurs terres à des fins agricoles, contribuant à la diminution de la surface forestière. À partir de 1843, l'État belge entreprit de racheter progressivement la forêt et en confia la gestion à l'Administration des Eaux et Forêts. En 1983, lors de la régionalisation de la Belgique, la gestion de la Forêt de Soignes a été répartie entre les trois régions du pays.

Les parcelles de hêtres, initialement destinées à l'abattage une fois les arbres centenaires, furent maintenues plus longtemps et éclaircies, conférant à la forêt son aspect actuel de cathédrale. Aujourd'hui, ces arbres ont entre 170 et 220 ans. De nos jours, le développement urbain, particulièrement important en Région bruxelloise, accentue la pression anthropogénique sur cet environnement. La Forêt de Soignes est très fréquentée par des promeneurs, cavaliers et cyclistes, dont les activités ont un impact direct sur la couverture forestière et la composition des essences (Frederik et al., 2017) et (Stéphane et al., 2003, p.45).

### **2.1.3 Description abiotique**

#### **Topographie**

Le relief de la Forêt de Soignes s'est formé durant les périodes glaciaires et est pratiquement resté intact grâce à la présence permanente de la forêt. Cela a permis de réduire l'érosion des sols. La forêt se trouve sur un plateau situé entre les rivières de la Dyle et de la Senne, à une altitude variant entre 65 et 130 mètres au-dessus du niveau de la mer. Selon le modèle numérique de terrain fourni par Bruxelles Environnement, 71 % de la surface du massif est constitué de pentes faibles de moins de 5°. Cela permet de constater le relief relativement contrasté aux pentes parfois importantes qu'il y est possible d'observer. Cette topographie représentée à la figure 2.2, composée de petites collines et de vallées, contribue à la diversité des sols et habitats au sein de la forêt (Grossmann (2022)). Dans le reste de cette région limoneuse, la topographie vallonnée n'est plus observable, car elle a été nivelée par l'activité agricole, exploitant des conditions pédologiques favorables. La conservation des caractéristiques naturelles du terrain en Forêt de Soignes permet une étude continue des interactions entre le sol, la végétation et le relief.

## Topographie de la Forêt de Soignes bruxelloise

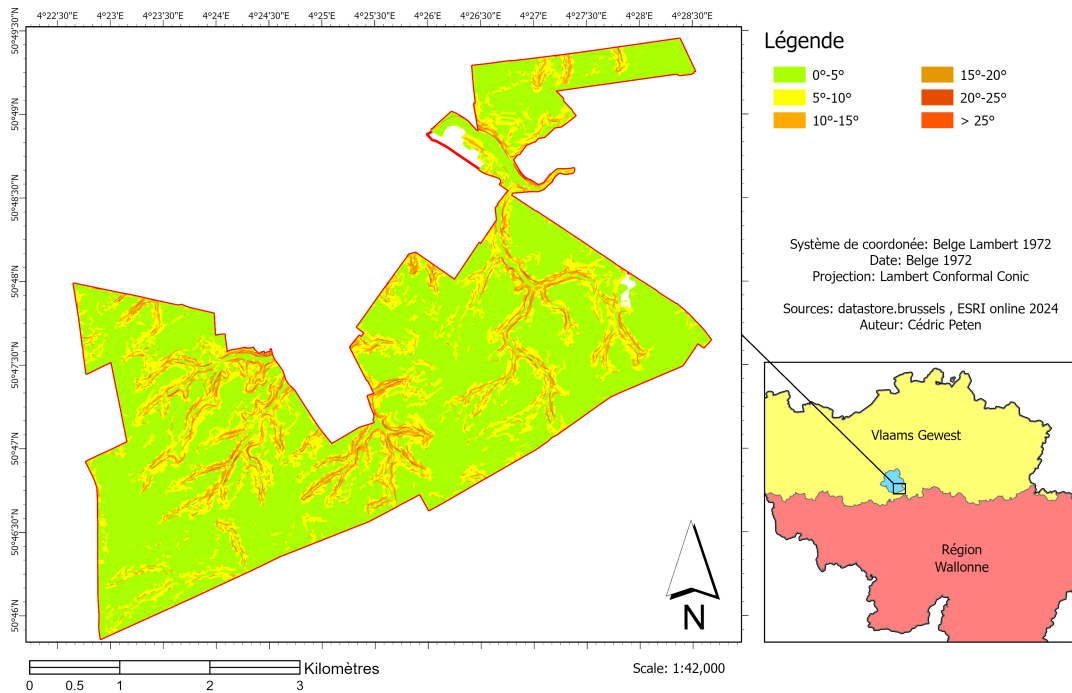


Figure 2.2 – Carte topographique de la Forêt de Soignes.

## Pédologie

La Forêt de Soignes s'étend sur l'extrémité d'un ancien banc marin. Les nombreuses transgressions marines du tertiaire ont déposé, sur le socle primaire, une succession de couches de sable et d'argile. Les sols y reposent donc principalement sur du sable appelé sable du Bruxellien, caractérisé par un sable grossier et la présence de grès. Au cours de l'ère quaternaire, un sol limoneux provenant du Löss est déposé par le vent, caractérisant les sols de surface acides et riches en calcaire (Pierron, 1905). Ce type de sol caractérise actuellement la majorité des sols soniens et favorise une flore acidophile, incluant des espèces telles que le Dryoptéris et la Luzule des bois (Jacquemart (2024)) (fig. 2.3).




Figure 2.3 – Coupe géologique N-S à travers la Forêt de Soignes. (Stéphane et al., 2003)

L'érosion des sols a induit une épaisseur du Löss qui varie en fonction de la topographie. La présence de sols limoneux est faible au sommet des collines, plus importante en fond de vallée et absente dans le lit des rivières. Par conséquent, la granulométrie des sols varient de sols sablo-limoneux à drainage naturel à sols limoneux avec un drainage naturel modéré ou imparfait. Les différences de proportions de sable mélangé au Loess en fonction de leur position topographique représentées à la figure 2.3 en sont l'origine. Il se peut qu'à certains endroits cette épaisseur fasse jusqu'à 15 m, ce qui correspond alors aux sols les plus riches du massif forestier.

#### 2.1.4 Description des essences forestières

Grâce à sa longue histoire et à son taux de conservation unique, la Forêt de Soignes a atteint le stade de climax<sup>2</sup>. Sous un climat atlantique, ce stade est caractérisé par la prédominance des hêtraies acidophile (Habitat européen 9120). Selon Nature (2021), ce type de formation végétale est dominé par le hêtre (*Fagus sylvatica*) et présente un sous-bois peu développé en raison de l'ombrage dense créé par la canopée arborescente. La structure particulière des vieilles hêtraies, avec leurs troncs élancés et leur voûte de feuillage, a souvent été comparée à celle des cathédrales, d'où l'appellation de « hêtraie cathédrale », un terme qui s'applique parfaitement à la Forêt de Soignes.

Une gestion visant à favoriser la biodiversité a permis l'introduction d'autres espèces dans la strate arbustive et la création de nouveaux habitats. En plus de la hêtraie acidophile, des chênaies pédonculées ou chênaies-charmaies sub-atlantiques (Habitat européen 9160) y sont observables. Ces peuplements comprennent principalement des chênes pédonculés (*Quercus robur*), parfois mélangés au chêne sessile (*Quercus petraea*) et du charme (*Carpinus betulus*). Il est également possible d'observer des chênaie-boulaie (Habitat européen 9190) qui se composent principalement de chêne pédonculé (*Quercus robur*), de bouleaux verruqueux (*Betula pendula*) et pubescent (*Betula pubescens*). Les peuplements de conifères occupent à peu près 7% de la superficie totale du massif forestier. Ceux-ci comprennent entre autres des plantations de mélèze (*Larix sp.*), de pin sylvestre (*Pinus sylvestris*), de pins noirs (*Pinus nigra*) et de sapin de Douglas (*Pseudotsuga menziesii*). La localisation de ces essences est directement liée aux caractéristiques pédologiques observées dans la zone, telles que mentionnées dans le point 2.1.3. Ces variations pédologiques justifient la présence de plusieurs formations végétales en Forêt de Soignes. Les sols sableux à drainage naturel favorisent la présence de conifères tels que le pin et le mélèze, alors que les sols à drainage modéré ou imparfait favorisent quant à eux la présence de chênes et de hêtres (Jacquemart, 2024).

La composition principale de la futaie en Forêt de Soignes est représentée dans le tableau 2.1. Ces données ont été récoltées en 2023 dans le cadre de travaux menés par l'Uliège (2023). L'annexe A, reprend quant à elle l'ensemble des essences observées par bruxelles environnement en Forêt de Soignes bruxelloise.

---

2. L'état de climax signifie que pour les conditions physico-chimiques et climatiques actuelles, la végétation est à son état final de succession écologique (FUTURA-SCIENCES, s. d.).

Table 2.1 – Principales essences d’arbres et leur taux de composition de la Forêt de Soignes.

| Essences d’arbre  | Taux de composition de la futaie (%) |
|-------------------|--------------------------------------|
| Hêtre             | 64                                   |
| Chênes indigènes  | 10                                   |
| Érable sycomore   | 4                                    |
| Pin sylvestre     | 4                                    |
| Mélèze            | 3                                    |
| Chêne pédonculé   | 3                                    |
| Bouleau           | 3                                    |
| Charme            | 2                                    |
| Pin noir de Corse | 1                                    |

### 2.1.5 Gestion et enjeux

Les recherches faites par Latte et al. (2015) ainsi que Stéphane et al. (2003) démontrent que l’environnement instable dans lequel évolue la Forêt de Soignes constitue un enjeu de taille pour sa conservation. Selon ces travaux, le vieillissement de la forêt, l’instabilité climatique et la compaction des sols sont les trois principaux facteurs responsables de l’instabilité de la forêt.

Premièrement, le vieillissement des hêtres rend les arbres plus vulnérables aux maladies et au risque de chablis. Leurs hauteurs élevées et la présence d’un sol difficilement accessible dû au Frangipan en sont les principales raisons. Le Frangipan est un limon densifié présent à une profondeur de 40 à 80 centimètres dans les sols qui entrave le développement racinaire des arbres. Cela augmente le risque de chablis du hêtre en cas de vents forts.

Ensuite, l’évolution croissante des températures induit par le changement climatique impacte fortement la croissance des hêtres. Une augmentation de la température moyenne de 3 à 4 °C entraîne une diminution de la vitalité des arbres et les rend plus susceptibles de souffrir lors des épisodes de sécheresse et de tempêtes Latte et al. (2015). Par ailleurs, la fréquence croissante des périodes de sécheresse raréfie les conditions propices au développement des hêtres. Les sécheresses répétées réduisent la disponibilité en eau, essentielle à la croissance et à la survie des hêtres, augmentant ainsi leur état de stress hydrique. Les phénomènes climatiques extrêmes comme les tempêtes et les canicules sont de plus en plus fréquents et intenses, provoquant des dommages directs aux arbres, y compris des pertes significatives de biomasse et un affaiblissement général de la forêt. Ces événements perturbent la structure de la forêt et diminuent sa capacité à se régénérer efficacement.

Enfin, la compression du sol de surface par le passage de chevaux d’agrément, de piétons, de cyclistes et d’engins de débardage cause des problèmes d’aération des sols. À certains endroits, cette compaction est si importante que l’eau de pluie reste en surface et, dans les cas les plus graves, que le tassement de tout l’horizon biologiquement actif asphyxie les systèmes racinaires de végétaux. La conséquence est l’impact négatif sur la végétation indigène et la présence de plantes envahissantes.

capables de se développer dans un sol très peu profond comme c'est par exemple le cas de la renouée poivre d'eau (*Polygonum hydropiper*) (Langohr, 2010, p.5).

En réponse à ces défis, Latte et al. (2015) proposent une gestion pro-active de la Forêt de Soignes. Elle doit inclure la mise en œuvre de stratégies de régénération naturelle de la végétation des zones boisées en favorisant le développement des strates forestières basses, améliorer les pratiques forestières pour limiter la compaction des sols et sélectionner des espèces plus résistantes aux changements climatiques. La surveillance continue de l'état de la forêt et l'adaptation des stratégies de gestion en fonction des données scientifiques actualisées sont également cruciales pour assurer la résilience de cet écosystème précieux.

---

---

# CHAPITRE 3

---

## ÉTAT DE L'ART

### 3.1 Télédétection

La télédétection consiste en l'acquisition de données à propos d'un objet à l'aide d'un capteur qui est physiquement séparé de celui-ci. Elle se base sur les propriétés des ondes électromagnétiques qui sont émises, réfléchies ou diffractées par cet objet (Defourny, 2023). La télédétection permet de faciliter l'obtention d'informations sur des grandes surfaces ou sur des sites d'études difficiles d'accès. Tempfli et al. (2009) mentionne dans son travail que la télédétection permet l'identification et la classification de diverses caractéristiques et phénomènes, ce qui permet le développement de nombreuses applications. À l'origine, l'imagerie spectrale a été utilisée dans divers domaines tels que l'agriculture, les études environnementales, la géologie, les produits pharmaceutiques, la médecine, ainsi que la qualité et la sécurité alimentaire (Goetz et al., 1985). Elle est basée sur le fait que divers matériaux ont des caractéristiques spécifiques de réflexion, de diffusion, d'absorption et d'émission d'énergie électromagnétique à des longueurs d'onde données. Cela est lié aux différences de composition chimique et de structure physique de la matière caractérisé par les chromophores<sup>1</sup> (Tempfli et al., 2009). La caractérisation, l'identification et la différenciation des matériaux présents dans chaque pixel d'une image sont facilitées par des caractéristiques distinctives, connues sous le nom de signatures spectrales. Chaque objet a une signature spectrale qui lui est propre. Grâce à l'étude des signatures spectrales par des modèles de caractérisation, il est possible de distinguer les particularités électromagnétiques propres à chaque matériau. Cela rend par exemple possible de produire des cartes d'occupation du sol à grande échelle (Goetz et al., 1985).

Tempfli et al. (2009) mentionnent dans leurs travaux que la télédétection utilise des dispositifs de détection et d'affichage en temps réel ou des dispositifs d'enregistrement de l'énergie émise, diffractée ou réfléchi par un objet. L'énergie peut être de la lumière ou une autre forme de rayonnement électromagnétique, un champ de force ou de l'énergie acoustique. L'ensemble des longueurs d'ondes électromagnétique forment le spectre électromagnétique tel que représenté dans la figure 3.1. Ces

---

1. Un chromophore est une molécule qui absorbe certaines longueurs d'onde et en résulte l'émission d'une couleur (Hayashi, 2013).

ondes interagissent avec l'atmosphère et la surface de la terre ou toute autre matière rencontrée. Chaque matière a une signature spectrale propre à elle-même (European Space Agency, 2009). De cette manière, il est possible de déterminer les propriétés spécifique de celles-ci à distance.




Figure 3.1 – Spectre électromagnétique. (Passy, 2021)

### 3.1.1 Types de télédétection

Il existe deux principaux types de télédétection. Celles-ci sont différenciées par la source des ondes électromagnétiques détectées. Si la source d'énergie utilisée est une source synthétique, tel que c'est le cas du LiDAR<sup>2</sup>, l'obtention des données relève de la télédétection active. Si, en revanche, la source d'énergie utilisée est naturelle, tel que c'est le cas pour le soleil, cela correspond à de la télédétection passive (Kogut, 2020).

La **Télédétection active** se base sur une source d'énergie artificielle (fig.3.2) et a le potentiel de fournir des informations sur la surface d'une zone d'étude (Tempfli et al., 2009, p.103). Elle fournit des mesures de surface sur base d'interférence de SAR ou de scan par laser. Les capteurs radar utilisent le principe de la détection de micro-ondes, alors que le scan par laser fonctionne avec des capteurs optiques opérant dans des gammes de longueurs d'ondes proche infrarouge et visible du spectre électromagnétique (fig.3.1). Tempfli et al. (2009) mentionnent que l'utilisation de capteurs actifs offre comme avantage d'acquérir des données à tout moment, peu importe les conditions météo ou la présence de lumière du jour. Les ondes étant générées par le capteur lui-même, les caractéristiques du signal sont contrôlées et peuvent, dans certains cas, être ajustées selon l'application désirée.

La **télédétection passive** repose quant à elle sur des sources d'énergie naturelles, comme la lumière du soleil, pour capturer des informations sur des surfaces (fig. 3.2). La méthode mesure les radiations réfléchies ou émises dans différentes parties du spectre électromagnétique représenté à la figure 3.1, notamment les longueurs d'onde visibles, infrarouges et thermiques. L'énergie atteignant la

2. Le LiDAR (Light Detection and Ranging) est une technologie de télédétection qui utilise des lasers pour mesurer la distance entre un capteur et un objet ou une surface. En émettant des impulsions laser et en mesurant le temps de retour des réflexions, le LiDAR peut créer des représentations tridimensionnelles détaillées des paysages et des structures (Estes & Loveland, 2005, p.668)

surface étudiée est appelée l'irradiance. L'énergie réfléchiée par cette surface est appelée la luminance. L'irradiance et la luminance sont exprimées en  $\text{W m}^{-2} \text{sr}^{-1}$ . C'est la luminance qui est mesurée par les capteurs passifs. La télédétection passive est cependant limitée par la présence de lumière du jour et les conditions atmosphériques. Ce type de télédétection ne s'applique pas de nuit ou par temps nuageux. Malgré ces contraintes, elle est largement utilisée pour des applications telles que la classification de la couverture terrestre, le suivi de la végétation et l'évaluation de la qualité de l'eau (Tempfli et al., 2009, p.88).




Figure 3.2 – Différence entre capteur actif et passif utilisé en télédétection. (Tempfli et al. (2009))

### 3.1.2 Caractéristiques des capteurs

Tout type de télédétection nécessite l'utilisation de capteurs. Les deux principaux groupes de capteurs se distinguent également par la source d'énergie utilisée. Ceux-ci se distinguent par d'autres caractéristiques telles que la résolution spatiale, spectrale, radiométrique et temporelle (Tempfli et al., 2009, p.107). Ces différentes caractéristiques influencent le champ d'application de chacun d'eux. La **résolution spatiale** définit la taille des pixels formant l'image collectée. La **résolution spectrale** correspond à l'aptitude d'un capteur à distinguer des rayonnements électromagnétiques de fréquences différentes. Plus globalement, cela s'apparente à l'intervalle comprenant différentes longueurs d'onde formant les bandes spectrales distinctes l'une de l'autre. La **résolution radiométrique** désigne la capacité d'un capteur à mettre en évidence les variations d'intensité du signal reçu. Le capteur peut détecter plus de nuances entre les niveaux d'énergie réfléchiée ou émise par la surface terrestre à mesure que la résolution radiométrique augmente. En général, cela est exprimé en bits. L'intervalle de temps séparant l'acquisition des images correspond à la **résolution temporelle**. Celle-ci est importante pour l'analyse de l'évolution de la couverture terrestre. La résolution temporelle est déterminée par la plateforme transportant le capteur et le système permettant la transmission des données du capteur embarqué vers la terre. Plus les données à transmettre sont volumineuses, plus la quantité d'énergie nécessaire à la transmission est élevée. La plateforme, quant à elle, peut être un satellite, un avion, ou autre objet volant.

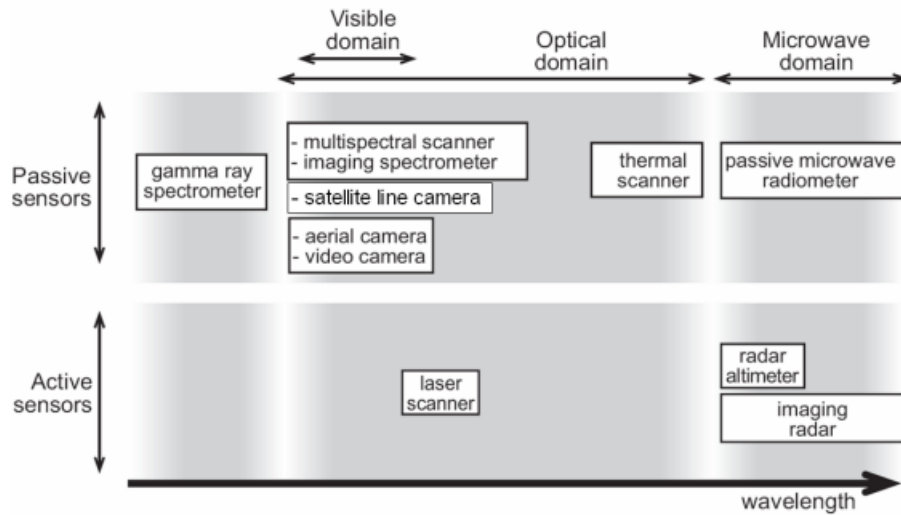


Figure 3.3 – Types de capteurs utilisés en télédétection en fonction de la gamme de longueur d’onde détectée. (Source : Tempfli et al., 2009)

Tels que représentés à la figure 3.3, les capteurs multispectraux (MS) ou hyperspectraux (HRS) sont utilisés dans le cadre de la télédétection passive. Selon les recherches de Feng et al. (2020), ces capteurs se différencient par leur habilité à enregistrer un nombre plus ou moins élevé de bandes de longueurs d’onde différentes du spectre électromagnétique représenté à la figure 3.1. Les capteurs MS sont limités à une partie du spectre électromagnétique et collectent de l’information dans 5 à 10 bandes spectrales. Celles-ci correspondent principalement aux trois couleurs primaires (rouge, bleu et vert) et à des longueurs d’onde infrarouges. Les capteurs HRS ont quant à eux la capacité d’enregistrer de l’information dans un plus grand nombre de bandes spectrales pour une même gamme de longueur d’onde. Autrement dit, la résolution spectrale des capteurs HRS est plus élevée que celle des capteurs MS. Cela permet de pouvoir interpréter le spectre électromagnétique de manière pratiquement continue pour la gamme de longueur d’onde étudiée (fig. 3.4).

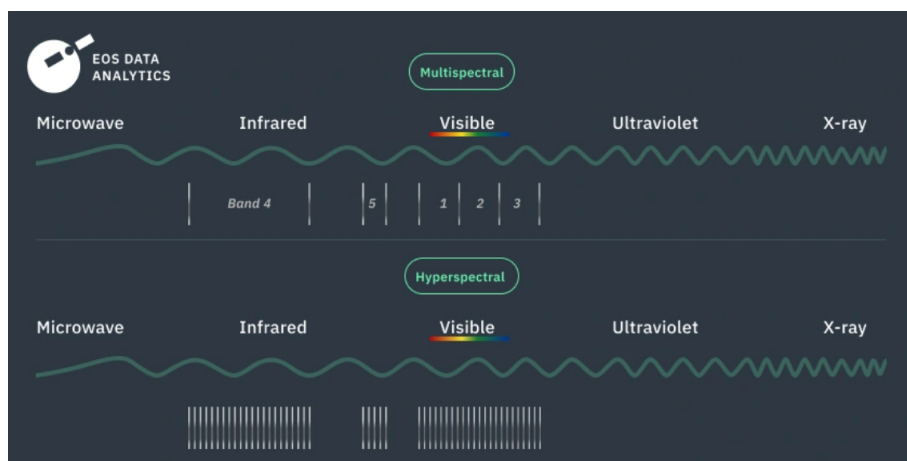


Figure 3.4 – Comparaison entre les données MS et HRS. (Source : Feng et al., 2020)

### 3.1.3 Vue d'ensemble des capteurs hyperspectraux

Ce paragraphe vise à établir une synthèse des capteurs HRS embarqués sur satellite. Leurs technologies et les types de données acquises sont divers, ce qui permet d'avoir des applications propres à chaque capteur.

Le terme hyperspectral a été utilisé pour la première fois par Goetz et al. (1985). Il s'agissait alors de l'utilisation d'une image pour identifier la matière de surface. Le spectromètre imageur aéroporté, inventé par Alexander Goetz, est à l'origine de l'imagerie hyperspectrale dans les années 1980. L'Airborne Visible/Infrared Imaging Spectrometer (AVIRIS) est un capteur hyperspectral développé par la NASA en 1983 pour étendre les capacités des spectromètres imageur terrestres aux plateformes aériennes. Les premières images spectrales ont été capturées par AVIRIS en 1987, ce qui en fait le premier spectromètre imageur à mesurer le spectre électromagnétique de la lumière de 400 nm à 2500 nm à des intervalles de 10 nm. À la suite du succès d'AVIRIS et aux avancées technologiques des capteurs HRS, les techniques d'étalonnage ont conduit au développement d'une nouvelle génération de capteur.

Hyperion est le premier capteur hyperspectral qui fonctionne à partir d'un satellite. La NASA a lancé le satellite en 2000. Il distingue 220 bandes dans la plage de 0,4 à 2,5  $\mu\text{m}$ , possède une résolution spatiale de 30 mètres et une largeur de bande d'acquisition de 7,7 km (Tempfli et al., 2009). En réaction, les Européens ont développé en 2001 leur propre capteur hyperspectral, le Compact High Resolution Imaging Spectrometer (CHRIS). Le spectromètre CHRIS avait pour but d'être compact tout en ayant une résolution spectrale élevée lui permettant d'être catégorisé comme capteur HRS. Dans les faits, il a une masse inférieure à 15 kg et mesure 790 x 260 x 200 mm. Le spectromètre CHRIS est programmable et a la capacité d'adapter le nombre de bandes spectrales détectées à l'application nécessaire. Il est capable d'employer au minimum 19 bandes spectrales et au maximum 63 bandes différentes. Le nombre de bandes employées influence la résolution spatiale du spectromètre. Elle est au maximum de 18 m lorsque 19 bandes sont employées, tandis qu'un minimum de 36 m de résolution spatiale est requis pour l'utilisation de 63 bandes spectrales. Il est possible de programmer la sélection des bandes de CHRIS afin que chaque application puisse utiliser les bandes les plus adaptées (Van Mol & Ruddick, 2024).

Les technologies hyperspectrales se sont fortement développées au cours des 15 années qui ont suivi. Récemment, l'Agence Spatiale Italienne a mis sur pied un programme visant à développer un nouvel outil, PRISMA. PRISMA est un satellite d'imagerie hyperspectrale à résolution moyenne. Il a été lancé le 22 mars 2019 et restera fonctionnel pour une durée de 5 ans. L'objectif de sa mission est déterminé par diverses applications : imagerie de surface terrestre, agriculture et sylviculture, géologie régionale, études de l'utilisation des sols et des ressources en eau, études de la végétation, ect. Il est un satellite doté de deux instruments de mission. Tout d'abord, le HYC (HYperspectral CameraOperational) qui offre des images hyperspectrales avec une résolution de 30 m, ainsi que le PAN CAMERA (Panchromatic CameraOperational) qui consiste en un imageur optique à haute résolution avec 5 m de résolution spatiale (CEOS, 2024).

Shrestha et al. (2021) mentionnent dans leurs travaux que le premier spectromètre HRS installé sur la Station Spatiale Internationale (ISS) est le DLR Earth Sensing Imaging Spectrometer (DESI). L'utilisation de l'instrument DESIS rentre dans le cadre de la mission de détection de la surface terrestre (MUSES) qui a pour but de contribuer à l'élaboration de mesures efficaces pour la protection de l'environnement et du climat. DESI permet aux scientifiques de détecter les changements dans les écosystèmes et de faire des déclarations sur l'état des forêts et des terres agricoles (Shrestha et al., 2021). Ce spectromètre a été mis en service le 29 juin 2018 et permet d'obtenir de l'information dans la plage spectrale de 400 à 1000 nm tous les 2,55 nm, avec une résolution spatiale de 30 m.

Dans le contexte du développement de technologies de télédétection hyperspectrales, l'Agence spatiale allemande au Centre aérospatial allemand (DLR) a mis en place en 2006, le Environmental Mapping and Analysis Program (EnMAP) pour le compte du ministère fédéral allemand de l'économie et de la protection du climat (BMWK). Le satellite EnMAP a été lancé le 1er avril 2022 depuis Cap Canaveral en Floride, aux États-Unis. Le DLR (2022) cite dans leur programme que EnMap est actif dans la gamme spectrale de 420 nm à 2500 nm avec une résolution spatiale de 30 m et une résolution spectrale de 6,5 nm à 10 nm. Le capteur HRS EnMAP permet diverses possibilités d'application en foresterie. Henning Buddenbaum et Hill (2013) ont par exemple utilisé ses données pour obtenir une caractérisation détaillée des propriétés de réflexion et de la structure d'une forêt en Allemagne. Le satellite EnMAP étant opérationnel seulement depuis 2022, il n'existe pas encore beaucoup de recherche sur le sujet laissant un potentiel d'exploitation important.

Table 3.1 – Principaux capteurs hyperspectraux sur satellite et leurs caractéristiques

| Capteur  | Satellite    | Gamme Spectrale             | Résolution Spatiale | Année de Lancement  | Résolution Temporelle |
|----------|--------------|-----------------------------|---------------------|---------------------|-----------------------|
| Hyperion | EO-1         | 400-2500 nm                 | 30 m                | 2000-2007           | 16 jours              |
| CHRIS    | PROBA-1      | 400-1050 nm                 | 18-36 m             | 2001                | 2-3 jours             |
| HICO     | ISS          | 400-900 nm                  | 90 m                | 2009-2014           | 10 jours              |
| DESI     | ISS          | 400-1000 nm                 | 30 m                | 2018                | 1-3 jours             |
| PRISMA   | PRISMA       | 400-2500 nm                 | 30 m                | 2019                | 5-10 jours            |
| EnMAP    | EnMAP        | 420-2450 nm                 | 30 m                | 2022                | 4-5 jours             |
| EMIT     | ISS          | 1900-2500 nm                | 30 m                | 2022                | 1-3 jours             |
| SHALOM   | SHALOM       | 400-1000 nm,<br>900-2500 nm | 30 m                | Planifié en<br>2025 | 3-4 jours             |
| SBG      | Landsat Next | 400-2500 nm                 | 30 m                | Planifié en<br>2027 | 5-16 jours            |

### 3.1.4 Avantages et limites des données HRS satellite

Les images hyperspectrales offrent une avancée significative par rapport aux images classiques ou multispectrales dans le domaine de l'observation satellitaire, grâce à leur capacité à capturer un spectre continu avec des centaines de bandes étroites. Cette résolution spectrale fine permet une analyse détaillée et la détection précise de signatures spectrales uniques, essentielles pour identifier et discrimi-

ner des matériaux ou substances similaires, tels que des types spécifiques de minéraux ou de végétation.

Ces capacités se traduisent par une meilleure caractérisation des propriétés chimiques et physiques des objets observés. Par exemple, les images hyperspectrales permettent d'analyser en détail la composition biochimique de la végétation, en identifiant son contenu en chlorophylle, son taux d'humidité ou son niveau de stress. De même, elles sont précieuses pour étudier les sols, en déterminant leur teneur en eau ou leur composition minérale.

Dans le domaine de la cartographie, les images hyperspectrales se distinguent par leur précision. Elles permettent de différencier de manière fine les classes au sol, ce qui les rend idéales pour des applications telles que la cartographie des habitats naturels, le suivi des forêts, ou encore l'étude des récifs coralliens. Ces technologies jouent également un rôle clé dans la surveillance environnementale, en détectant les changements subtils causés par des phénomènes tels que l'érosion, la désertification ou la pollution.

Par ailleurs, les données hyperspectrales s'intègrent parfaitement dans des systèmes multisource en complément d'autres capteurs, tels que les radars ou les lidars, permettant ainsi des analyses combinées et enrichies. Leur rôle en climatologie et météorologie est tout aussi notable, notamment pour l'étude des gaz atmosphériques, des aérosols ou des propriétés des nuages.

Villafranca et al. (2012) mettent en évidence différents aspects limitant l'utilisation de données hyperspectrales dans l'observation de la terre à partir de satellites. Les trois limites principales sont le rapport signal/bruit, les systèmes de communication des données ainsi que de la fonction de transfert de modulation.

### **Rapport Signal/Bruit**

Le rapport signal/bruit (RSB) est une mesure de la qualité des données obtenues par les capteurs. Il compare le niveau du signal utile acquis à celui du bruit de fond, constitué d'interférences indésirables. Dans le contexte de la télédétection HRS, la réduction de la largeur des bandes spectrales pour obtenir une haute résolution spectrale entraîne une diminution du nombre de photons obtenu dans chacune des bandes détectées. Cela a comme conséquence une réduction du RSB. Un RSB faible signifie que le bruit peut masquer les détails subtils des données spectrales, rendant plus difficile la distinction des différentes caractéristiques des objets observés. Cela affecte directement la qualité des données et la capacité à en extraire des informations fiables. Une manière de compenser le faible taux d'énergie fourni par les photons et d'avoir un RSB plus élevé est d'augmenter la surface de chaque pixel observé. Ceci offre la possibilité d'accroître la quantité de photons obtenus pour chaque pixel, ce qui par conséquent permet d'obtenir une quantité d'énergie plus importante dans chacune des bandes spectrales.

### **Système de communication des données**

Les capteurs HRS embarqués sur satellite génèrent une quantité massive de données. Ce volume de données pose un défi majeur pour la transmission des informations depuis l'espace vers la terre.

La transmission est limitée par la bande passante disponible à bord des satellites, ce qui implique une vitesse de transmissions limitée. La compression des données hyperspectrales permet réduire leur taille et faciliter leur envoi. La transmission s'effectue par l'intermédiaire de systèmes de communication par radiofréquence ou par laser, qui doivent être suffisamment puissants et fiables pour garantir que les données parviennent intactes aux stations au sol, malgré la distance et les conditions de transmission potentiellement défavorables. Les capacités de stockage limitées à bord du satellite ajoutent une autre couche de complexité à la gestion de ces données volumineuses.

### **Fonction de Transfert de Modulation**

La Fonction de Transfert de Modulation (MTF) est utilisée pour décrire la capacité d'un système optique à reproduire les détails d'une scène dans une image. Elle mesure comment le contraste des détails de l'image est réduit par le système optique. Dans le cas des satellites HRS, la petite taille du système optique, la diffraction des ondes par les lentilles et le mouvement du capteur ou du satellite peuvent limiter la MTF. Cela compromet la capacité du satellite à capturer des images nettes et précises. La MTF est directement liée à la résolution spatiale, car elle influence la netteté des détails dans l'image ce qui accentue l'effet limitant sur la résolution spatiale par le RSB. En effet, les systèmes optiques des capteurs HRS doivent souvent sacrifier une partie de la résolution spatiale pour obtenir une haute résolution spectrale.

## **3.2 Applications forestières**

Les applications développées à partir de données hyperspectrales dans le domaine forestier sont variées. Par exemple, le gouvernement canadien utilise des données hyperspectrales provenant de capteurs embarqués sur satellite afin de cartographier les propriétés des sols et la géologie et d'en tirer des conclusions directes sur les processus physiques des sols et donc de faciliter les décisions de gestion forestière sur des grandes surfaces.

Une autre application concerne la santé forestière. Chaque couverture végétale a une signature spectrale théorique propre. En la comparant avec des informations spectrales de terrain, il est possible de déterminer la santé végétale pour la zone étudiée. Cet état de santé peut être impacté par la présence de stress, comme par exemple le manque d'apport en eau ou en nutriments. Elle peut également être affectée par des perturbations naturelles telles que des parasites ou des variations climatiques. Chaque matériau ayant une influence sur la signature spectrale qui lui est propre, il est possible de déterminer l'origine du problème. (Mike, 2013)

Dans le but de différencier le sol et les différentes canopées forestières, Ustin et Trabucco (2000) ont utilisé les données du spectromètre AVIRIS. Ces données hyperspectrales sont représentées à la figure 3.5 où la réflectance est mise en fonction des longueurs d'ondes. Sur ce graphique, il est observable que les herbacées et les jeunes pousses ont un taux de réflectance équivalent aux conifères anciens pour les longueurs d'ondes se situant dans le spectre visible (400 à 700 nanomètres). Néanmoins, lorsque le spectre complet est comparé, il est possible de les différencier. Si l'on compare le taux de réflectance pour les longueurs d'ondes se situant dans le proche infrarouge (700 à 850 nanomètres), il est observable que les herbacées et les jeunes pousses réfléchissent jusqu'à 50 pourcents des ondes alors que les conifères anciens en réfléchissent seulement 15 pourcents. En suivant cette méthode d'approche, il est possible de différencier la réflectance produite par les sols, le couvert herbacé et la canopée des forêts anciennes. Cette méthode peut alors s'appliquer à tous types de matières pour autant qu'elles possèdent des différences dans leur spectre de réflexion.




Figure 3.5 – Signature spectrale utilisée comme référence d'analyse mixte de données AVIRIS

### 3.2.1 La reconnaissance d'essences forestières développée à partir de données multispectrales

Dans leur revue de littérature sur les études portant sur la classification d'essence forestière, Fassnacht et al. (2016) constatent qu'il y a eu une augmentation du nombre de recherches sur le sujet au cours des 40 dernières années. Toutefois, ils remarquent que ces études sont principalement appliquées à de petites zones d'études pour lesquelles il est facile d'obtenir des informations de terrain avec une haute précision. Pour cette étude, il n'est donc pas pertinent de tenir compte d'études sur la classification forestière à partir d'images ne provenant pas de capteurs embarqués sur satellite car elles bénéficient de données de qualité non comparable. Ce paragraphe a comme objectif de synthétiser les études ayant été faites dans le même contexte que cette recherche, mais en se basant sur des images MS provenant de satellite.

En 1988, Frank (1988) publie une des premières recherches concernant la classification de la végétation à partir de données multispectrales provenant du Landsat Thematic Mapper. Sa recherche intègre également des variables topographiques et climatiques. Elle a permis de distinguer les types de végétation alpine et subalpine, mais les types de végétation forestière de la zone montagnarde du Colorado n'ont pas pu être distingués. Depuis, de nombreuses autres recherches ont permis de faire évoluer l'utilisation de données multispectrales à des fins de classification d'essences forestières.

Dans cette quête d'évolution technologique, Immitzer et al. (2019) a publié une recherche visant à optimiser le nombre de variables nécessaires à la classification d'essence forestière en Autriche. Pour ce faire, ils utilisent 18 images Sentinel-2 multitemporelles afin d'observer les variations saisonnières des

arbres (couleur des feuilles, débourrement, ect.). Ils en concluent que l'utilisation de 7 images prises à des périodes spécifiques du développement de la végétation permet d'obtenir une précision équivalente à l'utilisation des 18 images. De manière à réduire le nombre de données à traiter et à éviter la confusion entre les différentes classes, Immitzer et al. (2019) préconisent de faire la classification en deux temps. Premièrement, ils différencient l'occupation du sol en trois classes : conifère, feuillus et site non boisé. Ensuite, ils traitent les classes de conifères et de feuillus en utilisant des modèles Random Forest (RF) différents. Dans le même souci du nombre de variables à traiter, Bolyn et al. (2018) utilisent le modèle VSuRF pour réduire le nombre de variables utiles à leur classification. Ce modèle consiste en la sélection de variables suivant une procédure basée sur un random forest. L'étude de Bolyn et al. (2018) porte sur les Ardennes belges et a comme objectif de produire une carte d'un massif forestier de 333 850 hectares. Le massif comporte 11 classes d'arbres majoritaires tels que le hêtre, le pin et le chêne. La sélection finale de variable produite par le modèle VSuRF comprend : Deux images Sentinel-2, choisies pour leurs dates correspondant à des variations saisonnières fortes, ainsi que des données topographiques et des modèles de hauteurs de canopé obtenus par Lidar permettant la détection des coupes récentes. En ce qui concerne les pixels composés de différentes essences d'arbres, Bolyn et al. (2018) préconisent un minimum de présence d'essence de 80 % dans le pixel pour qu'il soit considéré comme étant un pixel pur. Si cela n'est pas le cas, le pixel est considéré comme étant composé de végétation mixte. Dès lors, une classe de végétation mixte est créée. De manière à faire la validation des résultats obtenus, Bolyn et al. (2018) et Immitzer et al. (2016) consacrent 10% de leur jeu de donnée alors que Immitzer et al. (2019) y consacrent 20%. Les restes des données servent à l'entraînement des modèles de classification.

### **3.2.2 La reconnaissance d'essences forestières développée à partir de données hyperspectrales**

Les données HRS peuvent également être utilisées dans la reconnaissance d'essence forestière. Actuellement, la majorité des recherches ayant été faites dans ce domaine se basent sur des données HRS provenant d'avion ou de drone. Cela s'explique par le fait que les capteurs embarqués sur ce type de plate-formes existent depuis plus longtemps et qu'ils permettent d'obtenir des images avec une meilleure résolution spatiale (0,4 m à 7 m) (Trier et al., 2018) alors que les capteurs HRS embarqués sur satellite ont actuellement la capacité de fournir des images avec un maximum de 30 mètres de résolution spatiale. (Cfr. 3.1.3).

Goodenough et al. (2003) ont mené une des premières recherches ayant pour but de cartographier les essences forestières en utilisant des données HRS provenant de satellite. Leur recherche se base sur des données provenant du capteur Hyperion et couvre huit zones d'études différentes situées au Canada et aux États-Unis. Dans cette étude, les résultats obtenus à partir de différents types de données sont comparés. Goodenough et al. (2003) y concluent que l'utilisation des données HRS provenant d'Hyperion permet d'obtenir des résultats ayant une précision plus élevée comparé aux résultats obtenus à partir de données MS provenant de Landsat-7 avec une précision globale de 90 % pour Hyperion et 75% pour Landsat-7. Cela est donc encourageant et pousse à l'utilisation de données HRS dans le domaine de la discrimination des essences forestières.

Les recherches menées avec des données provenant d'Hyperion sont multiples dans le domaine de la reconnaissance d'essence forestière. Deák et al. (2017) les utilisent dans le but de comparer différentes méthodes de classification. Leur étude porte sur la classification d'arbres dans la région de steppe forestière hongroise. Ils en concluent que réduire le nombre de variables explicatives à l'aide d'une analyse en composantes principales (ACP) permet d'augmenter la qualité des résultats obtenus. Dans le cas de cette étude, l'application d'une ACP permet d'augmenter la précision globale de la classification de 5,5 % par rapport à l'application du jeu de données original. Une autre manière de réduire le volume des données est la sélection de bandes spectrales en fonction de leur apport lors de la classification. Delogu et al. (2024) appliquent cette méthode sur des données spectrales PRISMA. Cette méthode consiste à sélectionner un sous-ensemble de bandes spectrales originales en fonction de leur capacité à fournir des informations utiles pour la tâche de classification. Cette capacité peut être représentée grâce à des indices tels que l'indice gini. Seules les bandes les plus pertinentes sont donc traitées, ce qui évite de devoir traiter des informations redondantes ou du bruit. Ils comparent ensuite cette méthode avec l'ACP en utilisant la même base de données. La sélection de bandes spectrales permet d'atteindre un f1-score moyen plus élevée (>90 pour-cent) que l'ACP. Enfin, il convient de mentionner le phénomène de Hughes, qui explique pourquoi la réduction du nombre de composantes ou de bandes spectrales est souvent bénéfique (Daria, 2024). Ce phénomène décrit comment, au-delà d'un certain seuil, l'ajout de nouvelles composantes ou bandes ne contribue plus à améliorer la classification et peut même introduire du bruit ou des informations redondantes. Il décrit également que le nombre d'échantillons augmente de manière exponentielle lorsque le nombre de variables augmente. En d'autres termes, la réduction de la dimensionnalité permet d'éviter les effets néfastes de l'augmentation excessive du nombre de variables, ce qui renforce l'importance d'une sélection optimisée des données pour maximiser la précision des résultats (Hughes, 1968).

De manière à améliorer la classification des pixels comprenant plusieurs essences d'arbres différentes, Deák et al. (2017) proposent d'introduire une nouvelle classe pour chaque combinaison d'essences d'arbres au sein d'un même pixel. Les pixels comprenant plusieurs essences possèdent un spectre électromagnétique résultant de la combinaison des spectres de chacune des essences présentes. Dès lors, il est possible de déterminer les combinaisons d'essences d'arbres pour chaque pixel non-pure et donc d'obtenir un meilleur résultat final. A titre d'exemple, les résultats obtenus dans la recherche de Deák et al. (2017) comportent des classes telles que Chêne-charmée ou encore Hêtre/Chêne. Awad (2018) a également utilisé des données d'Hyperion, mais cette fois-ci dans le but de les comparer avec des données HRS provenant du capteur CHRIS. Son étude porte sur la détection des pins (*Pinus pinea L.*) au Liban. Dans ce cas, les résultats obtenus avec les données d'Hyperion sont plus précis que ceux obtenus avec le capteur CHRIS. Cela s'explique par le fait que Hyperion a une aire de fauche plus petite et une résolution spectrale plus élevée. CHRIS produit donc des données sur une plus grande zone, mais avec moins de précision.

Dans certains cas, les données HRS sont combinées avec d'autres types de données. Vanguri et al. (2024) utilisent dans leur recherche des données HRS provenant du capteur EnMap et les intègrent avec des données MS provenant du capteur Sentinel-2 dans le but de distinguer des

essences forestières en Pologne. Cela leur permet d'obtenir un F1-score globale de 0.91. C'est également le cas de Glowienka et Zembol (2022) qui combinent des données provenant du capteur HRS CHRIS avec des données MS de Sentinel-2 dans le cadre de recherche portant sur la gestion forestière dans la province de Warmia-Masuria Voivodeship en Pologne. Fassnacht et al. (2016) décrivent dans leurs recherches : « La haute résolution spatiale fournie par les images MS et la riche information spectrale provenant des données HRS conduisent à une classification et une cartographie plus précises des espèces d'arbres. » Les résultats obtenus en intégrant les données MS de Sentinel-2 avec les données HRS de EnMap sont plus précis que dans le cas où seules les données de EnMap sont utilisées. L'utilisation de plusieurs données provenant de capteurs différents s'étant au-delà des données HRS et MS. Stavros et al. (2016) complètent quant à eux des données HRS provenant du capteur PRISMA avec des orthophoto afin d'augmenter la précision des résultats obtenus .

Enfin, il existe différents modèle et méthode de classification de pixels. Vanguri et al. (2024) étudient et comparent une partie des modèles de classification entre eux. Cette comparaison est faite dans le cadre de leur recherche qui a pour but de cartographier neuf essences d'arbres présentes dans une forêt proche de Warsaw en Pologne. Ils comparent dans leur étude les Support Vector Machines (SVM), Random Forest (RF), CatBoost (CAT), Gradient Boosting Classifier (GBC) et XGBoost (XGB). Le SVM et le RF obtiennent respectivement des F1-score de 0,86 et 0,93 pour les essences feuillues. Cela correspond aux résultats les plus précis pour la classification d'essence. De plus, Vanguri et al. (2024) mentionnent le modèle Random Forest comme étant le plus adapté à des applications similaires à cette recherche. Cet algorithme créé par Breiman en 2001 (Breiman, 2001) est une approche basée sur l'apprentissage automatique (machine learning). La classification se base sur un ensemble d'arbres de décision individuels qui travaillent ensemble. Chaque arbre est entraîné sur un sous-ensemble aléatoire d'échantillons étiquetés. Cette randomisation des données d'entraînement réduit la probabilité d'erreur à mesure que le nombre d'arbres augmente. Chaque arbre ne donne qu'un seul vote par instance, et la classification finale est déterminée par la majorité des votes de tous les arbres. Selon Brownlee (2020), ce modèle peut être adapté en fonction de la qualité et du type de données qui y sont utilisés pour l'entraînement. La bibliothèque Scikit-Learn offre des outils permettant de diviser les données en ensembles d'entraînement et de validation, comme train test split, ou d'effectuer une validation croisée imbriquée (Nested cross-validation). Cela permet d'alterner la base de donnée servant à entraîner le modèle et celle servant à le valider. De cette manière, la classification se base sur l'ensemble des données et n'est pas limitée à une partie de celle-ci tout en minimisant le risque de sur-apprentissage. Par ailleurs, Brownlee (2020) souligne qu'il est possible d'adapter les hyperparamètres du modèle Random Forest, et de les intégrer à une validation croisée imbriquée de manière à maximiser le F1-score des classes étudiées. Ils citent 4 hyperparamètres différents. 1) n-estimators : Ce paramètre représente le nombre d'arbres dans la forêt. Plus ce nombre est élevé, plus le modèle est robuste, mais cela augmente aussi le temps de calcul. 2) max depth : il définit quant à lui la profondeur maximale des arbres. Une profondeur plus grande permet de capturer des relations plus complexes, mais cela peut entraîner un surapprentissage. 3) Min samples split : cela correspond au nombre minimum d'échantillons requis pour diviser un nœud interne. Par exemple, avec une valeur de 2, un nœud sera divisé si au moins 2 pixels sont disponibles. Des valeurs plus élevées empêchent une division excessive et réduisent le surapprentissage. 4) min

samples leaf : est le nombre minimum d'échantillons nécessaires pour qu'un nœud feuille soit valide. Une valeur plus élevée entraîne des arbres plus simples, ce qui peut améliorer la généralisation. Ces ajustements dépendent principalement de la capacité des variables explicatives à discriminer les classes.

Le tableau 3.2 contient une liste non exhaustive des récentes recherches faites dans un contexte similaire à celle-ci. Ces recherches regroupent différentes méthodes de classification et l'utilisation de données variées. Il a comme objectif de comparer de manière synthétique les différentes manières de faire qui se montrent intéressantes dans le cadre de ce travail.

Table 3.2 – Comparaison des principales études sur la classification des espèces forestières par imagerie hyperspectrale provenant de satellite

| <b>Auteurs</b>             | <b>Spectromètre</b>       | <b>Zone d'étude</b>                              | <b>Méthode</b>                                                                                                                                                                                                                                                                                                                              | <b>Résultat</b>                                                        |
|----------------------------|---------------------------|--------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------|
| Vanguri et al. (2024)      | EnMap, Sentinel-2         | Pologne                                          | Étude utilisant des indices spectraux comme le NDVI, NDMI, SAVI et EVI avec des données multispectrales de Sentinel-2. Les images multispectrales (MS) et hyperspectrales (HRS) sont combinées, et le spectre de neuf essences forestières est extrait. Classification par cinq algorithmes différents comparés. (SVM, RF, CAT, GBC et XGB) | F1-score global :<br>SVM : 86%<br>RF : 93%                             |
| Caputi et al. (2023)       | PRISMA                    | Région de Lazio (Italie)                         | Comparaison de méthodes de classification pour les données PRISMA.                                                                                                                                                                                                                                                                          | KNN : 72%<br>SVM : 69%<br>RF : 73%                                     |
| Glowienka et Zembol (2022) | CHRIS / PROBA, Sentinel-2 | Province de Warmia-Masuria Voivodeship (Pologne) | Étude sur la faisabilité de combiner les images HRS et MS pour la classification de pins, d'aulnes et de bouleaux. Utilisation de trois méthodes de classification : SAM (Spectral Angle Mapper), MTMF (Mixture Tuned Matched Filtering), SVM.                                                                                              | Exactitude globale :<br>SVM : 72%<br>MTMF : 52%<br>SAM : 62%           |
| Vangi et al. (2021)        | PRISMA                    | Italie                                           | Les données HRS sont comparées aux données MS de Sentinel-2 pour évaluer leur pertinence pour la reconnaissance des essences forestières.                                                                                                                                                                                                   | Prisma offre une précision supérieure de 102% par rapport à Sentinel-2 |

|                          |                                       |                                                  |                                                                                                                                                                                                                                                                                                                |                                                                                                                                                     |
|--------------------------|---------------------------------------|--------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------|
| Grigorieva et al. (2020) | Resurs-P, Landsat                     | République Tchèque et le nord-ouest de la Russie | Étude des différences spectrales des pins, de l'épicéa, du bouleau et du hêtre selon les saisons. Les différences sont plus marquées au printemps et en automne.                                                                                                                                               | Exactitude globale : 80%                                                                                                                            |
| Awad (2018)              | Hyperion, CHRIS, Landsat 8            | Liban                                            | Cette étude vise à comparer les résultats obtenus avec des données HRS ou MS en utilisant l'algorithme de classification "Spectral angle mapper".                                                                                                                                                              | Exactitude globale :<br>Hyperion data : 92%<br>CHRIS data : 82%<br>Landsat 8 data : 60%                                                             |
| Deák et al. (2017)       | Hyperion                              | Budai Hills (Hongrie)                            | Comparaison des méthodes de réduction de la dimension du jeu de données en appliquant une ACP et en réduisant le nombre de bandes spectrales selon leur pouvoir de discrimination. Différentes classes ont également été testées, telles que une classe comprenant les pixel non-homogènes (Végétation mixte). | Exactitude globale :<br>Base de données d'origine : 77%<br>Réduction de bande : 84%<br>ACP : 82%<br>SDA : 83%<br>Classes de végétation mixtes : 86% |
| Stavros et al. (2016)    | CHRIS / PROBA, Landsat-8, Orthophotos | Parc National Pindos (Grèce)                     | L'objectif de cette étude est d'explorer l'efficacité d'un algorithme appelé BI-ICE, basé sur une approche bayésienne hiérarchique, pour différencier deux espèces d'arbres (le hêtre et le pin)                                                                                                               | Exactitude globale : 92%                                                                                                                            |
| Galidaki et Gitas (2015) | Hyperion                              | Région méditerranéenne                           | Étude ayant comme objectif d'investiguer le potentiel des satellites hyperspectraux afin de cartographier les essence forestière d'une zone. La méthode de classification est le nearest neighbour.                                                                                                            | Exactitude globale : 83%                                                                                                                            |

|                          |                                                                                                                |        |                                                                                                                                                                                                                                 |                                                      |
|--------------------------|----------------------------------------------------------------------------------------------------------------|--------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------|
| Goodenough et al. (2003) | Hyperion, Advanced Land Imager (ALI), National Aeronautics and Space Administration's Earth Observing 1 (EO-1) | Canada | <p>Une comparaison est faite des résultats de classification des essences à partir des données de Hyperion, ALI et du capteur Enhanced Thematic Mapper Plus (ETM+) de Landsat-7 dans le bassin versant de Greater Victoria.</p> | <p>Hyperion : 90%<br/> ALI : 85%<br/> ETM+ : 75%</p> |
|--------------------------|----------------------------------------------------------------------------------------------------------------|--------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------|

### 3.3 Conclusion

Les avancées technologiques dans le domaine des données spectrales, multispectrales (MS) et hyperspectrales (HRS) ont radicalement modifié les techniques de cartographie forestière et d'identification des espèces. Les données MS, provenant de capteurs satellites tels que Sentinel-2 ou Landsat, servent souvent à la classification globale en raison de leur grande précision et fréquence temporelle. Cependant, leur application est limitée par un spectre relativement restreint en comparaison aux informations HRS. Malgré une résolution spatiale réduite (actuellement de 30 mètres), les informations HRS présentent un spectre détaillé qui permet une discrimination précise des essences, comme le prouvent les résultats acquis grâce à des capteurs comme Hyperion ou EnMap.

Cependant, l'étude de ces données complexes nécessite des méthodes solides pour minimiser la dimensionnalité, tel que l'analyse en composantes principales (ACP), dans le but d'éviter le phénomène de Hughes et d'améliorer les performances des modèles de classification. Les méthodes d'apprentissage automatique, en particulier le modèle Random Forest, prévalent dans le domaine de la classification grâce à leur capacité d'ajustement et robustesse. De plus, en le combinant à une validation croisée imbriquée dans le but de déterminer les hyperparamètres, cela crée un modèle de classification puissant.

L'association de différents types de données tel que MS et HRS présente un fort potentiel, combinant leurs avantages respectifs pour obtenir des catégorisations plus exactes. Ces synergies soulignent la nécessité de poursuivre l'exploration des solutions hybrides tout en mettant au point des méthodes appropriées face à la complexité des informations.

Pour finir, malgré les défis persistants, en particulier en ce qui concerne la résolution spatiale des HRS et le traitement des pixels mixtes, les études en cours révèlent un potentiel grandissant pour une gestion forestière durable à grande échelle.

---

---

# CHAPITRE 4

---

## OBJECTIFS ET HYPOTHÈSES

L'objectif général de cette recherche est d'analyser la capacité des images hyperspectrales à discriminer les différents peuplements forestiers de la Forêt de Soignes. Cet objectif sera poursuivi en comparant différentes méthodes de classification dans le but d'obtenir les paramètres optimaux menant à la discrimination la plus précise possible des peuplements forestiers. Les objectifs spécifiques de cette étude sont les suivants :

- Analyser la contribution des différents stades phénologiques correspondant aux différentes dates d'observation sur la classification des essences forestières et, tester l'impact de leurs combinaisons pour une même classification.
- Identifier et discuter les bandes spectrales ou longueurs d'onde permettant une classification optimale, notamment à l'aide du modèle Random Forest.
- Examiner l'impact de la quantité de données disponibles par classe sur l'exactitude de la classification.
- Étudier l'amélioration de la discrimination des essences forestières en combinant des données issues de différentes périodes de l'année et correspondant à divers stades phénologiques.
- Évaluer la valeur ajoutée des images hyperspectrales des satellites EnMAP et PRISMA par rapport aux images multispectrales de Sentinel-2, pour distinction des essences forestières de la Forêt de Soignes.

Plusieurs hypothèses sont posées pour atteindre ces objectifs :

- La zone étudiée est constituée de peuplements homogènes
- La valeur de luminance acquise dans une bande hyperspectrale correspond à la valeur de luminance de la longueur d'onde centrale de la dite bande.
- L'occupation du sol ne varie pas au cours de la période d'acquisition des images.

# CHAPITRE 5

## MATÉRIEL ET MÉTHODE

Ce chapitre reprend la méthode et le matériel utilisés dans le but d'atteindre les objectifs mentionnés au chapitre 3. L'ensemble des étapes clés établies sont représentées à la figure 5.1 ci-dessous. Elles représentent le traitement des images PRISMA et ENMAP, le traitement des données de terrain, la calibration de modèles de classification ainsi que la validation de celui-ci. L'ensemble de ces étapes permet la comparaison des différentes manières de classer les pixels représentatifs des peuplements en Forêt de Soignes.

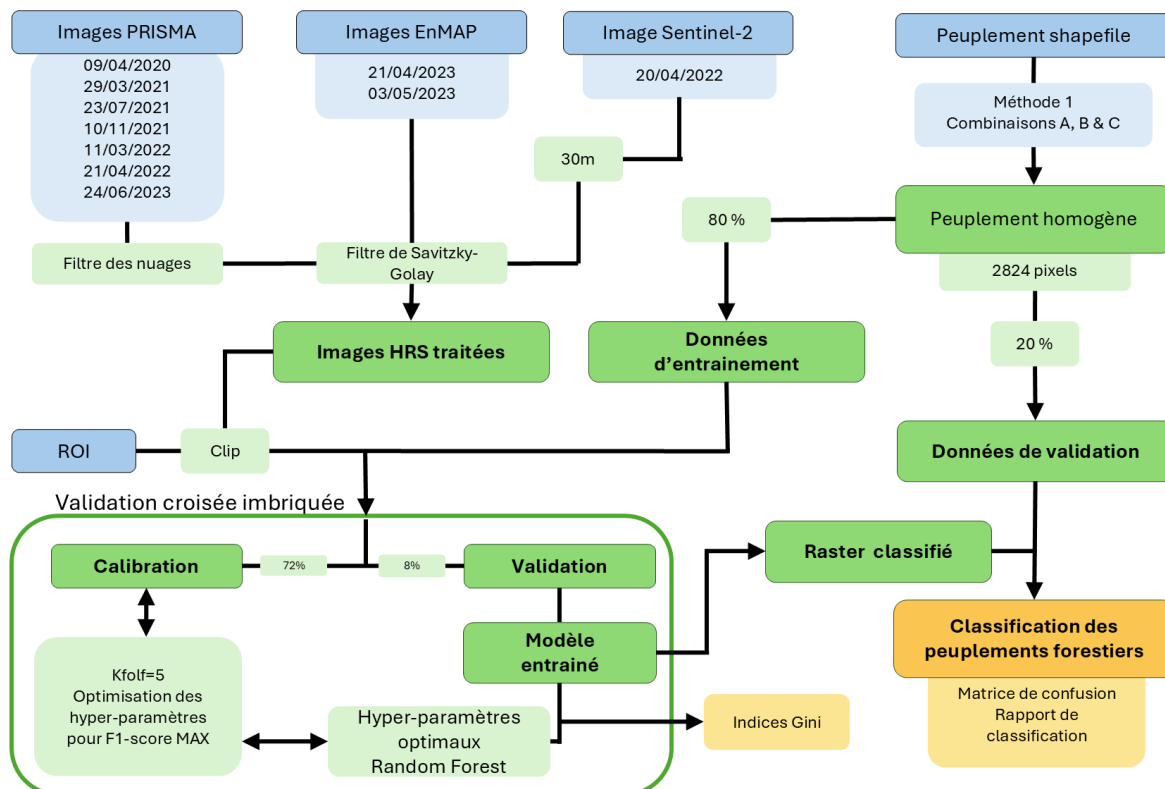


Figure 5.1 – Synthèse de la méthode appliquée

## 5.1 Données satellites

### 5.1.1 Satellites EnMAP, PRISMA et Sentinel-2

Les données hyperspectrales ont été acquises exclusivement par deux capteurs hyperspectraux. Le premier est le capteur allemand EnMAP et le second est le capteur italien PRISMA. Ces deux capteurs sont choisis pour leurs mesures hyperspectrales et leur couverture de la zone étudiée. Les principales caractéristiques de ces capteurs sont reprises dans le tableau 5.1 ci-dessous. Le satellite Sentinel-2 est également employé pour comparer les résultats de classification obtenus à partir des données HRS avec ceux issus des données MS. Cependant, étant donné que ces données sont utilisées uniquement à des fins de comparaison, une description plus concise leur est consacrée.

Table 5.1 – Comparaison des caractéristiques des capteurs EnMAP et PRISMA. (Sources : CEOS (2024) ; Segl et al. (2012))

| Paramètre                  | Capteur EnMAP     | Capteur PRISMA   |
|----------------------------|-------------------|------------------|
| Principe d'imagerie        | Pushbroom-prisme  | Pushbroom-prisme |
| Gamme spectrale VNIR       | 420-1000nm        | 400-1010nm       |
| Gamme spectrale SWIR       | 900-2450nm        | 920-2505nm       |
| Nombre de bandes VNIR      | 89                | 66               |
| Nombre de bandes SWIR      | 155               | 173              |
| Résolution spectral VNIR   | 6,5nm             | 2,78-12nm        |
| Résolution spectral SWIR   | 10nm              | 9-12nm           |
| SNR (VNIR)                 | > 400 :1 à 495nm  | > 100 :1         |
| SNR (SWIR)                 | > 150 :1 à 2200nm | > 150 :1         |
| Résolution spatiale        | 30 m              | 30 m             |
| Largeur de la fauchée      | 30 km             | 30 km            |
| Temps de revisite (VZA 5°) | 23 jours          | Variable         |
| Mémoire de masse           | 512 Gbit          | 256 Gbit         |

Par exemple, les valeurs de réflectance obtenues le 21 avril 2023 (EnMAP) et le 24 juin 2023 (PRISMA) sont illustrées par les tuiles présentées dans la figure 5.2. Ces tuiles couvrent l'ensemble de la région bruxelloise, incluant le site d'étude situé au sud-ouest de Bruxelles. Ce site se distingue par une vaste zone homogène, séparée du sud au nord par le ring de Bruxelles (R0), et de l'ouest à l'est par l'E411 et la ligne ferroviaire 161 reliant Bruxelles à Ottignies. Les deux tuiles mesurent 30 km de large et de haut. La tuile EnMAP a une résolution de 1200 pixels en hauteur et 1276 pixels en largeur, tandis que la tuile PRISMA a une résolution de 920 pixels en hauteur et 1526 pixels en largeur.

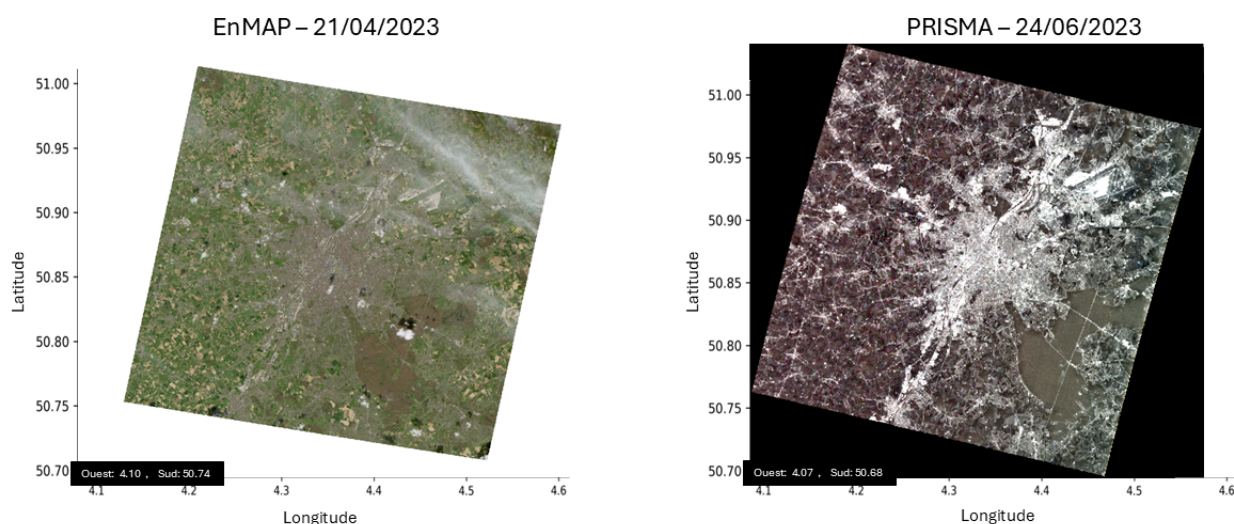


Figure 5.2 – Tuiles acquises par les capteurs EnMAP et PRISMA

### Sentinel-2

Les données du capteur Sentinel-2 seront également utilisées dans le but de comparer les résultats obtenus lors de la classification basée sur des données HRS avec ceux obtenus à partir de données MS. Cette inclusion permettra d'examiner les performances des deux méthodes de classification. Le capteur Sentinel-2 est équipé d'un instrument multispectral (MSI) qui enregistre 13 bandes spectrales avec des résolutions spatiales variées (European Space Agency, 2024) :

- Bandes bleu, vert, rouge (B2, B3, B4) : Longueurs d'onde de 490, 560, 665nm, résolution de 10 m, utilisées pour les analyses de couleur naturelle.
- Bandes proche infrarouge (NIR, B8) : 842nm, résolution de 10 m, essentielle pour l'étude de la végétation.
- Bandes d'infrarouge à ondes courtes (SWIR, B11, B12) : 1610, 2190nm, résolution de 20 m, utile utilisées pour les analyses d'humidité et de surfaces minérales.
- Bandes de correction atmosphérique (B1, B9, B10) : 443, 940, 1375nm, résolution de 60 m, utilisées pour la correction des effets atmosphériques.
- Bandes Red Edge (B5, B6, B7, B8A) : 705, 740, 783, 865nm, résolution de 20 m, idéales pour le suivi précis de la santé de la végétation.

Le champ de vision couvre 290 km avec une revisite de 5 jours (à l'équateur).

### 5.1.2 Choix des images

La sélection des images a été guidée par plusieurs critères, le principal étant la période d'acquisition. Comme l'a souligné Immitzer et al. (2019), l'utilisation d'images prises pendant le débourrement, le pic de croissance végétative ou la sénescence des feuilles améliore la classification des essences. Cela est principalement dû au décalage temporel des stades phénologiques de chacune des essences. Il est par exemple plus simple de distinguer le chêne du hêtre si seuls les chênes ont des feuilles. Les dates d'intérêt correspondant au moment où plusieurs stades phénologiques différents sont présents se basent sur des données fournies par la mission Copernicus de l'European Environment Agency

(Copernicus, 2024). Ces données permettent d’analyser la valeur du Normalized Difference Vegetation Index (NDVI) (EOS Data Analytics, 2022) en fonction du temps. Sur cette base, les valeurs de NDVI correspondantes aux peuplements homogènes sont comparées aux différents peuplements étudiés et permettent de cette manière de déterminer le stade phénologique des essences. Tel que représenté sur la figure 5.3, les profils temporels de NDVI correspondant aux peuplements de chênes et de résineux sont contrastés par rapport aux valeurs correspondant aux peuplements de hêtres. Il est donc possible de conclure que, pour la date donnée, les chênes ont des feuilles, les résineux ont des aiguilles, alors que les hêtres n’ont pas encore débourrés. Il s’agit dès lors d’une date d’intérêt pour leur discrimination.

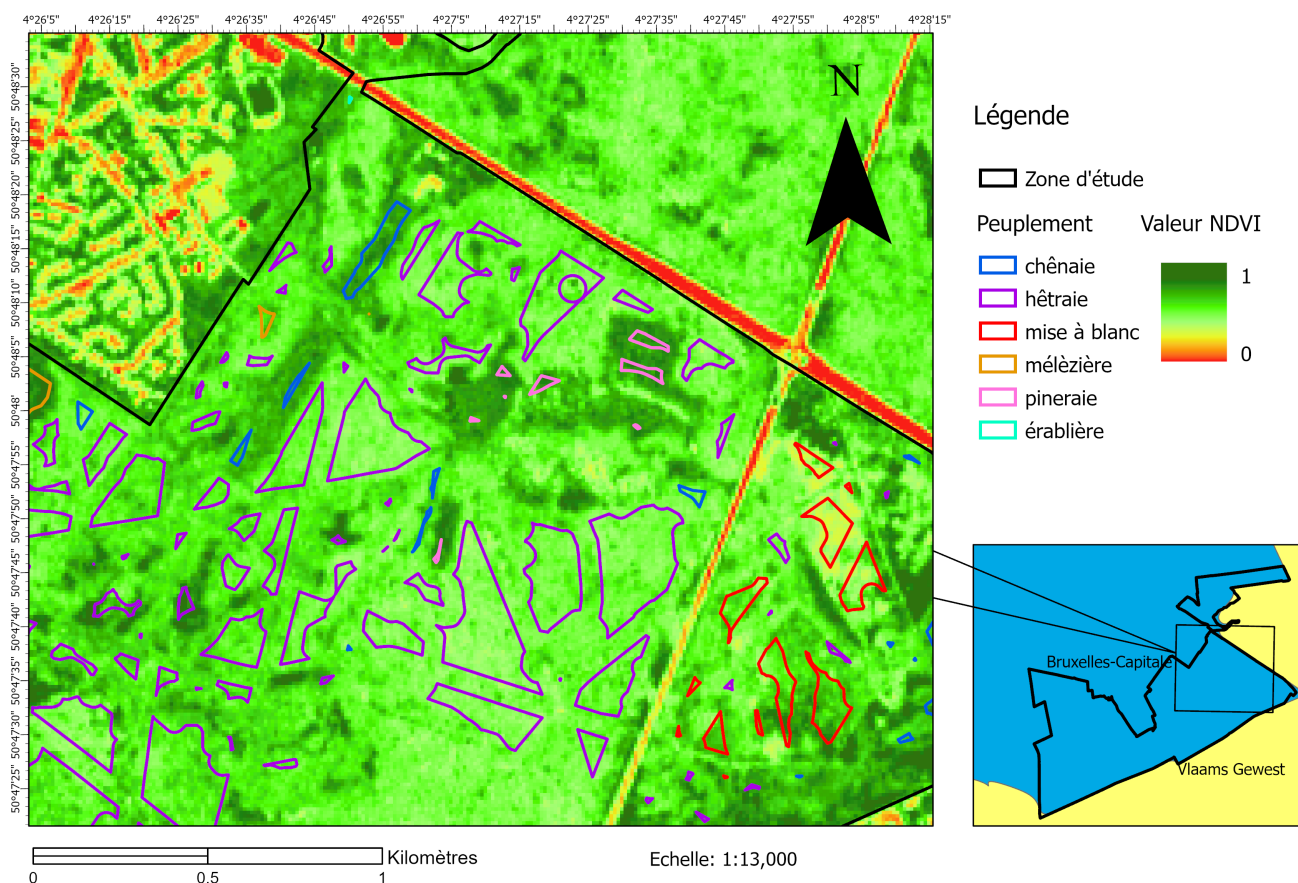


Figure 5.3 – Représentation des valeurs NDVI et des sites d’entraînement à la date du 25 avril 2021 (Copernicus, 2024).

Le tableau 5.2 représente l’ensemble des dates d’intérêt durant lesquelles une différence notable des stades phénologiques entre les essences étudiées est observable. Le mélèze étant un conifère caduc, il est également possible de les distinguer des pins suivant cette méthode. De manière à pouvoir déterminer les dates de stade de sénescence, l’utilisation d’images en vraies couleurs fut nécessaire.

Table 5.2 – Dates des images disponibles et les différents stades phénologiques observables correspondant.

| <b>Débourrement</b> |           | <b>Productivité végétale maximale</b> | <b>Sénescence des feuilles</b> |                   |
|---------------------|-----------|---------------------------------------|--------------------------------|-------------------|
| 07/04/2020          | Mélèzière | 24/06/2020                            | 10/11/2020                     | Hêtre sont jaune  |
| 09/04/2020          | Chênaie   | 19/07/2021                            | 16/11/2021                     | Hêtre sont jaune  |
| 15/04/2020          | Hêtraie   | 14/06/2022                            | 13/11/2022                     | Hêtre sont jaune  |
| 20/04/2021          | Mélèzière | 24/06/2023                            | 28/11/2023                     | Mélèze sont jaune |
| 25/04/2021          | Chênaie   |                                       |                                |                   |
| 29/04/2021          | Hêtraie   |                                       |                                |                   |
| 25/04/2022          | Chênaie   |                                       |                                |                   |
| 27/04/2022          | Hêtraie   |                                       |                                |                   |
| 15/04/2023          | Mélèzière |                                       |                                |                   |

Par la suite, certaines de ces dates pourront être combinées en fonction des différents stades phénologiques présents dans le but d’entraîner un modèle de classification sur base de différences notables entre un plus grand nombre d’essences. De cette manière, une analyse sera portée sur la classification de plusieurs images simultanément et la qualité de discrimination des essences qu’elle génère. Un second critère de sélection des images concerne la présence de nuages lors de l’acquisition de celle-ci. Les nuages formant un écran, ne permettent pas de distinguer la végétation. Le choix s’est logiquement porté sur des images ne comprenant pas ou peu de nuages. Le tableau 5.3 représente l’ensemble des images sélectionnées dans cette étude.

Table 5.3 – Date d’acquisition des images utilisées dans cette étude.

| <b>Images PRISMA</b> |                                       |
|----------------------|---------------------------------------|
| 09/04/2020           | Phase de dormance hivernale du hêtre  |
| 29/03/2021           | Phase de dormance hivernale du mélèze |
| 23/07/2021           | Pic de production végétale            |
| 11/11/2021           | Sénescence des feuilles de hêtre      |
| 21/04/2022           | Phase de dormance hivernale du mélèze |
| 21/04/2022           | Phase de dormance hivernale du hêtre  |
| 24/06/2022           | Pic de production végétale            |

| <b>Images EnMAP</b> |                                      |
|---------------------|--------------------------------------|
| 21/04/2023          | Phase de dormance hivernale du hêtre |
| 03/05/2023          | Période de débourrement du hêtre     |

| <b>Image Sentinel-2</b> |                                      |
|-------------------------|--------------------------------------|
| 20/04/2022              | Phase de dormance hivernale du hêtre |

### 5.1.3 Traitement des images

Avant toute utilisation des images à des fins d'analyse et de classification, il est nécessaire de leur appliquer différents traitements garantissant la cohérence des données et leurs pertinence. Une partie de ces traitements est effectués par les fournisseurs des données HRS (le DLR pour EnMAP et l'agence spatiale italienne pour PRISMA).

#### EnMAP

Les images EnMAP utilisées sont fournies préalablement traitées par le DLR (2024). Ces traitements reposent sur une série de niveaux (L1B, L1C, L2A) visant à produire des données de haute qualité pour l'analyse scientifique. Les images de niveau L2A, utilisées ici, contiennent des valeurs de réflectance corrigées au niveau du sol, également appelées "Bottom of Atmosphere" (BOA). Cela signifie que les données brute de luminance ont été corrigées des effets atmosphériques pour tenir compte uniquement des données provenant de la surface terrestre. Les critères d'élimination incluent des seuils de qualité spectrale et radiométrique, ainsi que des anomalies atmosphériques telles que nuages, ombres ou brume. Les produits EnMAP intègrent également des couches de qualité pour signaler les conditions spécifiques (neige, eau, etc.). À partir du niveau L1C, les masques sont ortho-rectifiés pour s'aligner sur une projection géographique standard.

#### PRISMA

De manière à détecter et éliminer les pixels inclassifiables dus à la présence de nuages ou de leur ombre, l'agence spatiale italienne fournit deux caractéristiques types du taux de réflectance pour les nuages (Agenzia Spaziale Italiana, 2021). Les images PRISMA, comme celles d'EnMAP, sont fournies sous forme de données L2A, avec des valeurs de réflectance corrigées au niveau BOA. Cela garantit que les variations atmosphériques n'interfèrent pas avec la détection des zones nuageuses ou d'autres anomalies. Dans le cas où ces conditions présentées ci-dessous sont respectées, les pixels sont considérés comme étant non utilisables pour la classification. Dans le cas inverse, les pixels sont conservés. Les équations ci-dessous représentent les seuils permettant la détection des pixels nuageux, où 'b X' représente la bande spectrale utilisée.

Nuages :

$$(b8 \geq 0.10) \text{ et } (b8 \leq 1) \text{ et } \left(\frac{b1}{b8} < 0.755\right) \text{ et } \left(\frac{b8}{b18} \geq 0.9\right) \text{ et } \left(\frac{b1}{b6} \geq 0.55\right) \text{ et } \left(\frac{b16}{b20} \leq 1.17\right) \text{ et } \\ (b15 \geq 0.05) \text{ et } (b18 \geq 0.125)$$

ou

$$(b8 \geq 0.2) \text{ et } \left(1.41 \geq \frac{b1}{b8} \geq 0.755\right) \text{ et } \left(\frac{b8}{b18} \geq 0.9\right) \text{ et } \left(\frac{b1}{b6} \geq 0.55\right) \text{ et } \left(\frac{b16}{b20} \leq 1.17\right) \text{ et } (b18 \geq 0.125)$$

Le résultat de la détection des nuages appliquée sur une image PRISMA obtenue le 21/04/2021 est représenté à la figure 5.4. La partie gauche de la figure 5.4 représente l'image et la partie droite est le

masque avec en rouge les nuages détectés.




Figure 5.4 – Détection des nuages sur une image PRISMA obtenue le 21/04/2021 avec en rouge les nuages détectés.

### Élimination des ondes non utilisables

Certaines longueurs d'onde sont fortement perturbées par la présence d'eau dans l'atmosphère. Les particules d'eau absorbent une grande partie de l'énergie transmise dans ces bandes, les rendant inexploitable. Il est donc nécessaire de les supprimer de manière à limiter le bruit dans les données. Ces bandes spectrales, ayant un taux de réflectance très faible, sont représentées sur la figure 5.5 et sont comprises entre 1300 et 1500nm et entre 1850 et 2000nm.

### Lissage du signal

Dans le but d'éliminer le bruit présent dans les spectres, les images ont été lissées grâce à la méthode de Savitzky et Golay (1964). Ce filtre se base sur l'approximation d'un polynôme  $f(x)$  permettant de minimiser la somme des carrés des écarts entre les valeurs observées et celles prévues par le modèle en utilisant la méthode des moindres carrés. Dans le but d'ajuster une fonction d'approximation  $y = f(x)$  à des données  $(x_i, y_i)$ , la méthode consiste à minimiser :

$$S = \sum_{i=1}^n (y_i - f(x_i))^2$$

L'application du filtre de Savitzky-Golay nécessite de déterminer trois paramètres. La fenêtre, la bordure et le degré du polynôme. La fenêtre correspond au nombre total de points pris en compte pour ajuster le polynôme et, est représentée par  $i$ . Elle doit être impaire pour garantir que le point central soit compris dans le polynôme. Une fenêtre plus grande lisse davantage, mais risque de gommer des détails fins. Dans le cadre de cette recherche, il a été décidé de travailler avec une valeur de  $i = 9$ . Celle-ci permet de préserver le détail de spectre tout en éliminant la présence de bruit. Ensuite, la bordure fait référence à la manière dont le filtre traite les points situés aux extrémités de la série de données. Dans le cas de cette recherche, le filtre ne s'applique qu'aux points pour lesquels il existe suffisamment de données à gauche et à droite. Pour terminer, le degré du polynôme  $f(x)$  qui correspond à la courbe lissée est représenté par  $p$  et équivaut dans ce cas à 2. Au plus  $p$  est élevé, au plus la fonction du polynôme s'approchera des valeurs observées. Ce qui signifie que le lissage du spectre sera moindre.

$$f(x) = a_0 + a_1x + a_2x^2 + \dots + a_px^p$$

Les coefficients  $a_0, a_1, \dots, a_p$  sont déterminés pour minimiser  $S$ . La fonction  $f(x)$  représentée en rouge à la figure 5.5 est le spectre lissé d'un pixel d'une image PRISMA acquise le 23/07/2021. La courbe bleue, quant à elle, représente les valeurs brutes du taux de réflectance obtenues par le spectromètre imageur.

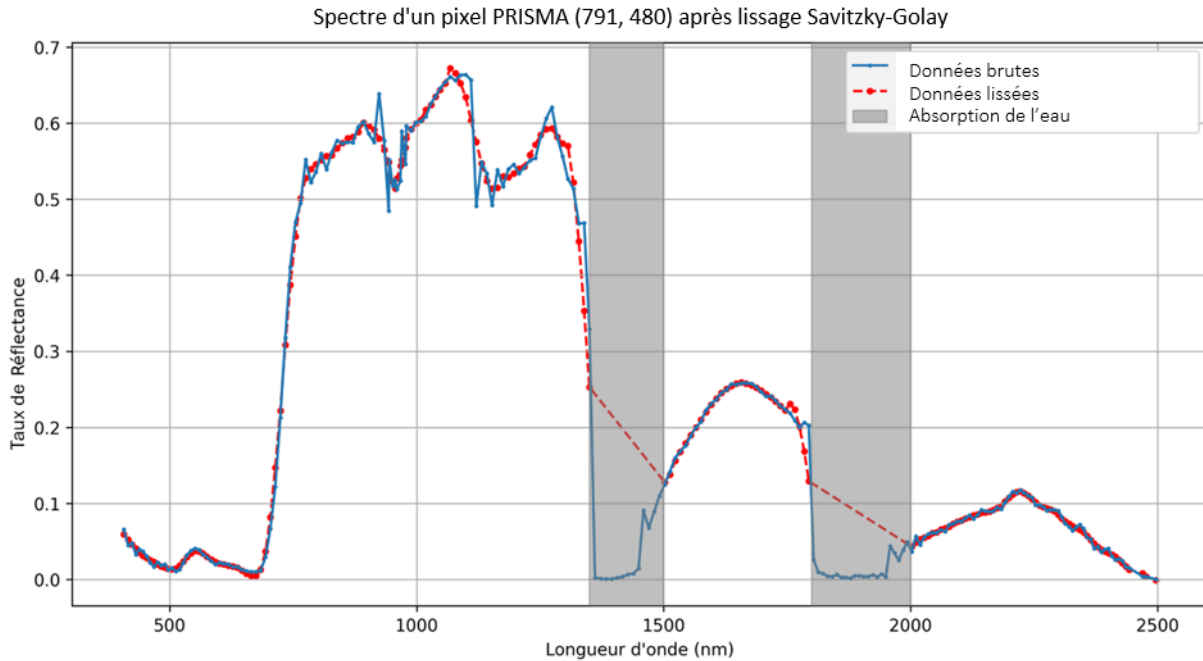


Figure 5.5 – Représentation des modifications effectuées au spectre (Image PRISMA : 23/07/2021)

Il convient d'observer que ce filtre semble approprié pour le niveau de bruit observé au-delà de 2000nm, mais qu'il pourrait également supprimer des variations produisant du bruit ou des pics d'absorption de bandes spécifiques, comme observé entre 700 et 1700nm.

### Sentinel-2

Afin de comparer l'influence de la résolution spatiale entre les données multispectrales de Sentinel-2 (S2) et les données HRS du capteur PRISMA, il a été nécessaire d'harmoniser la résolution spatiale. Ainsi, toutes les bandes spectrales acquises par S2 ont été rééchantillonnées à une résolution de 30 m, correspondant à celle du capteur PRISMA. Parmi les différentes méthodes envisageables, la méthode d'interpolation bilinéaire a été retenue. Cette méthode repose sur l'interpolation des valeurs des pixels voisins pour déterminer les nouvelles valeurs dans l'image rééchantillonnée. Elle calcule une moyenne pondérée des pixels environnants en fonction de leur distance au pixel cible. Ce processus est appliqué à l'ensemble des pixels de l'image (Michael et al. (2022)).

Parmi les avantages de cette méthode, on note qu'elle constitue également un bon compromis entre efficacité computationnelle et qualité des résultats dans de nombreuses applications. Cependant, cette méthode présente également des inconvénients. Lors d'un rééchantillonnage important, elle peut ne pas éliminer complètement les artefacts de repliement spectral (Bartwronski (2022)). Enfin, l'interpolation bilinéaire, qui suppose des données continues, est moins appropriée pour les rasters contenant des données catégorielles ou discrètes (Michael et al. (2022)).

## 5.2 Données de terrain

Des données de terrain sont nécessaires pour mener une classification des essences forestières et d'analyser son résultat. Pour cela, trois différentes bases de données ont été collectées auprès des gestionnaires forestiers (Bruxelles Environnement, 2024). Ces bases de données diffèrent par leurs méthodes de collecte et leurs types de données.

La première base de données représente l'ensemble des peuplements forestiers de la Forêt de Soignes bruxelloise. Elle est composée de polygones représentés à la figure 5.6. Elle contient des informations tel que la composition forestière pour une zone donnée ou l'occupation des sols.

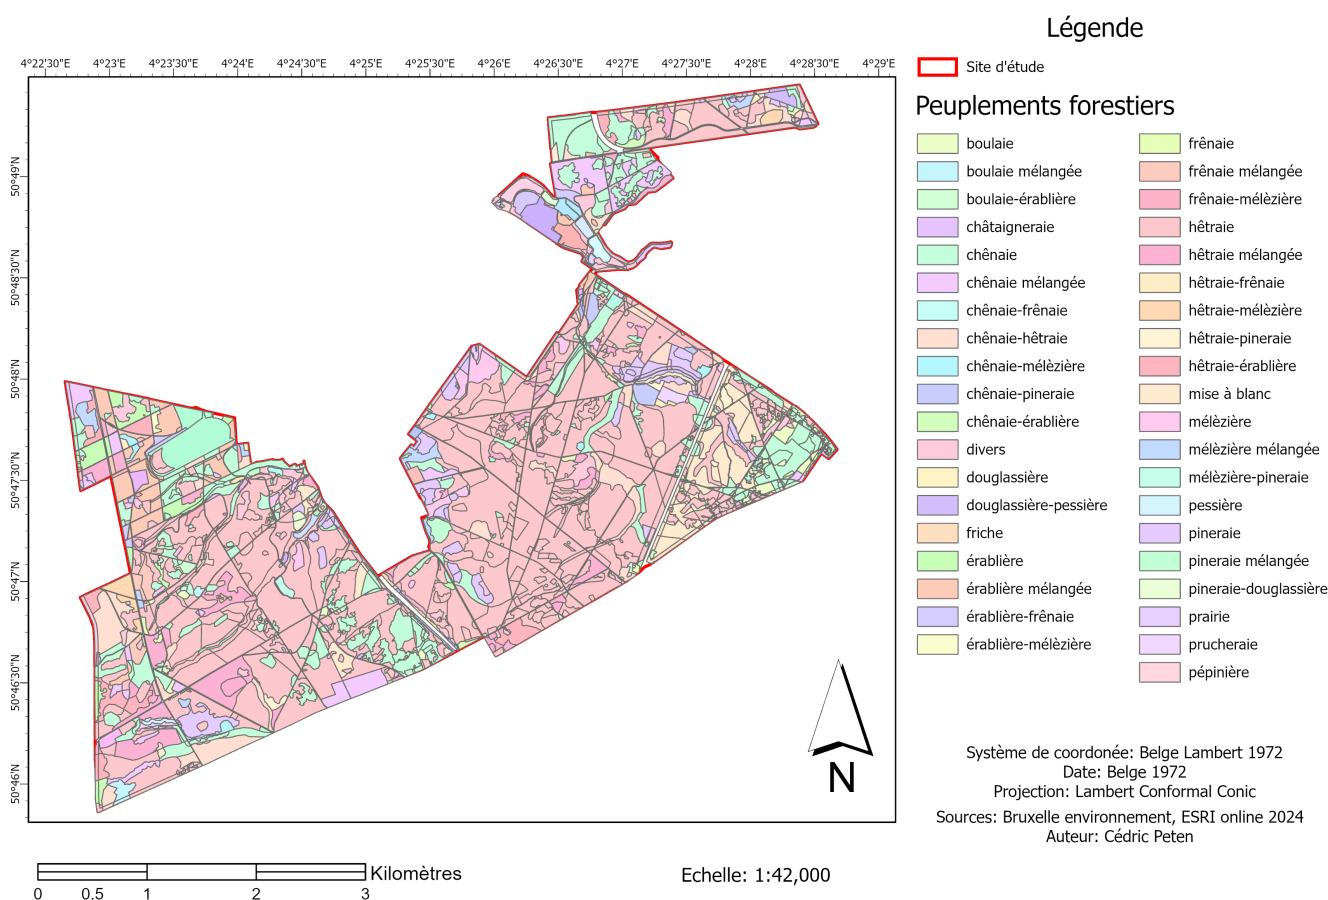


Figure 5.6 – Dataset 1 : Shapefile de polygones comprenant les informations d'occupation des sols

La seconde base de données, représentée à la figure 5.7, consiste en un inventaire permanent forestier. Il s'appuie sur un ensemble de placettes d'une surface de 10 ares. Ces placettes sont réparties de manière systématique selon une grille carrée de 200 m de côté. Cela signifie que pour chaque zone de 4 ha de forêt, 10 ares font l'objet de mesures précises. Ainsi, cette base de données est constituée de 409 placettes. Pour maintenir l'inventaire à jour, les observations au sein des placettes sont répétées tous les 4 ans. Dans chaque placette, tous les arbres dont la circonférence du tronc, mesurée à 1,5 mètre du sol, est supérieure ou égale à 40cm, font l'objet des mesures et observations suivantes : positionnement dans l'espace, identification de l'essence, mesure de la circonférence à 1,50m du sol, mesure de la hauteur totale ainsi que de la hauteur de la première grosse branche, et enfin, une évaluation de l'état sanitaire de l'arbre. Dans le cadre de cet inventaire, 5 742 arbres ont été répertoriés.

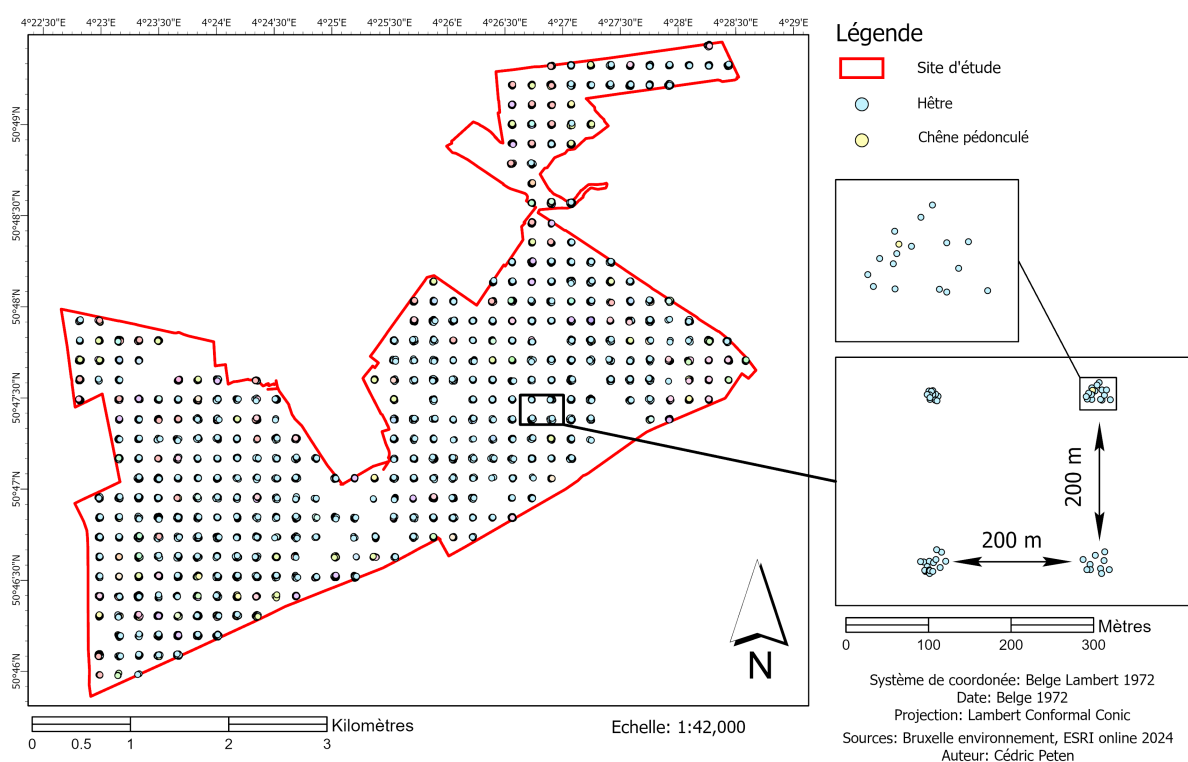


Figure 5.7 – Dataset 2 : Shapefile de points représentant l'inventaire permanent forestier mis à jour le 13 mai 2024.

La troisième et dernière base de données, représentée à la figure 5.8, est constituée par l'observation de l'ensemble des arbres objectifs. Ceux-ci sont déterminés par les gestionnaires, Bruxelles Environnement. Ces observations sont réparties de manière aléatoire parmi les arbres objectifs sur l'ensemble du site d'étude. Les informations qui y sont reprises consistent en la position dans l'espace, l'identification de l'essence et la mesure de la circonférence à 1,50 m du sol pour chaque observation. 17.329 arbres ont été observés pour cet inventaire.

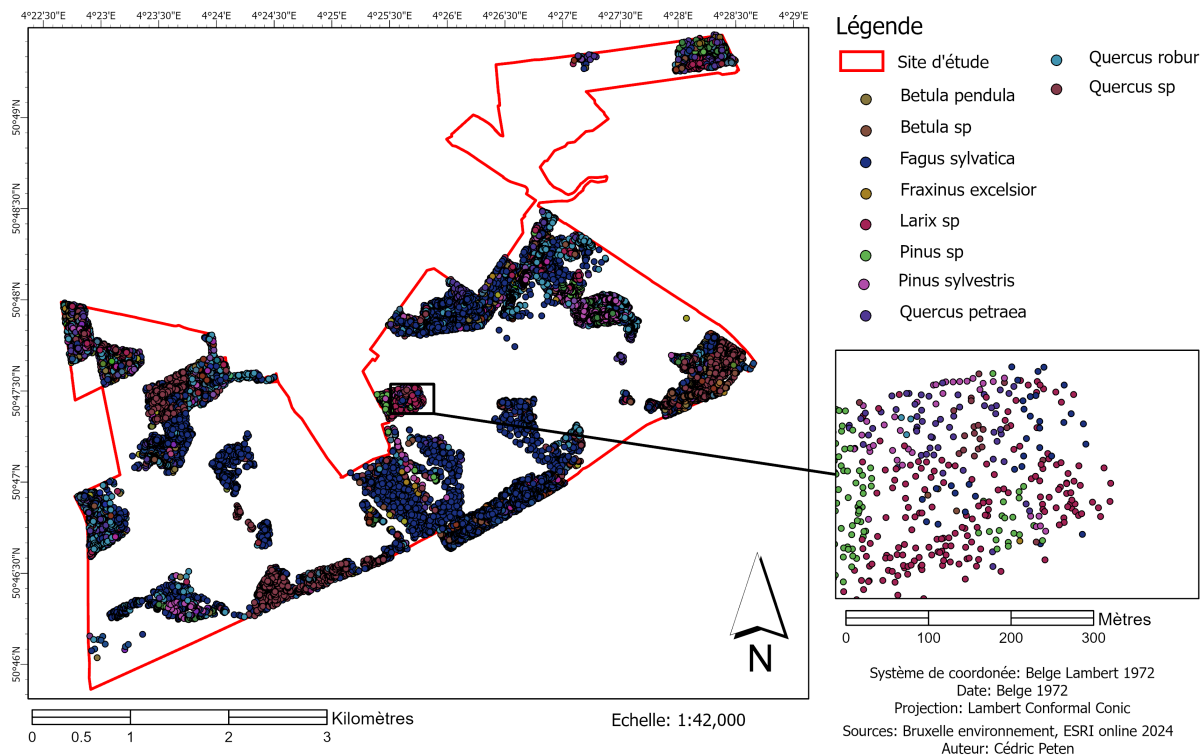


Figure 5.8 – Dataset 3 : Shapefile de points représentant l’inventaire des arbres objectifs déterminé par les gestionnaires, Bruxelles Environnement.

### 5.2.1 Sélection des peuplements homogènes

Dans le but d’isoler les zones de végétation homogènes afin de produire des échantillons d’entraînement et de validation, trois méthodes différentes ont été explorées. Chacune de ces méthodes présente des avantages et des inconvénients. Pour chaque polygone homogène isolé, un buffer négatif de 30 mètres est appliqué afin de restreindre l’influence de pixels non homogènes voisins. Le choix de cette distance correspond à la dimension d’un côté d’un pixel obtenu par EnMAP et PRISMA.

#### Méthode 1

La première méthode de discrimination des zones homogènes est de tenir compte uniquement du peuplement forestier et donc de la première base de données. Elle consiste à éliminer l’ensemble des polygones a ne pas considérer dans cette étude, tels que les polygones comprenant des zones urbanisées ou des peuplements forestiers mixtes. Suivant cette méthode, 2824 pixels homogènes sont isolés.

### Méthode 2

La seconde méthode consiste à intégrer les trois bases de données. Premièrement, la méthode 1 est appliquée afin de préserver uniquement l'ensemble des peuplements homogènes. Ensuite, en utilisant les bases de données 2 et 3 ainsi que des délimitations vectorielles des pixels EnMap et PRISMA, seuls les pixels contenant une seule et même essence forestière sont conservés et considérés comme homogènes. Suivant cette méthode, 775 pixels sont isolés.

### Méthode 3

La troisième et dernière méthode consiste à tenir compte des bases de données 2 et 3. Chacune des observations, représentées par un point, est transformée en polygones suivant la méthode des polygones de Thiessen appliquée dans le programme ARCGIS (esri, 2024). Chaque polygone est considéré comme un peuplement homogène propre à l'essence indiquée. Ensuite, l'ensemble des polygones adjacents représentant la même essence sont fusionnés. Tenant compte d'un buffer négatif de 30 mètres sur chacun de ces polygones, il est évident que les polygones de petite taille, proches d'observations d'essences différentes, sont supprimés. Cette troisième méthode permet d'obtenir 6509 pixels homogènes. Cependant, cette dernière technique exige une analyse visuelle des polygones de plus grandes tailles couvrant les zones pour lesquelles peu de données de terrain sont disponibles en les comparant à une orthophoto dans le but de supprimer les erreurs flagrantes.




Figure 5.9 – Représentation du nombre de pixels obtenus par classe et par méthode

Le tableau 5.4 reprend une liste exhaustive des avantages et inconvénients que comporte chacune des méthodes. Sur cette base, un choix a été fait sur la méthode à privilégier dans cette recherche.

Table 5.4 – Avantage et inconvénient des méthodes de sélection de pixels homogène

| Méthode   | Donnée            | Avantage                                                                                                   | Inconvénient                                                                                                                 |
|-----------|-------------------|------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------|
| Méthode 1 | dataset 1         | Grand nombre de pixels homogènes dans différentes classes                                                  | Se base sur une seule base de données.                                                                                       |
| Méthode 2 | dataset 1, 2 et 3 | Permet d'obtenir des données très fiable                                                                   | Trop peu de pixels homogènes que pour entraîner et valider un modèle de classification                                       |
| Méthode 3 | dataset 2 et 3    | Plus fiable que la méthode 1 car se base sur des méthodes d'acquisition de données précises et ponctuelles | Les observations isolées forment de grands échantillons selon les polygones de Thiessen et incluent des zones non homogènes. |

Après une comparaison qualitative et quantitative des résultats obtenus pour chacune des méthodes, c'est la méthode 1 qui a été retenue pour entraîner et valider le modèle de classification. La méthode 2 est plus sélective que la méthode 1 et se montre donc plus précise, mais dispose de trop peu de données que pour être appliquée pour cette analyse (figure 5.9). Le manque de données rend la classification des classes mal représentées très compliquée. Quant à la méthode 3, les polygones couvrant de grandes zones comprenant peu de données de terrain ne sont pas représentatifs de la réalité. Dans certains cas, un bouleau peut avoir été observé au milieu d'une hêtraie et l'ensemble de la hêtraie sera considéré comme étant une boulaie, ce qui est résolument faux. La figure 5.10 est une représentation des polygones de peuplement homogène obtenus selon la méthode 1.

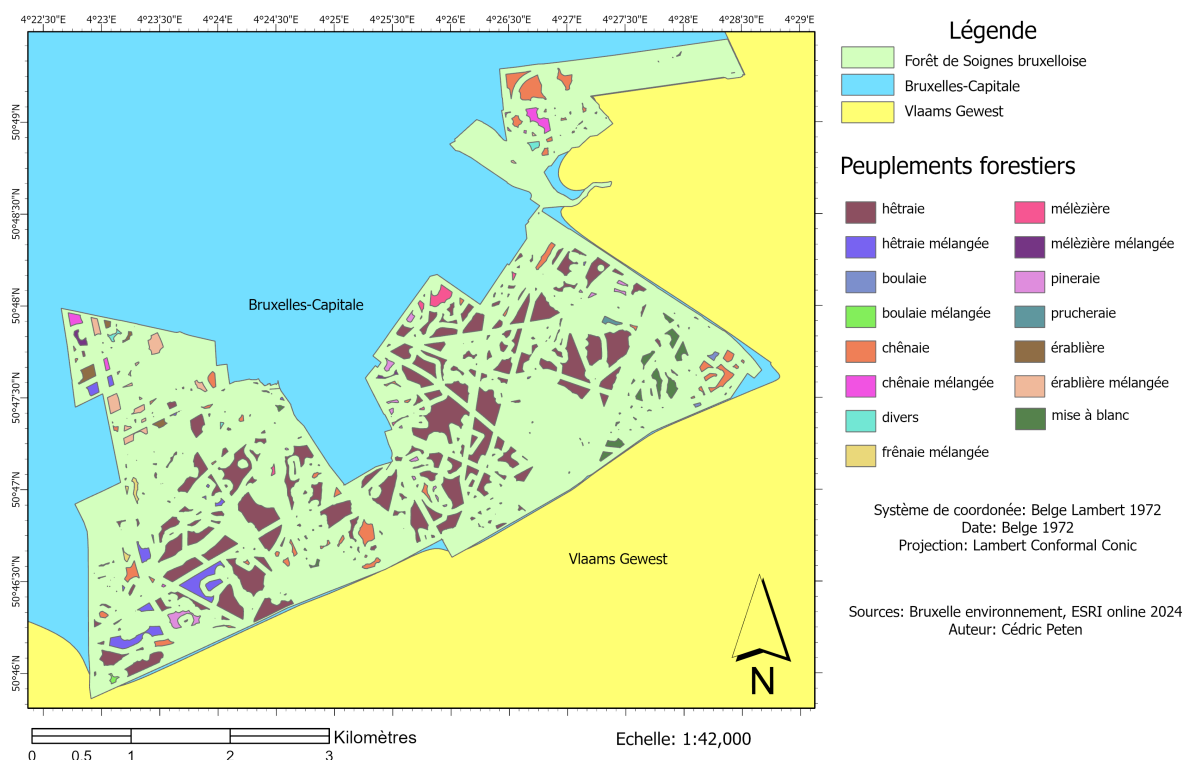


Figure 5.10 – Parcelles de peuplements forestiers homogènes.

Pour la suite de la recherche, 80% de pixels de peuplement purs déterminés par les polygones homogènes seront destinés à l’entraînement du modèle de classification (section 5.3) et 20% seront destinés à la validation finale de la classification (section 5.3.3). Cette division a été faite proportionnellement à chaque classe traitée.

## 5.2.2 Variation du nombre de classes et quantité de données disponibles

De manière à étudier l’influence du nombre de pixels présents dans chacune des classes, trois différentes combinaisons de classes ont été traitées par le modèle. La combinaison A comprend l’ensemble des classes reprises dans la base de données obtenue suivant la méthode 1 décrite dans la section 5.2. La combinaison B consiste à fusionner les classes d’arbres ayant des aiguilles (pineraie et mélèzière) en une seule classe sous le nom de résineux. Pour finir, la combinaison C a comme objectif de maximiser les distinctions entre la chênaie et la hêtraie. Il a donc été décidé de maintenir seulement ces deux classes et de regrouper les autres sous le nom de Classe Mixte. Le tableau 5.5 représente la répartition du nombre de pixels entre la calibration du modèle (colonne ‘Cal’) et la validation finale de la classification (colonne ‘Val’), et ce pour chacune des trois combinaisons de données étudiées. Tel que mentionné à la fin du point 5.2, 80% des échantillons de terrain sont utilisés à la calibration du modèle dans la colonne ‘Cal’ et les 20 % restant sont dédiés à la validation finale de la classification représentée dans la colonne ‘Val’.

Dans le cadre de cette recherche, la validation croisée imbriquée sépare également le dataset repris dans la colonne ‘Cal’ en deux. 90% de celui-ci est dédié à l’entraînement du modèle, alors que les 10 % restant sont dédiés à la validation du modèle de classification.

Table 5.5 – Répartition du nombre de pixels dans chaque classe en fonction de la combinaison des données appliquées.

| Classe       | Combinaison A |     | Combinaison B |     | Combinaison C |     |
|--------------|---------------|-----|---------------|-----|---------------|-----|
|              | Cal           | Val | Cal           | Val | Cal           | Val |
| Chênaie      | 245           | 63  | 245           | 63  | 245           | 63  |
| Hêtraie      | 1758          | 441 | 1758          | 441 | 1758          | 441 |
| Mise à blanc | 77            | 22  | 77            | 22  |               |     |
| Érablière    | 98            | 26  | 98            | 26  |               |     |
| Pineraie     | 36            | 10  |               |     |               |     |
| Mélèzière    | 17            | 31  |               |     |               |     |
| Résineux     |               |     | 53            | 41  |               |     |
| Classe mixte |               |     |               |     | 228           | 89  |

Si, dans certains cas, la répartition entre le nombre de pixels dédié à la calibration du modèle et à la validation de la classification ne respecte pas le ratio 80-20, cela est dû au fait que ce ratio a été réalisé à partir des polygones homogènes. Il se peut que, dans certains cas, dû au faible nombre de différents polygones dans une classe, cette répartition soit biaisée, tel est le cas pour la classe ‘Mélèzière’.

## 5.3 Modèle de classification

Le modèle de classification choisi dans cette étude est le Random Forest. Tel que mentionné dans la revue de littérature, ce modèle est le plus adapté à des applications similaires à cette recherche. L'utilisation du Random Forest est couplée à une validation croisée imbriquée permettant d'adapter les hyperparamètres du modèle Random Forest en fonction du jeu de données fourni pour la classification.

### 5.3.1 Calibration du modèle

L'utilisation de la validation croisée imbriquée a comme objectif d'adapter les hyperparamètres du modèle Random Forest de manière à ce que le f1-score de chaque classe soit maximisé. Cette méthode permet d'entraîner et d'adapter le modèle de classification sur la base de l'ensemble des données qui lui sont fournies en alternant la partie des données dédiée à l'entraînement et celle dédiée à la validation du modèle.

Selon le principe de la validation croisée imbriquée, le modèle va traiter à 5 reprises l'ensemble du dataset. Pour chacune des 5 reprises, le modèle va tester les hyperparamètres du Random Forest représenté dans le tableau 5.6. Seuls les hyperparamètres ayant obtenu le f1-score le plus élevé seront appliqués dans la classification finale.

Table 5.6 – Valeur des hyperparamètres testés lors de la validation croisée imbriquée.

|                  |     |     |      |
|------------------|-----|-----|------|
| n estimators     | 100 | 200 | 300  |
| max depth        | 10  | 20  | None |
| min sample split | 2   | 5   | 10   |
| min sample leaf  | 1   | 2   | 4    |

Ceci implique 81 différentes combinaisons d'hyperparamètres qui sont testées à 5 reprises différentes. Les hyperparamètres sont choisis en fonction du F1 score maximal qu'ils produisent pour les classes étudiées. De cette manière, le modèle Random Forest est adapté à chaque image et permet de fournir une meilleure classification des peuplements forestiers.

### 5.3.2 Évaluation de l'importance des bandes spectrales

L'utilisation du modèle Random Forest permet d'identifier les bandes spectrales les plus discriminantes pour la séparation des classes. L'importance des bandes spectrales est calculée à partir de la réduction de l'impureté dans les nœuds de l'arbre, ce qui permet d'évaluer l'impact de chaque bande sur le processus de classification.

L'importance d'une bande  $f_i$  est mesurée par la réduction de l'impureté générée dans un nœud  $t$  lorsqu'on divise les données à l'aide de cette bande (Breiman et al., 1984). Cette réduction est donnée

par la formule suivante :

$$\Delta G(f_i) = G(t) - \sum_{t'} p(t') G(t'|f_i)$$

où :

- $G(t)$  est l'impureté du nœud avant la division,
- $p(t')$  est la proportion des échantillons dans le nœud  $t'$ ,
- $G(t'|f_i)$  est l'impureté du nœud  $t'$  après la division selon la bande  $f_i$ ,
- $\sum_{t'} p(t') G(t'|f_i)$  est l'impureté moyenne pondérée des nœuds enfants après la division basée sur la bande  $f_i$ .

Ensuite, l'importance totale d'une bande  $f_i$  dans l'ensemble du modèle est calculée et correspond à la somme des réductions d'impureté à chaque fois que cette bande est utilisée pour diviser un nœud dans les arbres. Pour finir, les importances  $f_i$  sont ensuite normalisées pour chaque classe, de sorte que la somme des importances des bandes pour chaque classe soit égale à 1. Cela permet de comparer les contributions relatives des différentes bandes spectrales dans chacune des classes étudiées.

Les bandes identifiées comme les plus importantes par le modèle sont celles qui contribuent le plus à la réduction de l'impureté des nœuds, facilitant ainsi la séparation des classes. Elles jouent donc un rôle clé dans la prise de décision du modèle. Cependant, selon, plusieurs nuances doivent être prises en compte avant de tirer des conclusions de ces résultats.

- **Impact d'autres facteurs :** Bien que certaines bandes soient plus importantes en moyenne, leur rôle peut varier selon les branches des arbres. Une bande peut être cruciale dans un nœud, mais moins significative dans d'autres sections de l'arbre.
- **Interactions complexes entre les bandes :** Random Forest s'appuie sur des combinaisons de bandes spectrales pour la classification. Une bande semble parfois moins importante isolément, mais elle peut être déterminante lorsqu'associée à d'autres.
- **Variation de l'importance selon la classe :** Les importances calculées par Random Forest sont basées sur une évaluation globale, mais elles peuvent varier en fonction de la configuration locale de chaque arbre et des classes dans le modèle.

### 5.3.3 Validation du modèle

La validation du modèle de classification a comme objectif de déterminer la capacité prédictive du modèle combinée aux données, et, dans un second temps, elle permet de comparer les résultats en fonction de la méthode utilisée. Cette comparaison est rendue possible grâce au calcul de différents indices statistiques. Ceux-ci sont représentés pour chacune des classifications faites sous la forme du tableau 5.7 et sont détaillé dans les points ci-dessous (Duda et al., 2001).

Table 5.7 – Tableau des métriques de performance de la classification par classe avec  $i$  le nombre de classe

| Classe                    | Précision | Rappel | F1-Score | Support |
|---------------------------|-----------|--------|----------|---------|
| 1                         |           |        |          |         |
| 2                         |           |        |          |         |
| ...                       |           |        |          |         |
| $i$                       |           |        |          |         |
| <b>Exactitude Globale</b> |           |        |          |         |
| <b>Moyenne Macro</b>      |           |        |          |         |
| <b>Moyenne pondérée</b>   |           |        |          |         |

Premièrement, la **précision** mesure la proportion des prédictions positives correctes par rapport au total des prédictions positives effectuées. En d'autres termes, elle indique à quel point les prédictions positives sont fiables. Elle est donnée par la formule :

$$\text{Précision} = \frac{VP}{VP + FP}$$

où  $VP$  est le nombre de vrais positifs et  $FP$  est le nombre de faux positifs. Une précision élevée signifie que peu de faux positifs sont produits par le modèle.

Ensuite, le **rappel** mesure la capacité du modèle à identifier correctement toutes les instances positives. Il est donné par :

$$\text{Rappel} = \frac{VP}{VP + FN}$$

où  $FN$  est le nombre de faux négatifs. Un rappel élevé indique que le modèle est efficace pour ne pas manquer les instances positives, même s'il produit quelques faux positifs.

Le F1-score est une moyenne harmonique entre la précision et le rappel. Il équilibre ces deux métriques pour fournir une seule mesure de performance, surtout utile lorsque les classes sont déséquilibrées tel que c'est le cas dans cette étude. Effectivement, la classe 'Hêtraie' est beaucoup mieux représentée que d'autre classe (figure 5.5). La formule est donnée par :

$$F1 = 2 \cdot \frac{\text{Précision} \cdot \text{Rappel}}{\text{Précision} + \text{Rappel}}$$

Cette métrique atteint sa valeur maximale ( $F1 = 1$ ) lorsque la précision et le rappel sont tous deux parfaits. En d'autres mots, cela est le cas lorsqu'il n'y a pas de faux positifs et de faux négatifs, et donc, que l'ensemble des prédictions de cette classe soient bien classées et qu'aucun élément d'autres classes ne soit attribué à cette classe.

Le **support** représente le nombre total de pixels appartenant à une classe donnée utilisé lors de la validation. Il ne s'agit pas d'une métrique de performance, mais plutôt d'une statistique descriptive qui indique la taille des classes. Par exemple, pour la hêtraie, le support est égale à 441 pixels (figure 5.5).

**L'exactitude globale** évalue le pourcentage de prédictions correctes parmi l'ensemble des prédictions effectuées. Elle est calculée comme :

$$\text{Précision globale} = \frac{\text{Nombre de prédictions correctes}}{\text{Nombre total d'échantillons}}$$

où en utilisant les termes de la matrice de confusion :

$$\text{Précision globale} = \frac{VP + VN}{VP + VN + FP + FN}$$

où  $VN$  représente les vrais négatifs. C'est une mesure simple mais limitée dans le cas de classes déséquilibrées tel c'est le cas dans cette étude.

La **moyenne macro** correspond à la moyenne arithmétique des métriques (précision, rappel, F1-score) calculées séparément pour chaque classe, sans tenir compte de leur support. Pour une métrique  $M_i$  associée à chaque classe  $i$ , elle est calculée comme :

$$\text{Moyenne Macro} = \frac{1}{n} \sum_{i=1}^n M_i$$

où  $n$  est le nombre de classes. Cette approche accorde un poids égal à chaque classe, quelle que soit sa taille. Si cette valeur est faible, cela signifie que le modèle de classification ne performe pas bien de manière uniforme dans toutes les classes.

Pour finir, la **moyenne pondérée** prend en compte le support de chaque classe, ce qui permet de pondérer les métriques en fonction de la taille des classes. Elle est calculée comme :

$$\text{Weighted Avg} = \frac{\sum_{i=1}^n M_i \cdot \text{Support}_i}{\sum_{i=1}^n \text{Support}_i}$$

où  $\text{Support}_i$  est le nombre d'échantillons pour la classe  $i$ . Cette approche est particulièrement utile en cas de déséquilibre entre les classes et sera donc analysée avec attention.

Ces métriques permettent d'évaluer les performances du modèle de manière globale (*précision, moyenne macro, moyenne pondérée*) et par classe (*précision, rappel, F1-score*). Leur interprétation dépend du contexte, notamment en cas de déséquilibre des classes tel c'est le cas dans cette étude. Le F1-score et la moyenne pondérée sont particulièrement importants dans ce cas.

---

---

# CHAPITRE 6

---

## RÉSULTATS

Ce chapitre présente les résultats des classifications pour la reconnaissance des peuplements forestiers de la forêt de Soignes à partir d'images HRS. Chaque classe a été étudiée individuellement selon ses spectres moyens obtenus lors des différentes phases phénologiques, lissés par la méthode de Savitzky-Golay (voir point 5.1.3), en utilisant les pixels des polygones homogènes de chaque classe. Une analyse a évalué le pouvoir discriminant des bandes spectrales lors de la classification avec le modèle Random Forest, utilisant 5 répétitions pour tester les hyperparamètres et la combinaison A des classes (Annexe O). Les résultats de trois différentes combinaisons de classes ont été analysés dans le but d'évaluer l'impact du nombre de pixels sur la qualité de la classification. Une analyse des résultats pour différentes combinaisons d'images phénologiques a également été réalisée, suivie d'une comparaison avec les performances de classification basées sur les données Sentinel-2. En raison des disparités entre classes et de la surreprésentation de la classe "Hêtraie", l'exactitude globale, seule métrique de performance, doit être interprétée avec prudence. Une haute exactitude peut être obtenue même avec une mauvaise classification des autres classes. Pour évaluer solidement les performances du modèle, des métriques spécifiques à chaque classe, telles que les F1-scores, sont privilégiées, pondérées selon le nombre de pixels par classe (colonne "Support" dans le tableau 5.7). Afin de comparer les cartes des prédictions de classes avec les données de terrain, ces dernières sont présentées en annexe B.

### 6.1 Périodes d'acquisition et signatures spectrales

Les résultats de ce paragraphe proviennent de la classification réalisée avec le modèle Random Forest, utilisant 5 répétitions pour optimiser les hyperparamètres. Cette classification repose sur la combinaison A des classes suivantes : Chênaie, Hêtraie, Pineraie, Érablière, Mise à blanc et Mélèzière. Les spectres des peuplements sont représentés par la moyenne de la réflectance des pixels échantillons acquis par les capteurs EnMAP et PRISMA. Le nombre de pixels par classe est repris dans le tableau 6.1.

Table 6.1 – Nombre de pixels utilisés pour calculer les spectres moyens de chaque peuplement étudié.

| Classe           | Hêtraie | Chênaie | Érablière | Mise à blanc | Mélèzière | Pineraie |
|------------------|---------|---------|-----------|--------------|-----------|----------|
| Nombre de pixels | 2199    | 308     | 124       | 99           | 48        | 46       |

### 6.1.1 Phase de dormance hivernale du mélèze

Cette période correspond au moment où le pin (*Pinus sp*), une espèce sempervirente, conserve ses aiguilles, tandis que le mélèze (*Larix sp*), étant un conifère caduc, a perdu les siennes. Elle se situe entre la fin de l'automne ou en hiver, après la défeuillaison des feuillus et avant la reprise végétative au printemps.

Les signatures spectrales moyenne et lissée des classes étudiées pour l'image acquise par PRISMA le 29/03/2021 sont représenté par la figure 6.1. L'ensemble des signatures spectrales présentent un maximum de réflectance à 1300nm mais à des niveaux très différents. La classe "Mise à blanc" a une réflectance plus faible que les autres classes sur l'ensemble du spectre. Les signatures spectrales des classes "Chênaie" et "Hêtraie" sont similaires pour les longueurs d'onde de moins de 1500nm et se distinguent plus clairement sur le reste du spectre. La classe "Pineraie" a une réflectance bien plus élevée que la "Mélèzière", même si la dorme de leurs profils restent semblables. La classe "Érablière" présente une réflectance globalement plus élevée que les autres peuplements étudié. Cela peut s'expliquer par une activité végétale plus importante au sein de cette classe pendant cette période, ou par la présence de peuplements peu denses, ce qui indique que le sous-bois a une influence significative sur ce profil spectral. Les ondes comprises entre 800nm et 1300nm présentent les différences les plus marquées entre les classes, suggérant leur importance potentielle pour la discrimination des peuplements.

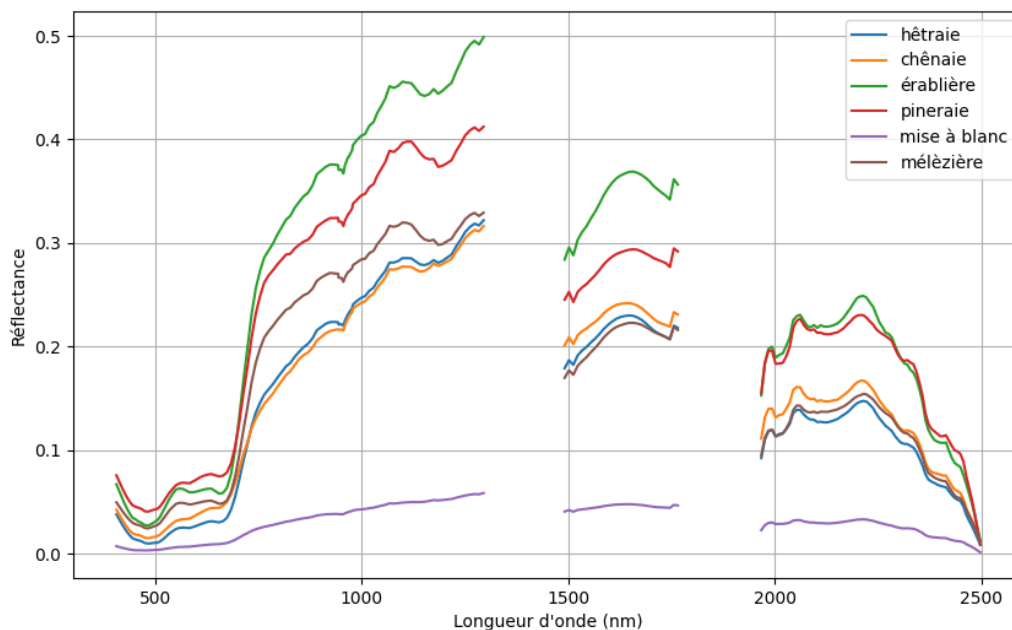


Figure 6.1 – Signature spectrale moyenne et lissée des peuplements forestiers obtenue sur la base des valeurs absolues de réflectance des pixels inclus dans les polygones de peuplements homogènes. (PRISMA : 29/03/2021)

La bande spectrale b87 comprenant les ondes de longueur de 1175nm montre une efficacité particulière pour distinguer les classes de hêtre et de chêne lors de la classification (Annexe O). Les scores F1 montrent des performances élevées pour la "Hêtraie" (0,87). La classe "Chênaie" obtient un score plus faible (0,24) et les autres classes obtiennent un F1-score de 0, ce qui indique qu'aucun pixel n'a été correctement classé. Le rappel de la classe "Hêtraie" (0,99) et la matrice de confusion révèle une sur-prédiction des pixels dans la classe "Hêtraie". Celle-ci regroupe la majorité des pixels prédits (Annexe C).

### 6.1.2 Phase de dormance hivernale du hêtre

Cette phase correspond au moment où toutes les classes étudiées sont sorties de leur dormance, sauf le hêtre. Ce dernier est alors la seule espèce forestière à ne pas encore posséder de feuilles. Trois acquisitions sont analysées : une par PRISMA et deux par EnMAP.

#### PRISMA

L'image acquise par le capteur PRISMA le 21 avril 2022 permet de distinguer les spectres des différents peuplements forestiers à la figure 6.2. Dans les ondes VNIR, trois groupements différents de spectres sont constatés suggérant une bonne discrimination de ces groupes sur base de ces données. Premièrement, la classe "érablière" présente une réflectance élevée par rapport aux autres peuplements forestiers. Ces derniers sont similaires pour les ondes VNIR, où ils ne dépassent pas une valeur absolue

de réflectance de 0,17. Dans les ondes SWIR, la classe "Hêtraie" présente des valeurs de réflectance plus élevées et se distingue des autres classes. Cela est également le cas pour les ondes caractéristiques de la couleur rouge comprise entre 600nm et 700nm. Ensuite, la classe "érablière" présente un pic de réflectance dans la catégorie des ondes visibles caractéristique de la couleur verte (500nm et 600nm).




Figure 6.2 – Signature spectrale moyenne et lissée des peuplements forestiers obtenue sur la base des valeurs absolues de réflectance des pixels inclus dans les polygones de peuplements homogènes. (PRISMA : 21/04/2022)

Cette classification obtient des résultats élevés pour les classes "Hêtraie" et "Chênaie", avec des F1-scores de respectivement 0,94 et 0,90. Les bandes spectrales permettant une bonne distinction lors de la classification de ces deux classes sont les bandes allant de b29 à b34 représentant les ondes comprises entre 630nm et 685nm (Annexe O). Cela correspond aux ondes absorbées par les chlorophylles a présentes dans les feuilles. Les classes "Pineraie" et "Mélèzière" obtiennent toutes les deux les f1-score les plus faibles avec des valeurs de respectivement 0,21 et 0,20. Selon la matrice de confusion, 18 pixels de mélèze sur 27 sont prédits comme faisant partie de la classe "Pineraie", suggérant une grande confusion entre ces deux classes. Lors de cette classification, la classe "Mise à blanc" obtient un F1-score de 0,54 et un rappel de 0,45. Elle est principalement caractérisée par la bande spectrale 84 (1142nm). Cette classe présente une réflectance globalement plus faible que les classes de peuplement forestier (Annexe E).

### EnMAP

Les deux images étudiées dans ce paragraphe ont été acquises par le capteur EnMAP à deux dates proches les unes des autres : les 21 avril 2023 et 3 mai 2023. Les deux graphiques présentés sous la figure 6.3 représentent les spectres moyens de chaque peuplement étudié. Ces spectres sont globalement similaires les uns aux autres. Les valeurs absolues de réflectance pour chaque classe sont également

similaires pour les deux dates, avec des valeurs élevées pour la classe "Mise à blanc" dues au démarrage du recouvrement forestier. La classe "Pineraie" présente une réflectance légèrement plus élevée qu'en hiver, mais est plus sombre que les autres peuplements en phase feuillée.




Figure 6.3 – Signature spectrale moyenne et lissée des peuplements forestiers obtenue sur la base des valeurs absolues de réflectance des pixels inclus dans les polygones de peuplements homogènes. (EnMAP, Annexe H : 21/04/2023 et Annexe I : 03/05/2023)

Les données acquises le 3 mai 2023 obtiennent les meilleurs résultats de prédiction des classes de cette étude. Ceux-ci sont représentés à la figure 6.2. Les classes ayant obtenu les meilleures performances de classifications sont la hêtraie et la mélèzière. Elles ont toutes les deux obtenu un F1-score de 0,95 et un rappel de 0,94. Les moins bons résultats concernent la classe "Pineraie", avec un F1-score de 0,57 et un rappel de 0,4. Les bandes spectrales permettant une meilleure distinction de la classe "Hêtraie" sont comprises entre les bandes b1 à b14 et b42 à b54. Elles représentent les ondes comprises de 420nm à 482nm et 623nm à 707nm (Annexe O). Cela correspond aux ondes fortement absorbées par les chlorophylles a et b. La moyenne macro fait partie des plus élevées de cette recherche, avec un score de 0,79, ce qui signifie une bonne prédiction dans l'ensemble des classes étudiées. La majeure partie des erreurs de prédiction survient dans la classe "Hêtraie", qui présente une sur-prédiction des pixels provenant d'autres classes (Annexe I).

Table 6.2 – Mesures de performance des différentes classes de peuplements forestiers (EnMAP : 2023/05/03)

| Classe               | Précision   | Rappel      | F1-score    | Support    |
|----------------------|-------------|-------------|-------------|------------|
| Chênaie              | 0.73        | 0.97        | 0.83        | 63         |
| Hêtraie              | 0.95        | 0.94        | 0.95        | 441        |
| Mise à blanc         | 0.70        | 0.64        | 0.67        | 22         |
| Mélèzière            | 0.97        | 0.94        | 0.95        | 31         |
| Pineraie             | 1.00        | 0.40        | 0.57        | 10         |
| Érablière            | 1.00        | 0.65        | 0.79        | 26         |
| <b>Moyenne macro</b> | <b>0.89</b> | <b>0.76</b> | <b>0.79</b> | <b>593</b> |
| Exactitude globale   | 0.91        |             |             |            |

Les données acquises le 21 avril 2023 obtiennent également de bons résultats. Les meilleures prédictions concernent les classes "Hêtraie" et "Mise à blanc", avec des F1-scores respectifs de 0,99 et 0,80. La matrice de confusion 6.3 suggère une bonne prédiction de la classe "Hêtraie" sans pour autant avoir de overfitting. Seuls 8 pixels d'autres classes y sont prédits sur les 593 pixels représentés. Les données prédisant le mieux la classe "Hêtraie" correspondent aux bandes allant de b57 à b64 représentant les ondes ayant une longueur de 730nm à 780nm. Cela correspond au saut de réflectance observable sur les spectres représentés à la figure 6.3. La classe "Mélèzière" est la moins bien prédite, avec un F1-score de 0,41. Dans ce cas, c'est la classe "Chênaie" qui est sur-représentée lors des prédictions et qui intègre la majeure partie des pixels des classes "Mélèzière" et "Érablière" (figure 6.3).

Table 6.3 – Matrice de confusion (EnMAP 21/04/2021)

Les colonnes de la matrice représentent les classes identifiées après le traitement dans l'échantillon de contrôle (classe prédite). Les lignes correspondent aux classes initiales de l'échantillon de contrôle (classe observée sur le terrain). Les éléments diagonaux indiquent le nombre de points appartenant à la fois à la classe de contrôle et à la classe résultante du traitement d'image.

|              | Chênaie   | Hêtraie    | Mise à blanc | Mélèzière | Pineraie | Érablière |
|--------------|-----------|------------|--------------|-----------|----------|-----------|
| Chênaie      | <b>58</b> | 0          | 0            | 0         | 0        | 5         |
| Hêtraie      | 3         | <b>436</b> | 2            | 0         | 0        | 0         |
| Mise à blanc | 4         | 2          | <b>16</b>    | 0         | 0        | 0         |
| Mélèzière    | 21        | 0          | 0            | <b>9</b>  | 0        | 1         |
| Pineraie     | 0         | 3          | 0            | 4         | <b>3</b> | 0         |
| Érablière    | 13        | 3          | 0            | 0         | 0        | <b>10</b> |

### 6.1.3 Période de production végétale maximale (NDVI maximale)

Cette période correspond au moment où la végétation atteint son activité photosynthétique maximale, avec une couverture foliaire dense et un indice NDVI maximal. Toutes les classes étudiées présentent des niveaux de productivité élevés, reflétant un état de développement optimal. Pour cette période, une acquisition datant du 24 juin 2023 et provenant du capteur PRISMA est étudiée.

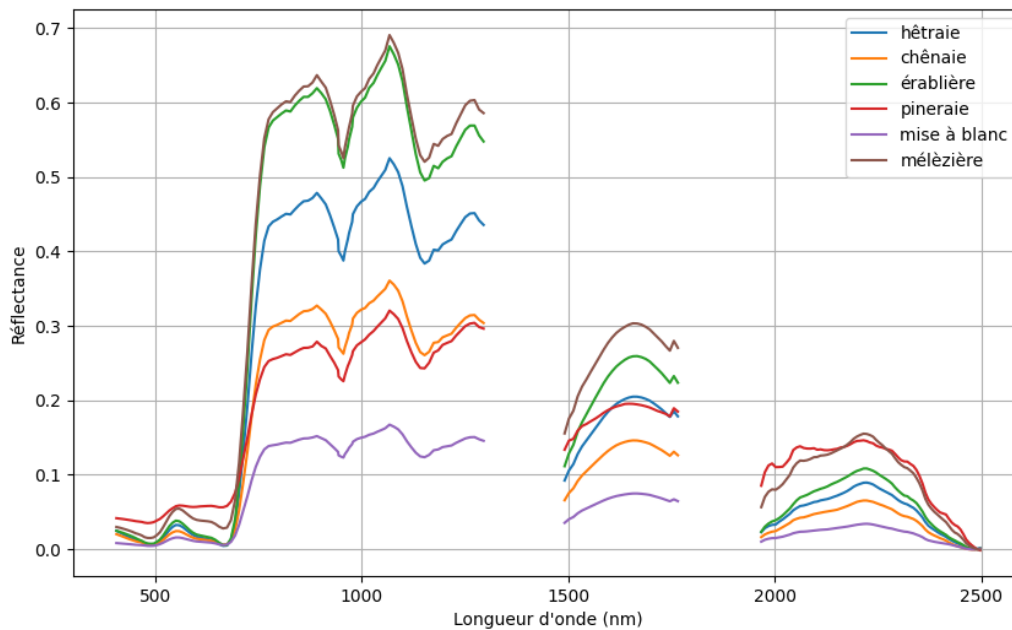


Figure 6.4 – Signature spectrale moyenne et lissée des peuplements forestiers obtenue sur la base des valeurs absolues de réflectance des pixels inclus dans les polygones de peuplements homogènes. (PRISMA : 24/06/2023)

Les spectres présentés à la figure 6.4 suggèrent que l'ensemble des peuplements possèdent des feuilles. Cela se constate par les faibles valeurs de réflectances pour les bandes absorbées par les chlorophylles a et b ( $\lambda = [400, 500] \& [600, 700] \text{nm}$ ). Une augmentation de la réflectance apparaît dans la région du vert ( $\lambda = [500, 600] \text{nm}$ ). Dans les ondes NIR, les spectres présentent des courbes similaires avec des niveaux de réflectance différents. Les classes "Érablière" et "Mélèzière" montrent une réflectance élevée, alors que la classe "Mise à blanc" absorbe davantage ces longueurs d'onde.

Les F1-scores issus de la classification sur base de ces données sont faibles, car tous les types de végétation sont bien verts. La classe "Hêtraie" a un F1-score de 0,90, mais cela provient d'une sur-prédiction de cette classe. La matrice de confusion montre que la majorité des pixels mal prédits d'autres classes sont repris dans la classe "Hêtraie". Les classes "Pineraie" et "Mélèzière" obtiennent les moins bonnes prédictions avec aucun pixel correctement prédit (Annexe G).

### 6.1.4 Phase de sénescence

La période de sénescence correspond au moment où la végétation commence à perdre sa vigueur photosynthétique, marquée par une diminution progressive de l'activité des feuilles et une baisse des indices de végétation, notamment le NDVI. Les classes de peuplements de feuillus entrent en transition vers une phase de dormance. L'analyse de cette période se base sur une image acquise par le capteur PRISMA le 10 novembre 2021.

Les différents spectres représentés à la figure 6.5 ne montrent plus de diminution de la réflectance pour les longueurs d'onde correspondant à l'absorption des chlorophylles a ( $\lambda = [600, 700]$ nm). Les résultats obtenus lors de la classification des différents peuplements sont globalement faibles. Des F1-scores inférieurs à 0,01 sont observés pour les classes "Erablière", "Pîneraie", "Mêlèzière" et "Mise à blanc". En analysant la matrice de confusion, l'ensemble de ces trois dernières classes est prédit comme faisant partie de la classe "Hêtraie". Cela est dû à un overfitting de cette classe, qui est surreprésentée dans les données d'entraînement et de validation. Cela est également constaté par la faible valeur de la moyenne macro, qui est de 0,22.




Figure 6.5 – Signature spectrale moyenne et lissée des peuplements forestiers obtenue sur la base des valeurs absolues de réflectance des pixels inclus dans les polygones de peuplements homogènes. (PRISMA : 10/11/2021)

## 6.1.5 Comparaison des spectres selon les dates d'acquisition des données

La figure 6.6 permet de mettre en évidence les différences spectrales de chaque peuplement selon la période d'acquisition des données.

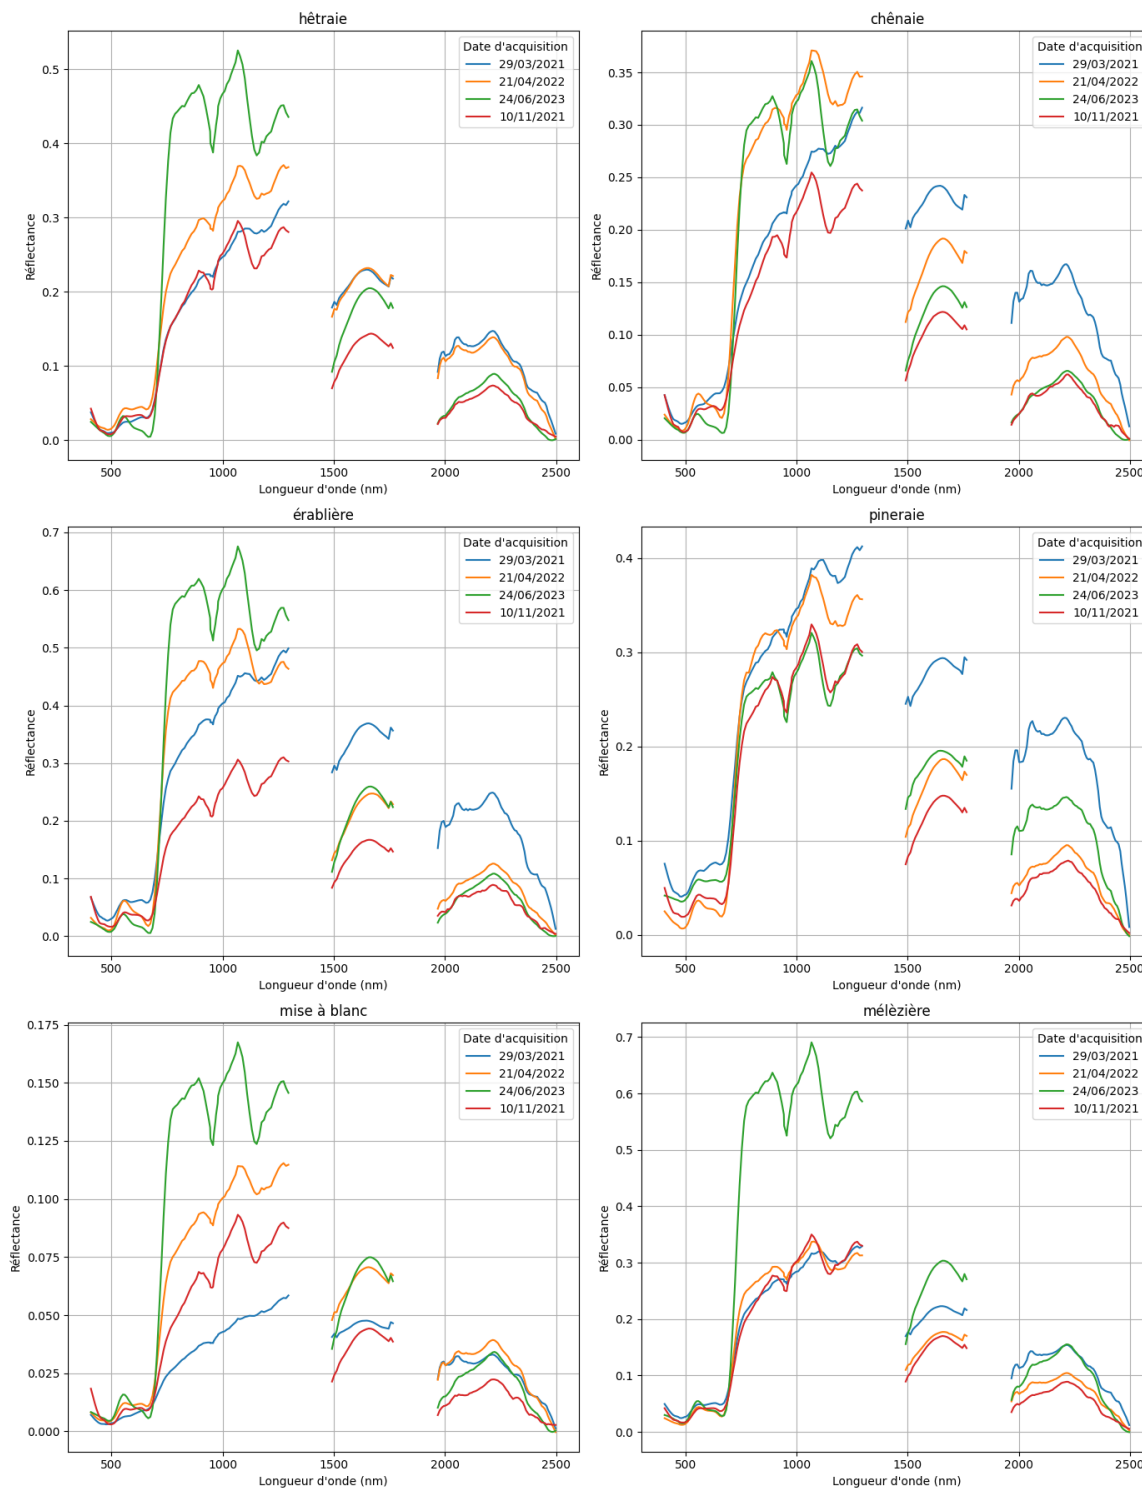


Figure 6.6 – Signature spectrale moyenne et lissée des peuplements forestiers étudié sur base des images PRISMA. Phase de dormance hivernale du mélèze : 29/03/2021, Phase de dormance hivernale du hêtre : 21/04/2022, Période de production végétale maximale : 24/06/2023, Phase de sénescence : 10/11/2021

Toutes les essences étudiées, à l'exception de la pineraie, présentent, le 29 mars, de faibles valeurs de réflectance pour les longueurs d'onde inférieures à 1500nm, tandis que les valeurs augmentent au-delà de cette limite. Les faibles réflectances observées s'expliquent par l'absence de feuilles ou d'aiguilles, tandis que les valeurs élevées au-delà de 1500nm sont probablement attribuables à un taux d'humidité élevé. Cette humidité pourrait provenir des sols forestiers, qui influencent fortement les spectres en raison de l'absence de feuilles sur le couvert végétal.

Les pins, qui conservent leurs aiguilles tout au long de l'année, présentent des spectres compris dans un intervalle de réflectance plus restreint que les autres essences. Cela est dû à la faible variation de leur apparence au fil des saisons. Cependant, ils reflètent davantage d'énergie durant les mois de mars et d'avril. Ces deux mois correspondent respectivement à la période où seuls les pins ont une activité photosynthétique et à celle où seul le hêtre n'a pas encore débourré.

La période où les valeurs de réflectance sont les plus élevées est clairement le mois de juin, lorsque la végétation atteint sa pleine activité photosynthétique. À l'inverse, les mois de mars et de décembre affichent les taux de réflectance les plus faibles. Durant ces périodes, les feuilles sont en phase de sénescence ou absentes, ce qui réduit fortement, voire élimine, l'activité photosynthétique.

En examinant les gammes de réflectance des différentes essences, il apparaît que les érablières et les mélèzières présentent des taux de réflectance plus élevés que les autres. Les mélèzes, en particulier, montrent une réflectance nettement supérieure pendant la période de production végétale maximale. En revanche, pour les autres dates d'acquisition de cette essence, leurs profils spectraux se situent, en dessous de 1500nm, dans la même gamme de valeurs que les autres essences. Cela suggère que les mélèzes n'ont probablement pas encore débourré le 21 avril, alors que cette période correspond au débourrement des autres essences, à l'exception du hêtre. Enfin, les zones de mise à blanc affichent des valeurs de réflectance nettement plus faibles que celles des peuplements forestiers.

## 6.2 Nombre de classes et quantité de données disponibles

Comme indiqué dans le paragraphe 5.2, trois combinaisons de classes ont été étudiées pour analyser l'influence du nombre de pixels de calibration et de validation sur la qualité de la classification. Deux images sont analysées : la première, acquise le 21 avril 2022 par le capteur PRISMA (Annexe E, K, M), et la seconde, acquise le 3 mai 2023 par le capteur EnMAP (Annexe I, L, N).

Les résultats obtenus à partir des données PRISMA, présentés dans le tableau 6.4, montrent des performances variées selon les combinaisons A, B et C. Les classes "Chênaie" et "Hêtraie" maintiennent des F1-scores constants entre 0,90 et 0,95. Les classes "Mise à blanc" et "Érablière" ont quant à elles des F1-scores faibles, même lorsqu'elles sont fusionnées sous la classe "Classe mixte" qui obtient le score de 0,65.

Pour la combinaison A, les classes "Mélèzière" et "Pineraie" affichent des F1-scores compris entre 0,2 et 0,21. Leur fusion dans la classe "Résineux" pour la combinaison B donne un F1-score de 1. La classe "Classe mixte" dans la combinaison C, regroupant toutes les autres classes sauf "Chênaie" et "Hêtraie", obtient un F1-score plus faible d'une valeur de 0,65.

Table 6.4 – F1-score et Support pour différentes combinaisons et classes à partir de l'image PRISMA acquise le 21/04/2022.

La colonne "Support" indique le nombre de pixels utilisés lors de la validation de la classification. Cela représente 20% de l'ensemble de la base de données.

|                     | Combinaison A |         | Combinaison B |         | Combinaison C |         |
|---------------------|---------------|---------|---------------|---------|---------------|---------|
|                     | F1-score      | Support | F1-score      | Support | F1-score      | Support |
| <b>Chênaie</b>      | 0.90          | 59      | 0.93          | 59      | 0.93          | 59      |
| <b>Hêtraie</b>      | 0.94          | 405     | 0.95          | 405     | 0.94          | 405     |
| <b>Mise à blanc</b> | 0.54          | 22      | 0.51          | 22      | -             | -       |
| <b>Érablière</b>    | 0.34          | 22      | 0.36          | 22      | -             | -       |
| <b>Mélèzière</b>    | 0.20          | 27      | -             | -       | -             | -       |
| <b>Pineraie</b>     | 0.21          | 8       | -             | -       | -             | -       |
| <b>Résineux</b>     | -             | -       | 1.00          | 35      | -             | -       |
| <b>Classe mixte</b> | -             | -       | -             | -       | 0.65          | 79      |

Les résultats obtenus à partir de l'image EnMAP montrent des performances variées dans la classification des classes en fonction des combinaisons de classes appliquées. Pour la classe "Chênaie", les F1-scores sont constants et compris entre 0,83 et 0,84. La classe "Hêtraie" obtient également des F1-scores plus élevés et également constants compris entre 0,94 et 0,95 selon la combinaison appliquée.

La classe "Mise à blanc" présente un F1-score de 0,67 dans les combinaisons A et B. Néanmoins, elle présente un score plus élevé dans la classe "Classes mixtes" d'une valeur de 0,8 dans la combinaison C. Pour la combinaison A, les classes "Mélèzière" et "Pineraie" obtiennent des F1-scores respectifs de 0,95 et 0,57. Cette performance atteint 0,84 pour la classe "Résineux" dans la combinaison B.

La classe "Érablière" quant à elle, obtient un F1-score constant de 0,79 dans les combinaisons A et B. Dans la combinaison C, la classe "Classe mixte", fusion de plusieurs autres classes, obtient un F1-score de 0,80.

Table 6.5 – Comparaison des performances de classification des différentes combinaisons et classes à partir de l'image EnMAP acquise le 03/05/2023.

La colonne "Support" correspond au nombre de pixels utilisés lors de la validation. Cette quantité représente 20% de l'ensemble de la base de données.

|                     | Combinaison A |         | Combinaison B |         | Combinaison C |         |
|---------------------|---------------|---------|---------------|---------|---------------|---------|
|                     | F1-score      | Support | F1-score      | Support | F1-score      | Support |
| <b>Chênaie</b>      | 0.83          | 63      | 0.81          | 63      | 0.84          | 63      |
| <b>Hêtraie</b>      | 0.95          | 441     | 0.94          | 441     | 0.95          | 441     |
| <b>Mise à blanc</b> | 0.67          | 22      | 0.64          | 22      | -             | -       |
| <b>Mélèzière</b>    | 0.95          | 31      | -             | -       | -             | -       |
| <b>Pineraie</b>     | 0.57          | 10      | -             | -       | -             | -       |
| <b>Érablière</b>    | 0.79          | 26      | 0.74          | 26      | -             | -       |
| <b>Résineux</b>     | -             | -       | 0.84          | 41      | -             | -       |
| <b>Classe mixte</b> | -             | -       | -             | -       | 0.80          | 89      |

La discrimination la plus exacte semble être la combinaison B pour PRISMA suivie de la combinaison A pour EnMAP. Cela peut s'expliquer par des écarts plus importants entre les spectres pour PRISMA par rapport à ceux basés sur les données EnMAP.

### 6.3 Combinaison de plusieurs dates d'acquisition

Cette méthode consiste à intégrer les données de plusieurs images avant d'effectuer la classification. Ces images ont été sélectionnées à des stades phénologiques différents de manière à pouvoir coupler les informations de traitement. Les deux premières images à avoir été combinées sont les images EnMAP acquises le 21 avril 2023 et le 3 mai 2023 (Annexe : H, I et J). Ces dates correspondent respectivement à phase de dormance hivernale du hêtre (Chap.6.1.2) et la période de débourrement de celui-ci. Les deux autres images à être traitées dans cette analyse ont été acquises par le capteur PRISMA les 11 mars et 21 avril 2022 (Annexe : D, E et F). Ces dates correspondent à la phase de dormance hivernale du mélèze (Chap.6.1.1) et à la phase de dormance hivernale du hêtre (Chap.6.1.2). Les F1-scores obtenus dans le cas de la combinaison d'images illustrent l'efficacité de la fusion des informations issues de différentes périodes pour améliorer la discrimination des essences étudiées. Les F1-scores de chaque image combinée sont comparés aux F1-scores obtenus sur base de l'utilisation des images séparées.

#### Images EnMAP

Le tableau 6.6 présente les F1-scores obtenus lors de la classification des essences forestières en utilisant les images EnMAP acquises les 21 avril et 3 mai 2023. Ces images ont été traitées soit combinées, soit séparément. Ces deux dates ont été choisies dans le but d'augmenter la performance de la classification en combinant différents stades phénologiques. L'image datant du 21 avril 2023 a été acquise au moment où l'ensemble de la végétation avait des feuilles sauf les hêtres, alors que l'image datant du 3 mai 2023 fut acquise à la période du débourrement du hêtre.

Les résultats montrent que la combinaison des images n'influence pas de manière systématique les performances de classification, car elles se limitent aux meilleures performances d'une seule des deux images. Les f1-scores des classes "Hêtraie" et "Chênaie" sont respectivement de 0,96 et 0,84 pour les données combinées, alors que les scores de 0,95 et 0,83 sont obtenus sur la base des données acquises le 5 mars. Il est également observable que le F1-score de la classe "Mise à blanc" est plus élevé pour l'image du 21/04/2023 que pour l'image combinée, avec un F1-score allant de 0,80 à 0,72. Cependant, cette amélioration n'entraîne pas une meilleure performance de classification lorsqu'on utilise l'image combinée, car le F1-score est plus faible dans ce cas (0,72). Cela se constate également en comparant les matrices de confusion des différentes classifications. Sur un total de 22 pixels de la classe "Mise à blanc", 16 sont correctement prédits sur base des données acquises le 21/04 et 14 sont correctement prédits sur base des données datant du 03/05. En combinant les données, seulement 14 pixels sont correctement prédit pour cette classe. Cela correspond à deux de moins que la meilleure prédiction. Pour l'image du 21/04/2023, les F1-scores sont globalement plus faibles, en particulier pour les classes "Mélèzière" et "Érablière", ce qui suggère que l'utilisation de cette image n'augmente pas les performances de la classification pour l'image combinée.

Table 6.6 – Scores F1 obtenus à partir des classifications des images EnMAP acquises les 21 avril et 3 mai 2023, traitées individuellement ou en combinaison.

Ce tableau présente les F1-scores, les valeurs de Support, ainsi que les moyennes macro obtenus pour les classifications des pixels de peuplements forestiers, réalisées à partir des données issues d'images individuelles ou combinées.

|                           | 21 avril 2023 | 3 mai 2023 | Dates combinées | Support |
|---------------------------|---------------|------------|-----------------|---------|
| <b>Chênaie</b>            | 0.72          | 0.83       | 0.84            | 63      |
| <b>Hêtraie</b>            | 0.99          | 0.95       | 0.96            | 441     |
| <b>Mise à blanc</b>       | 0.80          | 0.67       | 0.72            | 22      |
| <b>Érablière</b>          | 0.48          | 0.79       | 0.76            | 26      |
| <b>Mélèzière</b>          | 0.41          | 0.95       | 0.98            | 31      |
| <b>Pineraie</b>           | 0.46          | 0.57       | 0.57            | 10      |
| <b>Moyenne macro</b>      | 0.64          | 0.79       | 0.81            | 593     |
| <b>Exactitude globale</b> | 0.90          | 0.91       | 0.92            | 593     |

La figure 6.7 représente les résultats issus de la classification des peuplements forestiers en forêt de Soignes sur bases de la combinaisons des données EnMAP acquises les 21 avril et 3 mai 2023.

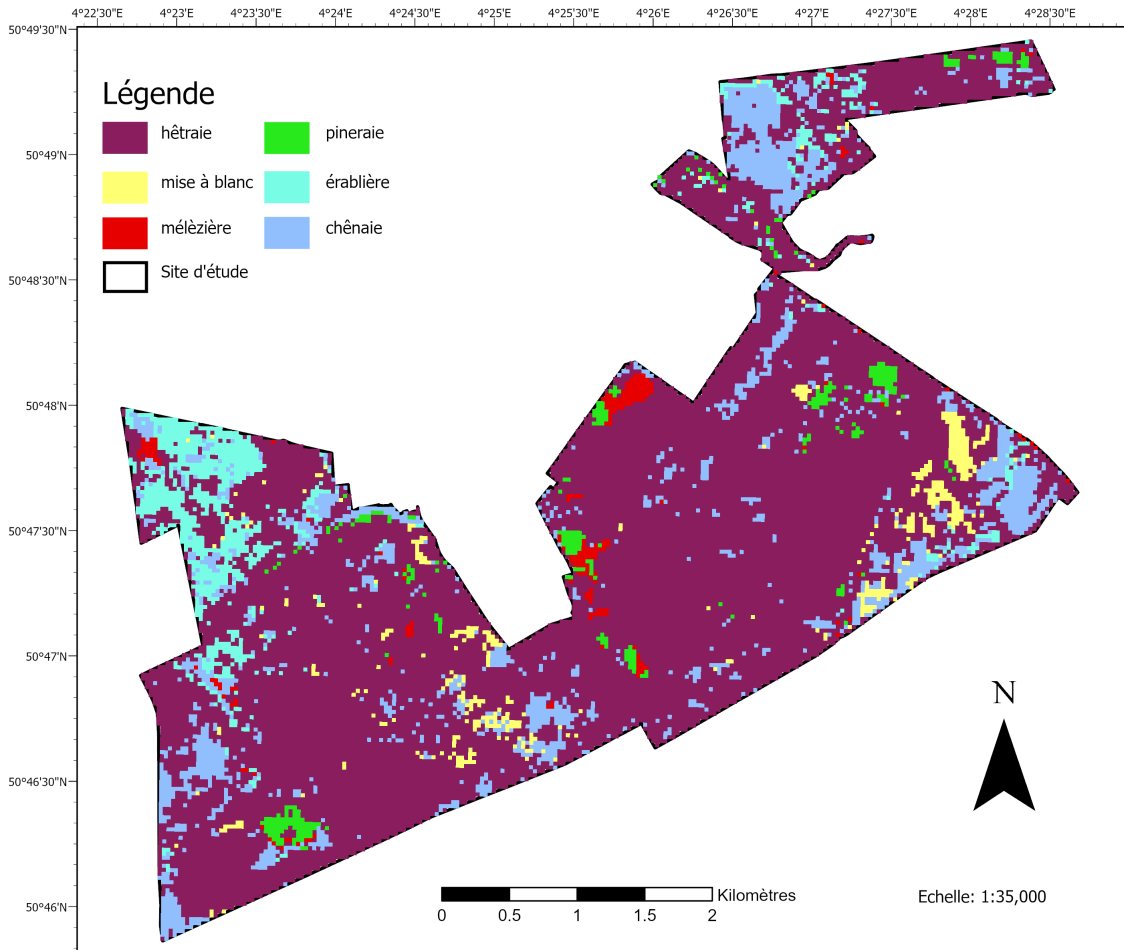


Figure 6.7 – Prédiction des peuplements forestiers sur l'ensemble du site d'étude sur base de la combinaison des données EnMAP acquise les 21 avril et 3 mai 2023.

### PRISMA

La figure 7.5 illustre les F1-scores obtenus lors de la classification des classes en utilisant les images PRISMA acquises les 11 mars et 21 avril 2022 (Annexe F). Elles correspondent au moment où les pins ont des aiguilles contrairement aux mélèzes ainsi qu'à la période où seuls les hêtres ne possèdent pas encore de feuilles. Elles ont été traitées séparément et combinées de manière à comparer les performances de classification des deux méthodes.

L'image du 11 mars affiche des scores relativement faibles pour l'ensemble des classes, à l'exception de la classe "Hêtraie", ce qui suggère un overfitting lié à la sur-représentation de cette classe dans les données d'entraînement. Ce phénomène est visible sur la matrice de confusion (Annexe D) où la classe "Hêtraie" comprend plus de 23% de faux positifs. Cela s'explique par le fait qu'à cette période de l'année, seuls les pins possèdent des aiguilles, ce qui rend difficile la distinction des autres types de végétation. En revanche, l'image du 21 avril montre de bonnes performances pour les classes 'Chênaie' et 'Hêtraie', avec des f1-score de respectivement 0,90 et 0,94. des scores moins satisfaisants pour les classes "Pineraie" et 'Érablière'. Ces dernières sont majoritairement prédites dans la classe "Hêtraie" qui, comme pour les classification sur base des données du 11 mars, présente une sur-prédiction.

Tel que observé précédemment pour les images EnMAP, la combinaison des données ne permet pas d'obtenir de meilleures performances que celles obtenues avec les données traitées individuellement. Les classes "Mélèzière" et "Mise à blanc" performent moins bien sur base des données combinées que sur bases des données acquise le 21 avril. Pour le reste des classes, les f1-score restent équivalents aux meilleurs prédictions obtenues sur base des données traitées séparément.

Table 6.7 – Scores F1 obtenus à partir des classifications des images PRISMA acquises les 11 mars et 21 avril 2022, traitées individuellement ou en combinaison.

Ce tableau présente les F1-scores, les valeurs de Support, ainsi que les moyennes macro obtenus pour les classifications des pixels de peuplements forestiers, réalisées à partir des données issues d'images individuelles ou combinées.

|                           | 11 mars 2022 | 21 avril 2022 | Dates combinées | Support |
|---------------------------|--------------|---------------|-----------------|---------|
| <b>Chênaie</b>            | 0.05         | 0.90          | 0.92            | 59      |
| <b>Hêtraie</b>            | 0.86         | 0.94          | 0.93            | 405     |
| <b>Mise à blanc</b>       | 0.00         | 0.54          | 0.39            | 22      |
| <b>Érablière</b>          | 0.00         | 0.34          | 0.35            | 22      |
| <b>Mélèzière</b>          | 0.00         | 0.20          | 0.00            | 27      |
| <b>Pineraie</b>           | 0.00         | 0.21          | 0.22            | 8       |
| <b>Moyenne macro</b>      | 0.15         | 0.52          | 0.47            | 543     |
| <b>Exactitude globale</b> | 0.73         | 0.86          | 0.85            | 543     |

## 6.4 Résultats obtenus sur base de données multispectrales

Dans le but de comparer les résultats obtenus avec des données HRS et MS, la même méthodologie de classification a été appliquée à une image Sentinel-2. Cette image fut acquise le 20 avril 2022, ce qui est proche de la date d'acquisition de l'image PRISMA ayant obtenu les meilleurs résultats de cette recherche pour ce capteur (21 avril 2022). À titre de rappel, les bandes spectrales de l'image S2 ont été préalablement rééchantillonnées à une résolution de 30 m de manière à correspondre à la résolution spatiale des données PRISMA.

La figure 6.8 reprend les différentes métriques de performance obtenues lors de la classification des pixels de peuplements forestiers sur la base de données Sentinel-2. Ces métriques affichent des F1-scores élevés, avec comme meilleure prédiction la classe "Mélèzière", qui obtient un score de 1. Les classes "Chênaie", "Hêtraie" et "Pineraie" affichent également des F1-scores supérieurs à 0,9. Cependant, les F1-scores des classes "Mise à blanc" et "Érablière" sont plus faibles et obtiennent respectivement les valeurs de 0,44 et 0,61. Cela suggère une moins bonne prédiction de ces deux classes. Le rappel des classe "Chênaie" et "Mélèzière" sont de 1, ce qui signifie que l'ensemble des pixels de ces classes sont correctement prédit. La moyenne macro s'élève à 0,84, ce qui suggère une bonne répartition des prédictions pour l'ensemble des classes étudiées.

En raison de la résolution spatiale plus élevée des données Sentinel-2, la quantité de pixels reprise dans le processus de validation est plus élevée que pour les données HRS. Cela est représenté sous la colonne "Support". Sachant que les données de validation représentent 20% de l'ensemble de la

base de données, le nombre de pixels utilisé lors de la calibration et de l'entraînement du modèle de classification est également plus élevé dans ce cas de figure par rapport aux images HRS.

Table 6.8 – Mesures de performance des différentes classes de peuplements forestiers (Sentinel-2 : 20/04/2022).

Les métriques F1-score, Précision, Rappel et Support sont calculées pour différentes classes, avec "Support" représentant le nombre d'échantillons utilisés pour la validation de la classification.

|                           | Précision | Rappel | F1-score | Support |
|---------------------------|-----------|--------|----------|---------|
| <b>Chênaie</b>            | 0.82      | 1.00   | 0.90     | 64      |
| <b>Hêtraie</b>            | 0.96      | 0.99   | 0.98     | 447     |
| <b>Mise à blanc</b>       | 0.70      | 0.32   | 0.44     | 22      |
| <b>Mélèzière</b>          | 1.00      | 1.00   | 1.00     | 27      |
| <b>Pineraie</b>           | 1.00      | 0.91   | 0.95     | 11      |
| <b>Érablière</b>          | 1.00      | 0.44   | 0.61     | 25      |
| <b>Moyenne macro</b>      | 0.91      | 0.78   | 0.81     | 596     |
| <b>Exactitude globale</b> | 0.94      |        |          |         |

La matrice de confusion (figure 6.9) compare les classes prédites par le modèle de classification à leurs classes observées sur le terrain. Chaque ligne représente une classe observée sur le terrain, et chaque colonne correspond à une classe prédite, les éléments diagonaux indiquant les prédictions correctes. Globalement, les valeurs reprises dans la matrice de confusion suggèrent de bonne prédiction des différentes classes. Néanmoins, les classes "Mise à blanc" et "hêtraie" présentent une certaine erreur. Soit 15 pixels de la classe "Mise à blanc" sont prédits comme appartenant à la classe "Hêtraie". Tandis que 7 pixels de la classe "Hêtraie" sont incorrectement classés comme faisant partie de la classe "Mise à blanc". Ensuite, la figure 6.9 suggère également que la majeure partie des erreurs de la classe "Érablière" est reprise sous la classe "Chênaie". Pour ces deux classes, 13 pixels de la classe "Érablière" sont repris sous la classe "Chênaie". Selon la matrice de confusion, la classe "Mélèzière" obtient une excellente prédiction avec l'ensemble des 27 pixels correctement prédit. La classe "Hêtraie" ne contient que 2 pixels provenant d'autres peuplements forestiers. Ce résultat semble logique compte tenu de la période d'acquisition des données, qui correspondait à la phase de dormance hivernale du hêtre. Dans ces conditions, l'identification de cette essence est supposée être facilitée.

Table 6.9 – Matrice de confusion issus de la classification sur base des données Sentinel-2.

Les colonnes de la matrice représentent les classes identifiées après le traitement dans l'échantillon de validation (classe prédite). Les lignes correspondent aux classes initiales de l'échantillon de validation (classe observée sur le terrain). Les éléments diagonaux indiquent les prédictions correctes.

|                     | Chênaie   | Hêtraie    | Mise à blanc | Mélèzière | Pineraie  | Érablière |
|---------------------|-----------|------------|--------------|-----------|-----------|-----------|
| <b>Chênaie</b>      | <b>64</b> | 0          | 0            | 0         | 0         | 0         |
| <b>Hêtraie</b>      | 1         | <b>443</b> | 3            | 0         | 0         | 0         |
| <b>Mise à blanc</b> | 0         | 15         | <b>7</b>     | 0         | 0         | 0         |
| <b>Mélèzière</b>    | 0         | 0          | 0            | <b>27</b> | 0         | 0         |
| <b>Pineraie</b>     | 0         | 1          | 0            | 0         | <b>10</b> | 0         |
| <b>Érablière</b>    | 13        | 1          | 0            | 0         | 0         | <b>11</b> |

La figure 6.8 représente les résultats issus de la classification des peuplements forestiers en forêt de Soignes sur bases des données spectrales Sentinel-2 acquise le 20 avril 2022.

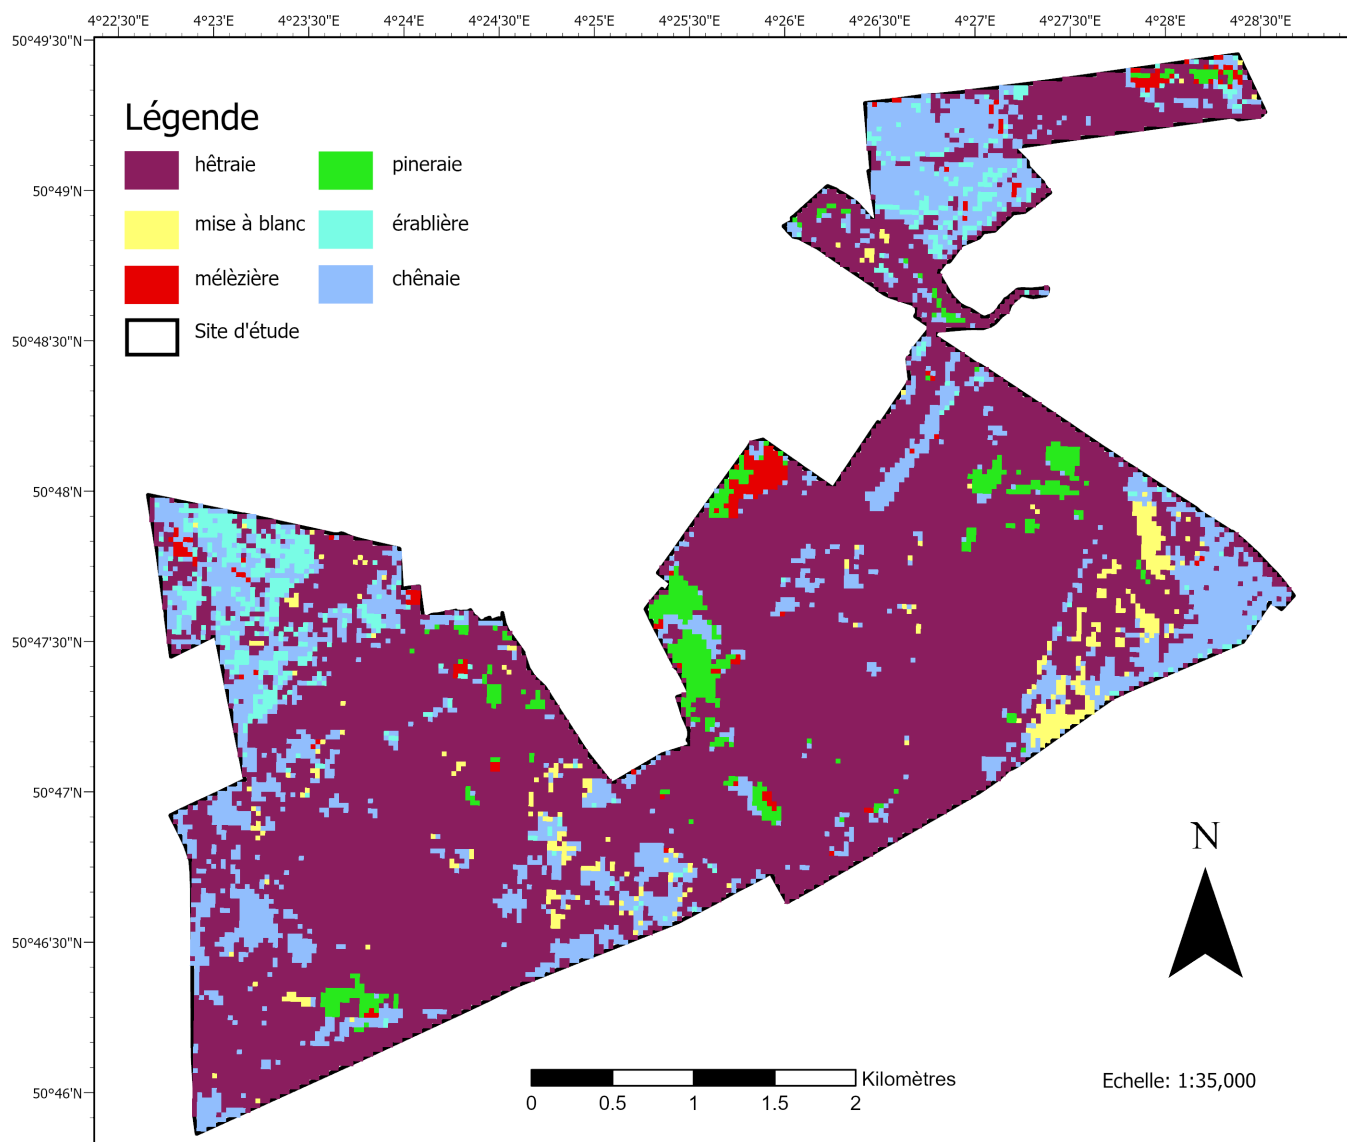


Figure 6.8 – Prédiction des peuplements forestiers sur l'ensemble du site d'étude sur base des données Sentinel-2 acquises le 20 avril 2022

---

---

# CHAPITRE 7

---

## DISCUSSION

### 7.1 Périodes d'acquisition

Ce paragraphe vise à identifier la phase phénologique offrant les meilleures performances pour la reconnaissance des peuplements forestiers. À cet effet, les résultats obtenus pour différentes périodes d'acquisition sont synthétisés dans le tableau 7.1.

#### **Phase de dormance hivernale du mélèze**

L'image acquise par PRISMA le 29 mars 2021 présente des résultats de classification faibles. Bien qu'il ait été attendu que les classes "Pineraie" et "Mélèzière" soient facilement distinguées, notamment en raison de la présence d'aiguilles sur les pins et de leur absence sur les mélèzes, ces deux classes affichent un F1-score de zéro, sans aucun pixel correctement classé. La majorité des peuplements sont classés comme "Hêtraie", ce qui reflète un problème de surapprentissage (overfitting) lié au déséquilibre dans la répartition des données disponibles pour chaque classe. Dès lors, les faibles résultats obtenus pour les classes Pineraie et Mélèzière peuvent s'expliquer par le manque de données de terrain.

#### **Phase de dormance hivernale du hêtre**

Les classifications faites sur bases de données acquise lors de la phase de dormance hivernale du hêtre présentent, de manière générale, une exactitude de prédiction plus élevée que pour les autres phases. Les deux classes présentant les résultats les plus constants sont la Chênaie et la Hêtraie. Les F1-score de ces deux classes varient entre 0.72 et 0.99. Cependant, Deux des trois images traitée présente de faible score pour les classes Mélèzière et Pineraie. Cela s'explique par une grande confusion entre ces deux classes.

La figure 7.1 illustre les résultats obtenus pour une zone spécifique du site d'étude, à partir des données EnMAP acquises le 3 mai 2023. Ces résultats représentent les meilleures performances obtenues avec les données HRS dans cette étude. La carte à droite permet d'identifier les peuplements, avec les hêtres situés au centre, entourés de pins disposés en demi-lune. On remarque également que les zones

où les sols forestiers sont visibles sont classées dans la catégorie "Mise à blanc". Cette figure met en évidence le potentiel des images HRS pour la classification, tout en soulignant leurs limites dues à leur faible résolution spatiale : les petits peuplements, comme la zone de mélèze, ne sont pas correctement identifiés.

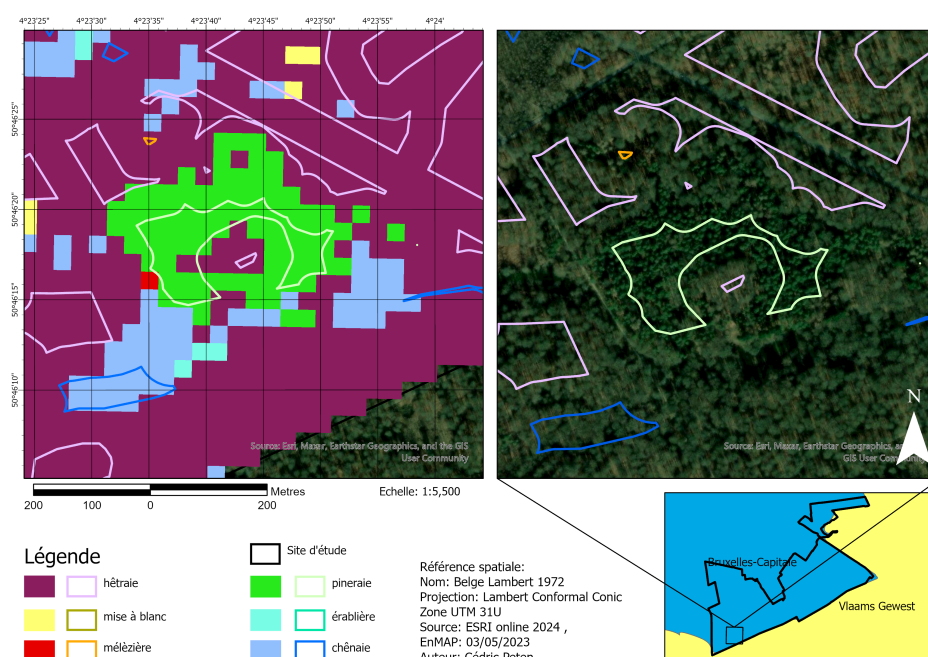


Figure 7.1 – Étude de cas (EnMAP : 03/05/2023)

La carte de gauche représente un raster obtenu lors de la classification des pixels sur la base des données EnMAP acquises le 03/05/2023 ainsi qu'une représentation des zones de peuplement homogène.

### Période de production végétale maximale

L'image acquise par PRISMA le 24 juin 2023, pendant la période de production végétale maximale, montre des spectres caractérisés par une couverture foliaire dense et un indice NDVI élevé. Les classes "Érablière" et "Mélèzière" présentent une réflectance plus élevée dans les ondes NIR, tandis que la classe "Mise à blanc" absorbe davantage. Malgré ces différences spectrales, les F1-scores restent faibles. Cela peut s'expliquer par le fait que la réflectance dans le proche infrarouge atteint un plateau pour de nombreuses essences, ce qui réduit les différences spectrales discriminantes. La classe "Hêtraie" obtient un score élevé, mais cela résulte d'une sur-prédiction, tandis que les classes "Pineraiie" et "Mélèzière" n'ont pas été correctement classées, ce qui révèle un problème de sur-apprentissage lié à un déséquilibre des données.

### Phase de sénescence

Pendant la phase de sénescence, marquée par une baisse d'activité photosynthétique et une diminution du NDVI, les spectres montrent une absence d'absorption significative des chlorophylles a. L'analyse des données PRISMA du 10 novembre 2021 révèle des résultats de classification très faibles, avec des F1-scores proches de zéro pour la plupart des classes. La sur-prédiction de la classe "Hêtraie", due à un overfitting causé par sa surreprésentation dans les données d'entraînement, entraîne une confusion généralisée entre les classes, comme en témoigne une moyenne macro de seulement 0,22. Ces résultats soulignent la difficulté de discriminer les peuplements pendant cette phase de transition phénologique.

Les F1-scores des classes étudiées pour les différentes périodes d'acquisition sont repris dans le tableau 7.1, ci-dessous. Les résultats montrent que l'acquisition de données durant la phase de dormance du hêtre offre les meilleures performances de classification. Sur les trois images acquises durant cette période, toutes les classes ont été reconnues et les exactitudes globales figurent parmi les trois plus élevées parmi les images analysées. Ces observations confirment les études antérieures, comme celles de Glowienka et Zembol (2022), qui indiquent que la synchronisation des acquisitions avec des phases phénologiques spécifiques améliore la discrimination des essences. Les résultats montrent également une variation significative des signatures spectrales des peuplements en fonction des phases phénologiques. Il est par exemple observable que les différences entre signatures spectrales des arbres sont maximisées pendant les phases phénologiques spécifiques aux essences étudiées. Cette idée est renforcée par Immitzer et al. (2019), qui met en évidence l'évolution des signatures spectrales selon les saisons. Ils soulignent ainsi l'importance d'utiliser des périodes critiques pour réduire la confusion entre classes d'occupation. Par exemple, les stades phénologiques comme le débourrement du hêtre améliorent la distinction entre les essences. Sur ces données, les classes hêtraie et chênaie présentent un taux élevé de discrimination, avec peu de confusion entre elles. Cependant, cette tendance n'est pas observée pour la période de sénescence et de dormance du mélèze, la période de NDVI maximale ou encore la période de sénescence, où les résultats sont moins performants. Pour ces trois périodes, aucun pixel des classes "Pinaie" et "Mélèzière" n'a été correctement classé. La majorité de ces pixels a été prédite dans la classe "Hêtraie", probablement en raison de la surreprésentation de cette classe dans les données d'entraînement et de terrain. Ce phénomène de sur-apprentissage, qui peut réduire l'exactitude des résultats, est mentionné par Daria (2024) dans leurs travaux. Il est donc nécessaire de rester critique quant au choix des périodes d'acquisition des données, car elles peuvent avoir une influence importante sur la qualité des résultats.

Table 7.1 – Score f1 obtenus sur base des classifications faites lors des différentes stades phénologiques

|                      | Dormance du mélèze | Dormance du hêtre |            |            | NDVI max   | Sénescence |
|----------------------|--------------------|-------------------|------------|------------|------------|------------|
|                      | 29/03/2021         | 21/04/2022        | 21/04/2023 | 03/05/2023 | 24/06/2023 | 10/11/2021 |
| <b>Chênaie</b>       | 0.24               | 0.90              | 0.72       | 0.83       | 0.74       | 0.36       |
| <b>Hêtraie</b>       | 0.87               | 0.94              | 0.99       | 0.95       | 0.90       | 0.87       |
| <b>Mise à blanc</b>  | 0.00               | 0.80              | 0.51       | 0.67       | 0.09       | 0.00       |
| <b>Érablière</b>     | 0.00               | 0.34              | 0.48       | 0.79       | 0.22       | 0.08       |
| <b>Mélèzière</b>     | 0.00               | 0.20              | 0.41       | 0.95       | 0.00       | 0.00       |
| <b>Pinaie</b>        | 0.00               | 0.21              | 0.46       | 0.57       | 0.00       | 0.00       |
| <b>Moyenne macro</b> | 0.19               | 0.52              | 0.64       | 0.79       | 0.32       | 0.22       |

L'importance des variables pendant le processus de classification est représentée à la figure 7.2. Le pouvoir discriminant des intervalles de longueurs d'onde de 50nm est illustré à l'aide de boîtes à moustaches. Ces valeurs sont détaillées par dates d'acquisition dans l'annexe O. Les boîtes centrales représentent 50 % des valeurs observées et la ligne rouge correspond à la médiane des valeurs. Les moustaches, quant à elles, s'étendent jusqu'à 1,5 fois l'intervalle interquartile (IQR). Sur ce graphique, il est observable que les intervalles de longueurs d'onde compris entre 400 et 500nm ainsi qu'entre 600 et 700nm sont ceux qui permettent une meilleure séparation des classes dans la classification Random Forest. La réflectance de ces deux intervalles de longueurs d'onde est fortement influencée par la présence de chlorophylles a et b. Ces dernières étant présentes dans les feuilles, cela indique que

la présence de feuillage facilite grandement la classification des essences forestières. Ces observations sont soutenues par les travaux de Fassnacht et al. (2016), qui identifient des bandes similaires comme étant cruciales pour différencier les espèces, grâce à des signatures spectrales spécifiques.




Figure 7.2 – Importance des variables pendant le processus de classification des peuplements forestiers. Les boîtes centrales représentent 50 % des valeurs observées et la ligne rouge correspond à la médiane des valeurs. Les moustaches, quant à elles, s’étendent jusqu’à 1,5 fois l’intervalle interquartile (IQR).

## 7.2 Comparaison du nombre de classe

La fusion et la combinaison des classes ont été étudiées pour évaluer l’impact de la quantité de données sur la qualité des classifications forestières. Les résultats montrent que regrouper certaines classes, comme les résineux sous une catégorie unique, améliore les performances de classification, en particulier pour les classes minoritaires. Par exemple, en utilisant les données PRISMA, la classe "Résineux" atteint un F1-score de 1 après fusion, bien que ce score doive être interprété avec prudence, car il pourrait être influencé par des erreurs dans la validation des données. De manière similaire, avec les données EnMAP, la fusion des classes "Pineraie" et "Mélèzière" sous "Résineux" augmente leur score combiné de 0,57 et 0,79 à 0,84.

Ce phénomène, également observé par Vangi et al. (2021) et Vanguri et al. (2024), s’explique par la capacité accrue des modèles à traiter les classes sur-représentées lorsque le nombre de catégories est réduit. Toutefois, cette simplification, bien qu’efficace pour améliorer l’exactitude globale, entraîne une perte d’information en réduisant les détails analytiques disponibles, comme le soulignent Fassnacht et al. (2016). La combinaison B, par exemple, améliore les résultats pour les résineux, mais

la réduction à trois classes dans la combinaison C montre comment ce niveau de détail élevé limite les possibilités d'analyse fine. Cependant, Fassnacht et al. (2016) précisent que cette méthode est à privilégier en cas de manque de données de terrain. En combinant plusieurs classes, la quantité de données disponible augmente. Cela permet de mieux entraîner le modèle et donc d'obtenir des prédictions avec une plus grande exactitude.

Certaines approches alternatives méritent également d'être considérées. Bolyn et al. (2018) ainsi que Deák et al. (2017) ont proposé d'introduire une classe de végétation mixte, englobant les pixels sans dominance marquée (moins de 80% d'une essence), pour réduire la confusion entre classes, bien que cela implique également une simplification des résultats. De leur côté, Immitzer et al. (2019) suggèrent une méthode en deux étapes : d'abord regrouper les espèces présentant des similitudes spectrales tel que les classes "Conifère", "Feuillus" et "Non-boisé", puis affiner la classification à l'intérieur de chacune de ces grandes catégories. Bien que cette approche n'ait pas été appliquée ici, elle pourrait améliorer les performances en adaptant les hyperparamètres des modèles de classification aux spécificités des sous-classes, tout en limitant les exigences en données nécessaires pour les classes les plus détaillées.




Figure 7.3 – F1-scores en fonction des combinaisons de classes.

## 7.3 Comparaison de la combinaison d'images

Les résultats de cette étude montrent que la combinaison des images acquises à différentes dates d'acquisition n'améliore pas significativement l'exactitude globale de la classification des peuplements forestiers, comme l'indiquent les figures 7.4 et 7.5. En effet, les F1-scores restent globalement faibles pour certaines classes, notamment "Mélèzière" et "Pineraie", quel que soit le capteur utilisé (PRISMA ou EnMAP), tandis que les classes "Chênaie" et "Hêtraie" bénéficient d'une légère amélioration grâce à cette combinaison. Cependant, ces résultats reflètent une limite : les images ont été combinées uniquement sur la base de leurs stades phénologiques, sans tenir compte des performances spécifiques de classification obtenues pour chaque image.

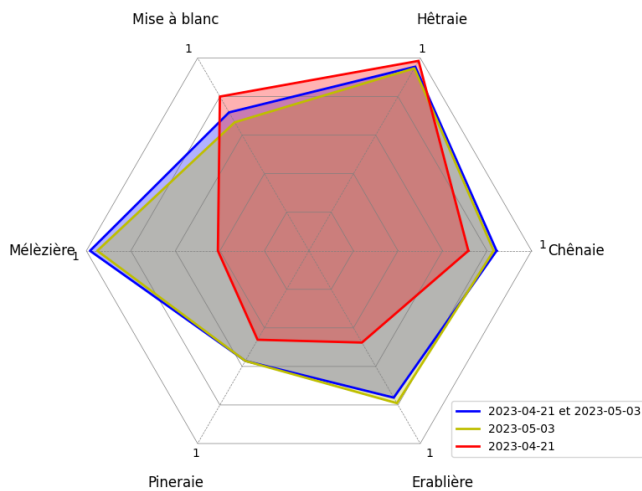


Figure 7.4 – Représentation des F1-scores obtenu sur base d’images EnMAP combinées.




Figure 7.5 – Représentation du F1-score obtenu pour chaque classe en fonction de la période phénologique.

Une stratégie plus ciblée consisterait à sélectionner les images en fonction de leur capacité à bien distinguer certaines classes. Par exemple, une image excelle pour les classes X et Y, tandis qu’une autre est performante pour les classes A et Z ; leur combinaison pourrait alors exploiter ces forces complémentaires pour améliorer la classification globale. Cette approche est appuyée par le travail de Grigorieva et al. (2020), qui montre que l’association de données complémentaires maximise les performances des modèles hybrides.

De plus, combiner des données issues de capteurs différents, tels que les données HRS et MS, pourrait offrir des perspectives intéressantes. La richesse spectrale des capteurs HRS et la haute résolution spatiale des capteurs MS, comme le notent Fassnacht et al. (2016), sont reconnues pour améliorer la différenciation des essences forestières. Glowienka et Zembol (2022) soulignent également l’intérêt de coupler ces sources avec des données LIDAR pour intégrer des modèles numériques de terrain, renforçant ainsi les analyses et la robustesse des classifications.

## 7.4 Comparaison des résultats obtenus a partir d’images HRS et MS

Dans le cadre de la comparaison des résultats obtenus à partir des données MS et HRS, ce paragraphe présente une analyse basée sur les données acquises par le capteur PRISMA le 21 avril 2022 et le capteur Sentinel-2 le 20 avril 2022.

Le tableau 7.2 résume les F1-scores et les valeurs de support obtenus pour ces deux classifications. Globalement, la classification effectuée sur la base des données MS montre de meilleures performances de prédiction que celle basée sur les données HRS. La moyenne macro des F1-scores passe de 0,52 pour les données HRS à 0,81 pour les données MS, ce qui indique une exactitude de prédiction plus élevée pour les données MS. Les classes "Chênaie" et "Hêtraie" affichent des résultats similaires, avec

des F1-scores supérieurs à 0,90 dans les deux cas, et sont les seules classes pour lesquelles plus de 59 pixels ont été utilisés lors de la validation des modèles.

En revanche, la classe "Érablière" montre une différence marquée entre les deux types de données, avec un F1-score passant de 0,21 sur la base de 8 pixels HRS à 1 avec 27 pixels MS. Cela suggère que l'augmentation du nombre de pixels pour l'entraînement et la validation améliore considérablement les performances de prédiction. Toutefois, dans le cas où la quantité de données d'entraînement reste inchangée, le score obtenu à partir de donnée MS est plus faible que celui obtenu à partir de données HRS. C'est le cas de la classe "Mise à blanc" qui obtient des F1-scores, passant de 0,54 pour les données HRS à 0,43 pour les données MS. À l'inverse, la classe Pineraie observe une diminution de moitié de la disponibilité en données et présente pourtant une augmentation du F1-score de 0,31.

Table 7.2 – F1-score et Support obtenus à partir des classifications faites sur base des données hyperspectrales PRISMA et multispectrales Sentinel-2.

|                           | <b>Données HRS</b>  |                         | <b>Données MS</b> |         |
|---------------------------|---------------------|-------------------------|-------------------|---------|
|                           | PRISMA : 21/04/2022 | Sentinel-2 : 20/04/2022 | F1-score          | Support |
| <b>Chênaie</b>            | 0.90                | 59                      | 0.90              | 64      |
| <b>Hêtraie</b>            | 0.94                | 405                     | 0.97              | 447     |
| <b>Mise à blanc</b>       | 0.54                | 22                      | 0.43              | 22      |
| <b>Érablière</b>          | 0.20                | 27                      | 0.61              | 25      |
| <b>Mélèzière</b>          | 0.21                | 8                       | 1                 | 27      |
| <b>Pineraie</b>           | 0.34                | 22                      | 0.65              | 11      |
| <b>Moyenne macro</b>      | 0.52                | 543                     | 0.81              | 596     |
| <b>Exactitude globale</b> | 0.86                |                         | 0.94              |         |

Les analyses des bandes spectrales révèlent que les longueurs d'onde entre 450nm et 850nm, couvertes par sept bandes multispectrales de Sentinel-2, offrent les meilleures performances de classification. Cette observation est appuyée par la figure 7.2, qui illustre la capacité de discrimination des pixels de peuplements homogènes par les différentes bandes spectrales. Dans cette figure, les bandes situées dans cette plage de longueurs d'onde montrent une contribution significative à la précision des classifications, confirmant leur importance dans la différenciation des classes forestières.

Bien que les données hyperspectrales PRISMA soient plus riches en informations spectrales, ce type de données présente certaines limites quant à leur efficacité pour cette étude. Premièrement, comme le montre l'analyse dans la figure 7.2, les bandes supplémentaires des données hyperspectrales en dehors de cette plage contribuent relativement peu à la classification. Ces résultats concordent avec le travail de Grabska et al. (2019), qui met en évidence l'importance des variables dans une classification similaire à celle étudiée ici. De plus, la grande dimensionnalité des données hyperspectrales pose des défis au modèle Random Forest. Pour y remédier, Deák et al. (2017) suggèrent d'appliquer, en amont de la classification finale, une sélection automatisée des dimensions. Cette approche est applicable à un modèle Random Forest, où il est possible de calculer l'indice de Gini pour chaque variable, puis de ne conserver que celles ayant les indices les plus élevés pour effectuer la classification finale.

L'exactitude globale plus élevée obtenue à partir des données MS par rapport aux données HRS contraste avec les résultats rapportés dans le travail de Vangi et al. (2021). Ils concluent que les données PRISMA permettent une meilleure classification que les données S2. Cependant, leurs études portent sur une zone d'intérêt plus vaste avec plus de données d'entraînement. Cela suggère de travailler sur un site d'échelle plus grande, avec des zones d'entraînement et de validation élargies. De cette manière, cela pourrait permettre de pallier la diminution de la quantité de données due à la faible résolution spatiale des données HRS et mieux exploiter leur potentiel.

---

---

# CHAPITRE 8

---

## CONCLUSION

Cette étude examine trois approches différentes pour discriminer les peuplements forestiers de la forêt de Soignes en utilisant des données hyperspectrales issues des capteurs EnMAP et PRISMA : La variation des périodes d'acquisition des données, la variation de la quantité d'échantillons terrain dans les classes étudiées et la combinaison de plusieurs dates d'acquisition. Chaque approche a révélé ses atouts et ses limites, mettant en lumière les défis spécifiques à la classification des peuplements dans cette région. Les classifications ont été réalisées à l'aide du modèle Random Forest, avec une validation croisée imbriquée pour optimiser les hyperparamètres. Le modèle a été entraîné sur 80 % des échantillons terrain, tandis que les 20 % restants ont servi à valider les prédictions.

Dans le cadre de la variation des périodes d'acquisition, quatre périodes distinctes ont été étudiées : la dormance hivernale du mélèze, la dormance hivernale du hêtre, la production végétative maximale, et la sénescence des feuilles. Ces périodes ont donné des résultats variés et intéressants. La période de dormance hivernale du hêtre, qui se déroule au printemps lorsque seuls les hêtres sont encore sans feuilles, a offert les prédictions les plus précises. L'exactitude globale obtenue pour cette période atteint 0,79, soit le meilleur score obtenu dans cette étude pour une classification basée uniquement sur des données hyperspectrales.

En ce qui concerne la variation de la quantité d'échantillons dans les classes étudiées, des regroupements ont été effectués pour améliorer la représentation des classes sous-représentées. Cette approche a démontré son efficacité en augmentant l'exactitude globale, grâce à l'accroissement du nombre d'échantillons disponibles pour les classes minoritaires. Toutefois, cette méthode n'est pas nécessaire pour les classes sur-représentées, comme le hêtre dans ce cas. Il est particulièrement pertinent de regrouper des classes aux signatures spectrales similaires, telles que le pin et le mélèze, combinés ici sous la classe "résineux". Cependant, une telle fusion entraîne une perte de granularité dans la représentation des classes, réduisant ainsi le niveau de détail.

Enfin, la combinaison de plusieurs dates d'acquisition, intégrant différents stades phénologiques, n'a pas permis d'améliorer les résultats dans cette étude. Cela peut s'expliquer par le fait que les combinaisons ont été établies sur la base des stades phénologiques, alors qu'une combinaison d'images fondée sur leurs performances individuelles aurait probablement été plus efficace.

Pour conclure, les résultats obtenus avec les données hyperspectrales ont été comparés à ceux issus de données multispectrales, en suivant la même méthodologie. Les données multispectrales se sont avérées plus robustes, atteignant une exactitude globale de 0,94 contre 0,86 pour les données hyperspectrales. Cette différence peut être attribuée au nombre trop élevé de variables explicatives dans les données hyperspectrales, rendant la classification plus complexe pour le modèle Random Forest. Il serait donc pertinent d'appliquer une sélection automatisée des dimensions en amont de la classification, en conservant uniquement les variables les plus pertinentes pour la distinction des classes.

---

# BIBLIOGRAPHIE

- Awad, M. (2018). Forest mapping: a comparison between hyperspectral and multispectral images and technologies. *Journal of Forestry Research*, 29, 1395-1405. <https://doi.org/10.1007/s11676-017-0528-y>
- Bolyn, C., Michez, A., Gaucher, P., Lejeune, P. & Bonnet, S. (2018). Forest mapping and species composition using supervised per pixel classification of sentinel-2 imagery. *BASE*. <https://doi.org/10.25518/1780-4507.16524>
- Breiman, L., Friedman, J., Stone, C. & Olshen, R. (1984). *Classification and Regression Trees*. Taylor & Francis. <https://books.google.be/books?id=JwQx-WOmSyQC>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>
- Caputi, E., Delogu, G., Patriarca, A., Perretta, M., Gatti, L., Boccia, L. & Ripa, M. N. (2023). Comparative performance of machine learning algorithms for Forest Cover classification using ASI - PRISMA hyperspectral data. *2023 IEEE International Workshop on Metrology for Agriculture and Forestry (MetroAgriFor)*, 248-252. <https://doi.org/10.1109/MetroAgriFor58484.2023.10424185>
- Daria, H. (2024). The curse of dimensionality. *FAECTOR*. Récupérée 1 octobre 2024, à partir de <https://estimator.faector.nl/article/2024-03-18-curse-of-dimensionality>
- Deák, M., Telbisz, T., Árvai, M., Mari, L., Horváth, F., Kohán, B., Szabó, O. & Kovács, J. (2017). Heterogeneous forest classification by creating mixed vegetation classes using EO-1 Hyperion [Publisher: Taylor & Francis \_eprint: <https://doi.org/10.1080/01431161.2017.1325529>]. *International Journal of Remote Sensing*, 38(18), 5215-5231. <https://doi.org/10.1080/01431161.2017.1325529>
- Fassnacht, F., Latifi, H., Stereńczak, K., Lefsky, M., Straub, C., Waser, L., Ghosh, A. & Modzelewska, A. (2016). Review of studies on tree species classification from remotely sensed data. *Remote Sensing of Environment*, 184.
- Feng, X., He, L., Cheng, Q., Long, X. & Yuan, Y. (2020). Hyperspectral and Multispectral Remote Sensing Image Fusion Based on Endmember Spatial Information. *Remote Sensing*, 12(6). <https://doi.org/10.3390/rs12061009>

- Frank, T. (1988). Mapping dominant vegetation communities in the Colorado Rocky Mountain Front Range with Landsat Thematic Mapper and digital terrain data. *Photogrammetric Engineering & Remote Sensing*, 54(12), 1727-1734.
- Frederik, V., Gregory, R., Patrick, H., Damien, B., Olivier, B., Herman, D., Regine, V., Sylvie, C., Isabelle, D. & Florence, D. (2017). La Forêt de Soignes : une perle verte à conserver précieusement ! *Plateforme de la Forêt de Soignes*, 21.
- Galidaki, G. & Gitas, I. (2015). Mediterranean forest species mapping using classification of Hyperion imagery [Publisher: Taylor & Francis \_eprint: <https://doi.org/10.1080/10106049.2014.883439>]. *Geocarto International*, 30(1), 48-61. <https://doi.org/10.1080/10106049.2014.883439>
- Glowienka, E. & Zembol, N. (2022). Forest Community Mapping Using Hyperspectral (CHRIS/PROBA) and Sentinel-2 Multispectral Images. *Geomatics and Environmental Engineering*, 16, 103-117. <https://doi.org/10.7494/geom.2022.16.4.103>
- Goetz, A. F. H., Vane, G., Solomon, J. E. & Rock, B. N. (1985). Imaging Spectrometry for Earth Remote Sensing [Publisher: American Association for the Advancement of Science]. *Science*. <https://doi.org/10.1126/science.228.4704.1147>
- Goodenough, D., Dyk, A., Niemann, K., Pearlman, J., Chen, H., Han, T., Murdoch, M. & West, C. (2003). Processing Hyperion and ALI for forest classification [Conference Name: IEEE Transactions on Geoscience and Remote Sensing]. *IEEE Transactions on Geoscience and Remote Sensing*, 41(6), 1321-1331. <https://doi.org/10.1109/TGRS.2003.813214>
- Grabska, E., Hostert, P., Pflugmacher, D. & Ostapowicz, K. (2019). Forest stand species mapping using the sentinel-2 time series. *Remote Sensing*, 11(10), 1197. <https://doi.org/10.3390/rs11101197>
- Grigorieva, O., Brovkina, O. & Saidov, A. (2020). An original method for tree species classification using multitemporal multispectral and hyperspectral satellite data. *Silva Fennica*, 54(2). Récupérée 3 octobre 2024, à partir de <https://www.silvafennica.fi/article/10143>
- Henning Buddenbaum, S. S. & Hill, J. (2013). Fusion of full-waveform lidar and imaging spectroscopy remote sensing data for the characterization of forest stands [Publisher: Taylor & Francis \_eprint: <https://doi.org/10.1080/01431161.2013.776721>]. *International Journal of Remote Sensing*, 34(13), 4511-4524. <https://doi.org/10.1080/01431161.2013.776721>
- Hughes, G. (1968). On the mean accuracy of statistical pattern recognizers. *IEEE Transactions on Information Theory*, 14(1), 55-63. <https://doi.org/10.1109/TIT.1968.1054102>
- Immitzer, M., Neuwirth, M., Böck, S., Brenner, H., Vuolo, F. & Atzberger, C. (2019). Optimal input features for tree species classification in central europe based on multi-temporal sentinel-2 data [Number: 22 Publisher: Multidisciplinary Digital Publishing Institute]. *Remote Sensing*, 11(22), 2599. <https://doi.org/10.3390/rs11222599>
- Immitzer, M., Vuolo, F. & Atzberger, C. (2016). First experience with sentinel-2 data for crop and tree species classifications in central europe [Number: 3 Publisher: Multidisciplinary Digital Publishing Institute]. *Remote Sensing*, 8(3), 166. <https://doi.org/10.3390/rs8030166>
- Langohr, R. (2010). Quelques facteurs édaphiques dans l'écosystème forêt de Soigne. *Forêt Wallonne*, 105, 3-14.
- Latte, N., Kint, V., Drouet, T., Penninckx, V., Lebourgeois, F., Vanwijnberghe, S. & Claessens, H. (2015). Dendroécologie du hêtre en forêt de Soignes. Les cernes des arbres nous renseignent

- sur les changements récents et futurs. *Forêt.nature*(137), 25-37. Récupérée 23 juillet 2024, à partir de [https://orbi.uliege.be/bitstream/2268/190054/1/FO137-24-37\\_VF.pdf](https://orbi.uliege.be/bitstream/2268/190054/1/FO137-24-37_VF.pdf)
- Monbaliu, D., Godefroid, S., Triest, L. & Boekaerts, P. (2003). Monitoring of vegetation stress and water quality of the sonian forest (CASI-TIR 2003 campaign).
- Pierron, S. (1905). *Histoire de la forêt de Soigne : Ouvrage publié sous les auspices de la Direction des Eaux et Forêts et orné de 116 gravures*. Bruxelles, Imp. scientifique Charles Bulens, 1905. <https://www.biodiversitylibrary.org/item/203885>
- Savitzky, A. & Golay, M. J. E. (1964). Smoothing and Differentiation of Data by Simplified Least Squares Procedures. [Publisher: American Chemical Society]. *Analytical Chemistry*, 36(8), 1627-1639. <https://doi.org/10.1021/ac60214a047>
- Segl, K., Guanter, L., Rogass, C., Kuester, T., Roessner, S., Kaufmann, H., Sang, B., Mogulsky, V. & Hofer, S. (2012). EeteS—The EnMAP End-to-End Simulation Tool [Conference Name: IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(2), 522-530. <https://doi.org/10.1109/JSTARS.2012.2188994>
- Shrestha, M., Helder, D. & Christopherson, J. (2021). DLR Earth Sensing Imaging Spectrometer (DESI) level 1 product evaluation using RadCalNet measurements. Récupérée 24 juillet 2024, à partir de <https://www.usgs.gov/publications/dlr-earth-sensing-imaging-spectrometer-desis-level-1-product-evaluation-using>
- Stavros, S., Theofilos, V. & Olga, S. (2016). Estimating forest species abundance through linear unmixing of CHRIS/PROBA imagery [Publisher: Elsevier]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 119, 79-89. <https://doi.org/10.1016/j.isprsjprs.2016.05.013>
- Tempfli, K., Huurneman, G. C., Bakker, W. H., Janssen, L. L. F., Feringa, W. F., Gieske, A. S. M., Grabmaier, K. A., Hecker, C. A., Horn, J. A., Kerle, N., Meer, F. D. v. d., Parodi, G. N., Pohl, C., Reeves, C. V., Ruitenbeek, F. J. A. v., Schetselaar, E. M., Weir, M. J. C., Westinga, E. & Woldai, T. (2009). *Principles of remote sensing: an introductory textbook*. International Institute for Geo-Information Science ; Earth Observation. Récupérée 24 avril 2024, à partir de <https://research.utwente.nl/en/publications/principles-of-remote-sensing-an-introductory-textbook-4>
- Trier, Ø. D., Salberg, A.-B., Kermit, M., Rudjord, Ø., Gobakken, T., Næsset, E. & Aarsten, D. (2018). Tree species classification in norway from airborne hyperspectral and airborne laser scanning data. *European Journal of Remote Sensing*, 51(1), 336-351. <https://doi.org/10.1080/22797254.2018.1434424>
- Ustin, S. L. & Trabucco, A. (2000). Using hyperspectral data to assess forest structure. *Journal of Forestry*, 98(6), 47-49. <https://doi.org/10.1093/jof/98.6.47>
- Van Mol, B. & Ruddick, K. (2024). The Compact High Resolution Imaging Spectrometer (CHRIS): the future of hyperspectral satellite sensors. Imagery of Oostende coastal and inland waters, 10. Récupérée 24 juillet 2024, à partir de <https://earth.esa.int/eogateway/documents/20142/37627/the-compact-high-resolution-imaging-spectrometer-chris-the-future-of-hyperspectral-satellite---.pdf/21024d97-1c52-adca-cf3e-acce9c26e246>
- Vangi, E., D'Amico, G., Francini, S., Giannetti, F., Lasserre, B., Marchetti, M. & Chirici, G. (2021). The new hyperspectral satellite PRISMA: Imagery for forest types discrimination [Number:

4 Publisher: Multidisciplinary Digital Publishing Institute]. *Sensors*, 21(4), 1182. <https://doi.org/10.3390/s21041182>

Villafranca, A., Corbera, J., Martín, F. & Marchan, J. F. (2012). Limitations of Hyperspectral Earth Observation on Small Satellites. *Journal of Small Satellites*, 1.

---

# INFOGRAPHIE

- Bartwronski. (2022, mars 7). *Fast, GPU friendly, antialiasing downsampling filter* [Bart wronski]. Récupérée 16 janvier 2025, à partir de <https://bartwronski.com/2022/03/07/fast-gpu-friendly-antialiasing-downsampling-filter/>
- Brownlee, J. (2020, juillet 28). *Nested cross-validation for machine learning with python* [MachineLearningMastery.com]. Récupérée 24 novembre 2024, à partir de <https://www.machinelearningmastery.com/nested-cross-validation-for-machine-learning-with-python/>
- CEOS. (2024). *PRISMA Satellite Mission Summary | CEOS Database*. Récupérée 24 juillet 2024, à partir de [https://database.eohandbook.com/database/missionsummary.aspx?missionID=396&utm\\_source=eoportals&utm\\_content=prisma-hyperspectral](https://database.eohandbook.com/database/missionsummary.aspx?missionID=396&utm_source=eoportals&utm_content=prisma-hyperspectral)
- Copernicus. (2024, novembre 30). *Copernicus Browser*. Récupérée 30 novembre 2024, à partir de [https://browser.dataspace.copernicus.eu/?zoom=13&lat=50.78214&lng=4.44253&themeId=DEFAULT - THEME & visualizationUrl = U2FsdGVkX19P8bGuRtzXsJuygKlsT7Hl %2BBiajkwNFbwt5odn8ugi1gk6xUTara%2B6TzraXxy4y%2BrvO5UzPS0wQMYsXrOsRLI%2FpzqcCs7uuSwP8ft03bhfoFdOv53r7KLe&datasetId=S2\\_L2A\\_CDAS&fromTime=2023-11-28T00%3A00%3A00.000Z&toTime=2023-11-28T23%3A59%3A59.999Z&layerId=3\\_NDVI&demSource3D=%22MAPZEN%22&cloudCoverage=30&dateMode=SINGLE](https://browser.dataspace.copernicus.eu/?zoom=13&lat=50.78214&lng=4.44253&themeId=DEFAULT - THEME & visualizationUrl = U2FsdGVkX19P8bGuRtzXsJuygKlsT7Hl %2BBiajkwNFbwt5odn8ugi1gk6xUTara%2B6TzraXxy4y%2BrvO5UzPS0wQMYsXrOsRLI%2FpzqcCs7uuSwP8ft03bhfoFdOv53r7KLe&datasetId=S2_L2A_CDAS&fromTime=2023-11-28T00%3A00%3A00.000Z&toTime=2023-11-28T23%3A59%3A59.999Z&layerId=3_NDVI&demSource3D=%22MAPZEN%22&cloudCoverage=30&dateMode=SINGLE)
- DLR. (2022, avril 1). *DLR – german satellite EnMAP launches successfully*. Récupérée 30 avril 2024, à partir de [https://www.dlr.de/en/latest/news/2022/02/20220401\\_german-satellite-enmap-launches-successfully](https://www.dlr.de/en/latest/news/2022/02/20220401_german-satellite-enmap-launches-successfully)
- EOS Data Analytics, I. (2022, juillet 26). *NDVI mapping in agriculture, index formula, and uses*. Récupérée 30 novembre 2024, à partir de <https://eos.com/make-an-analysis/ndvi/>
- esri. (2024). *Définition de Polygone De Thiessen | Dictionnaire SIG*. Récupérée 15 novembre 2024, à partir de <https://support.esri.com/fr-fr/gis-dictionary/thiessen-polygon>
- European Space Agency. (2009, décembre 9). *ESA - Signatures spectrales* [Publisher: European Space Agency]. Récupérée 23 avril 2024, à partir de [https://www.esa.int/SPECIALS/Eduspace\\_FR/SEM9Q0S7NWF\\_0.html](https://www.esa.int/SPECIALS/Eduspace_FR/SEM9Q0S7NWF_0.html)
- European Space Agency. (2024). *S2 mission* [Sentiwiki.copernicus.eu]. Récupérée 16 janvier 2025, à partir de <https://sentiwiki.copernicus.eu/web/s2-mission>

- FUTURA-SCIENCES, 2.-2. (s. d.). *Définition | Climax - Climacique | Futura Planète* [Futura].  
Récupérée 21 juin 2024, à partir de <https://www.futura-sciences.com/planete/definitions/developpement-durable-climax-6392/>
- Grossmann, M. (2022). *European Beech Forests - Belgium*. Récupérée 21 juin 2024, à partir de <https://www.europeanbeechforests.org/world-heritage-beech-forests/belgium>
- Kogut, P. (2020, novembre 18). *Types of remote sensing: Devices and their applications* [EOS data analytics]. Récupérée 23 avril 2024, à partir de <https://eos.com/blog/types-of-remote-sensing/>
- Michael, M., Steven, C., Jordan, G. & Nina, F. (2022). *Resampling & registering rasters w. rasterio and geowombat — python open source spatial programming & remote sensing*. Récupérée 16 janvier 2025, à partir de [https://pygis.io/docs/e\\_raster\\_resample.html](https://pygis.io/docs/e_raster_resample.html)
- Mike, W. (2013, juin 27). *Hyperspectral imagery for forests* [Last Modified: 2024-05-22 Publisher: Natural Resources Canada]. Récupérée 24 juillet 2024, à partir de <https://natural-resources.canada.ca/our-natural-resources/forests/sustainable-forest-management/measuring-and-reporting/remote-sensing-forestry/hyperspectral-imagery-for-forests/13437>
- Nations Unies. (2024, avril 26). *Biodiversity - our strongest natural defense against climate change* [United nations] [Publisher: United Nations]. Récupérée 26 avril 2024, à partir de <https://www.un.org/en/climatechange/science/climate-issues/biodiversity>
- Nature, N. (2021, mars 30). *Comment la forêt de Soignes est-elle devenue une hêtraie cathédrale ? - Notre Nature* [Notre Nature]. Récupérée 21 juin 2024, à partir de <https://www.notrenature.be/article/comment-la-foret-de-soignes-est-elle-devenue-une-hetraie-cathedrale>

#### Images EnMAP :

- DLR (2023) : EnMAP Product  
0000013763\_02\_2A\_20230421T190232\_010301\_230523+U0BLNNTS436G.  
doi :10.15489/rlyibn8gjc58
- DLR (2023) : EnMAP Product  
0000015629\_02\_2A\_20230503T191056\_010301\_230506+U0BLNNTS436G.  
doi :10.15489/rlyibn8gjc58

#### Images PRISMA

- Product. (2021, March 29). PRISMA hyperspectral data. Processed by Agenzia Spaziale Italiana (ASI).
- Product. (2021, November 10). PRISMA hyperspectral data. Processed by Agenzia Spaziale Italiana (ASI).
- Product. (2022, March 11). PRISMA hyperspectral data. Processed by Agenzia Spaziale Italiana (ASI).
- Product. (2022, April 21). PRISMA hyperspectral data. Processed by Agenzia Spaziale Italiana (ASI).
- Product. (2023, June 24). PRISMA hyperspectral data. Processed by Agenzia Spaziale Italiana (ASI).

#### Image Sentinel-2 :

- European Space Agency (ESA). Sentinel-2 data, acquired on [22/04/2022], processed by [Copernicus browser]

---

## A Composition de la futaie en Forêt de Soignes bruxelloise

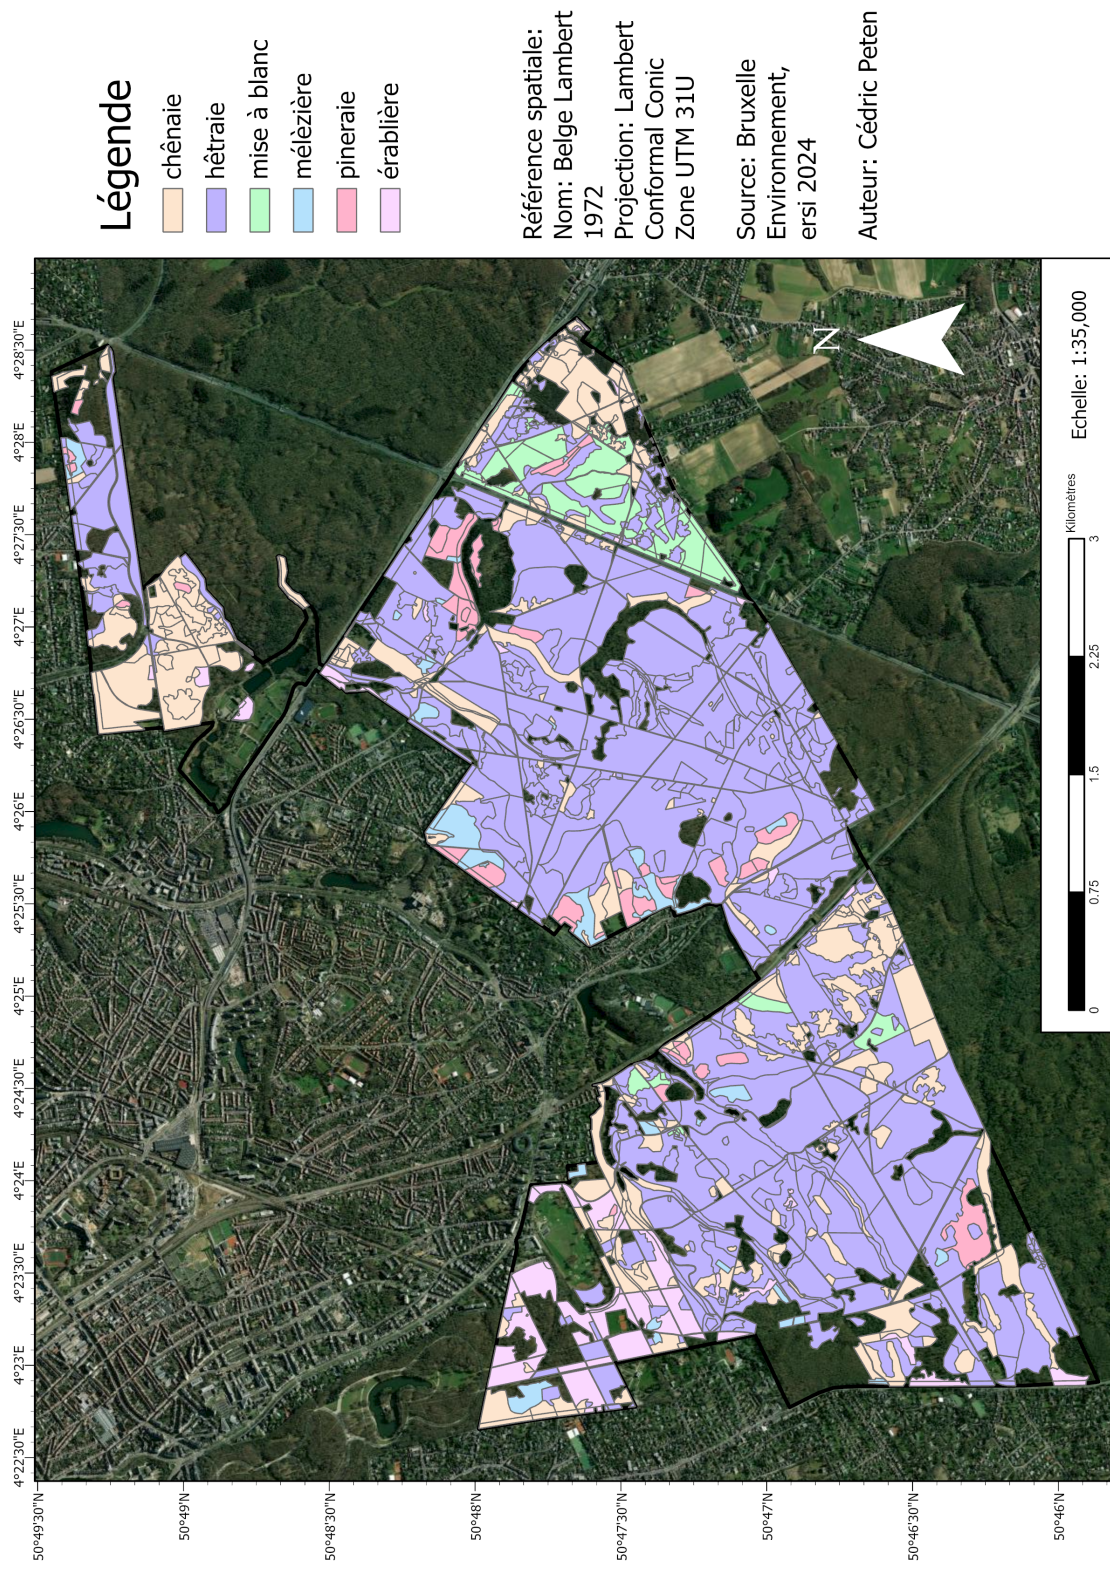
Liste des arbres et leurs peuplements

| Nom Latin                  | Nom Français         | Peuplement    |
|----------------------------|----------------------|---------------|
| <i>Acer campestre</i>      | érable champêtre     |               |
| <i>Acer platanoides</i>    | érable plane         |               |
| <i>Acer pseudoplatanus</i> | érable sycomore      | Erablière     |
| <i>Acer saccharinum</i>    | érable argenté       |               |
| <i>Acer sp</i>             | érable               |               |
| <i>Alnus glutinosa</i>     | aulne glutineux      | Aulnaie       |
| <i>Alnus sp</i>            | aulne                |               |
| <i>Betula pendula</i>      | bouleau verruqueux   |               |
| <i>Betula pubescens</i>    | bouleau pubescent    | Boulaie       |
| <i>Betula sp</i>           | bouleau              |               |
| <i>Carpinus betulus</i>    | charme commun        | Charmaie      |
| <i>Castanea sativa</i>     | châtaignier commun   | Châtaigneraie |
| <i>Corylus avellana</i>    | noisetier commun     | Coudraie      |
| <i>Fagus sylvatica</i>     | hêtre commun         | Hêtraie       |
| <i>Fraxinus excelsior</i>  | frêne commun         | Frênaie       |
| <i>Juglans sp</i>          | noyer                | Noyeraie      |
| <i>Malus sylvestris</i>    | pommier sauvage      | Pommeraie     |
| <i>Picea abies</i>         | épicéa commun        |               |
| <i>Picea sitchensis</i>    | épicéa de Sitka      | Pessièr       |
| <i>Pinus nigra</i>         | pin noir             |               |
| <i>Pinus sp</i>            | pin                  |               |
| <i>Pinus strobus</i>       | pin blanc d'Amérique | Pineraie      |
| <i>Pinus sylvestris</i>    | pin sylvestre        |               |
| <i>Populus sp</i>          | peuplier             | Peuplièr      |
| <i>Populus tremula</i>     | peuplier tremble     | Tremblaie     |

*Suite de la table*

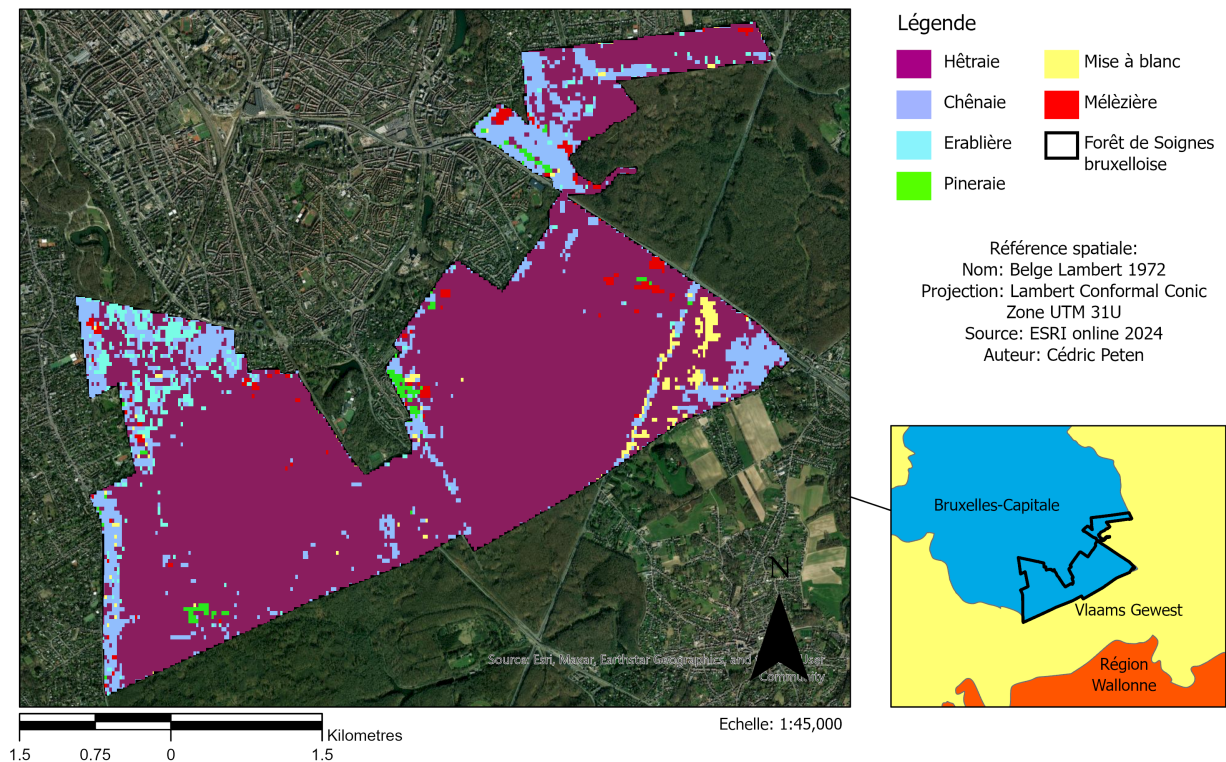
| <b>Nom Latin</b>             | <b>Nom Français</b>        | <b>Peuplement</b> |
|------------------------------|----------------------------|-------------------|
| <i>Prunus avium</i>          | merisier                   | Cérisaie          |
| <i>Pseudotsuga menziesii</i> | sapin de Douglas           | Sapinière         |
| <i>Quercus petraea</i>       | chêne sessile              | Chênaie           |
| <i>Quercus robur</i>         | chêne pédonculé            |                   |
| <i>Quercus rubra</i>         | chêne rouge                |                   |
| <i>Quercus sp</i>            | chêne                      |                   |
| <i>Robinia pseudoacacia</i>  | robinier faux-acacia       | Robiniaie         |
| <i>Salix alba</i>            | saule blanc                | Saulaie           |
| <i>Salix caprea</i>          | saule marsault             |                   |
| <i>Salix sp</i>              | saule                      |                   |
| <i>Sorbus aria</i>           | alisier blanc              | Aliseraie         |
| <i>Sorbus aucuparia</i>      | sorbier des oiseleurs      | Sorbière          |
| <i>Taxus sp</i>              | if                         | Ifaie             |
| <i>Tilia cordata</i>         | tilleul à petites feuilles | Tillaie           |
| <i>Tilia platyphyllos</i>    | tilleul à grandes feuilles |                   |
| <i>Tilia sp</i>              | tilleul                    |                   |
| <i>Tsuga sp</i>              | tsuga                      | Tsugaie           |
| <i>Tulipier</i>              | tulipier                   | Tuliperaie        |
| <i>Ulmus campestris</i>      | orme champêtre             | Ormaie            |
| <i>Ulmus glabra</i>          | orme de montagne           |                   |
| <i>Ulmus sp</i>              | orme                       |                   |

## B Représentation des peuplements d'arbres étudiés en Forêt de Soignes.



Représentation des peuplements étudiés dans cette recherche. (Bruxelles Environnement, 2024)

# C Classification : 2021/03/29 - PRISMA - Combinaison A



Raster : 2021/03/29 - PRISMA - Combinaison A

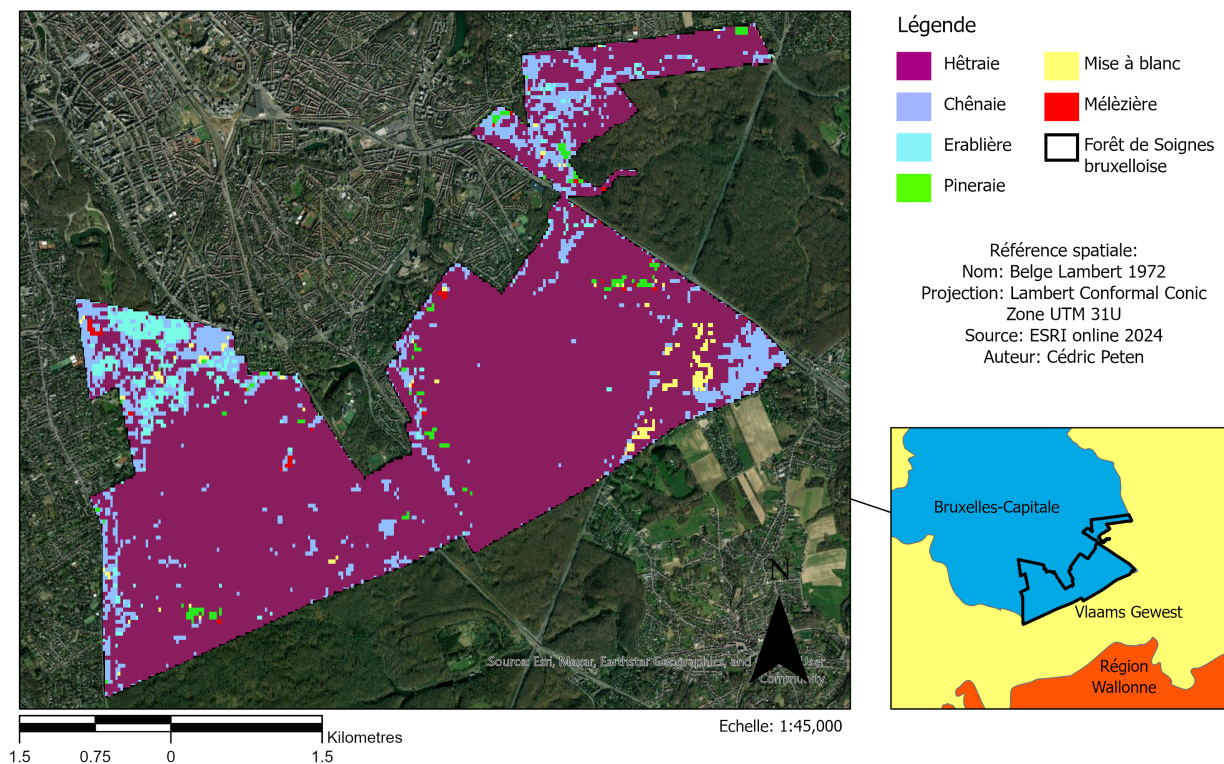
Matrice de confusion

|              | Chêne | Hêtre      | Mise à blanc | Mélèzière | Pineraie | Érablière |
|--------------|-------|------------|--------------|-----------|----------|-----------|
| Chêne        | 9     | 47         | 0            | 0         | 0        | 1         |
| Hêtre        | 1     | <b>393</b> | 0            | 0         | 0        | 2         |
| Mise à blanc | 0     | 17         | 0            | 1         | 1        | 0         |
| Mélèzière    | 0     | 24         | 0            | 0         | 0        | 0         |
| Pineraie     | 0     | 10         | 0            | 0         | 0        | 0         |
| Érablière    | 9     | 12         | 0            | 1         | 0        | 0         |

Rapport de classification

|                    | Précision | Rappel | f1-score | Support |
|--------------------|-----------|--------|----------|---------|
| Chêne              | 0.47      | 0.16   | 0.24     | 57      |
| Hêtre              | 0.78      | 0.99   | 0.87     | 396     |
| Mise à blanc       | 0.00      | 0.00   | 0.00     | 19      |
| Mélèzière          | 0.00      | 0.00   | 0.00     | 24      |
| Pineraie           | 0.00      | 0.00   | 0.00     | 10      |
| Érablière          | 0.00      | 0.00   | 0.00     | 22      |
| Exactitude globale | 0.76      |        |          |         |
| Moyenne macro      | 0.21      | 0.19   | 0.19     | 528     |
| Moyenne pondérée   | 0.64      | 0.76   | 0.68     | 528     |

# D Classification : 2022/03/11 - PRISMA - Combinaison A



Raster : 2022/03/11 - PRISMA - Combinaison A

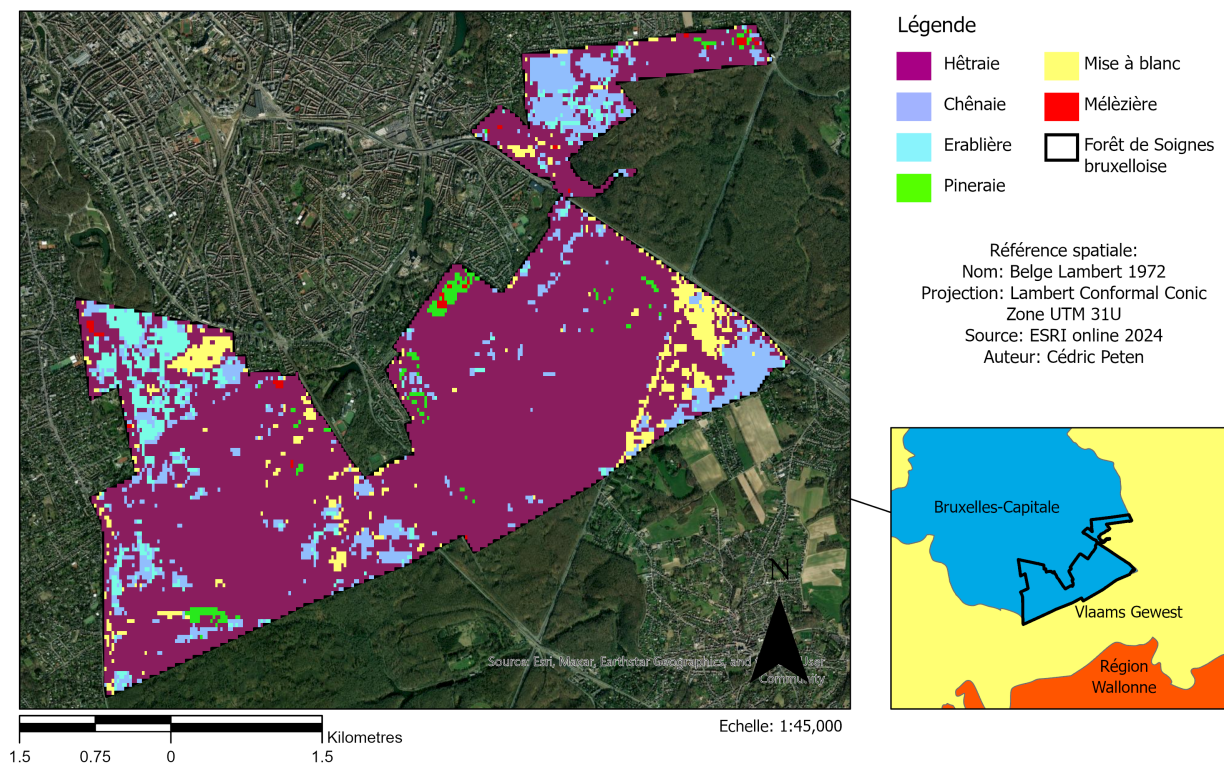
Matrice de confusion

|              | Chênaie | Hêtraie    | Mise à blanc | Mélézière | Pinaie   | Erablière |
|--------------|---------|------------|--------------|-----------|----------|-----------|
| Chênaie      | 2       | 49         | 0            | 0         | 0        | 2         |
| Hêtraie      | 9       | <b>372</b> | 0            | 0         | 0        | 0         |
| Mise à blanc | 0       | 19         | <b>0</b>     | 0         | 0        | 0         |
| Mélézière    | 1       | 22         | 0            | <b>0</b>  | 0        | 0         |
| Pinaie       | 0       | 9          | 0            | 0         | <b>0</b> | 0         |
| Erablière    | 10      | 14         | 0            | 0         | 0        | <b>0</b>  |

Rapport de classification

|                    | Précision | Rappel | f1-score | Support |
|--------------------|-----------|--------|----------|---------|
| Chênaie            | 0.09      | 0.04   | 0.05     | 53      |
| Hêtraie            | 0.77      | 0.98   | 0.86     | 381     |
| Mise à blanc       | 0.00      | 0.00   | 0.00     | 19      |
| Mélézière          | 0.00      | 0.00   | 0.00     | 23      |
| Pinaie             | 0.00      | 0.00   | 0.00     | 9       |
| Erablière          | 0.00      | 0.00   | 0.00     | 24      |
| Exactitude globale | 0.73      |        |          |         |
| Moyenne macro      | 0.14      | 0.17   | 0.15     | 509     |
| Moyenne pondérée   | 0.58      | 0.73   | 0.65     | 509     |

# E Classification : 2022/04/21 - PRISMA - Combinaison A



Raster : 2022/04/21 - PRISMA - Combinaison A

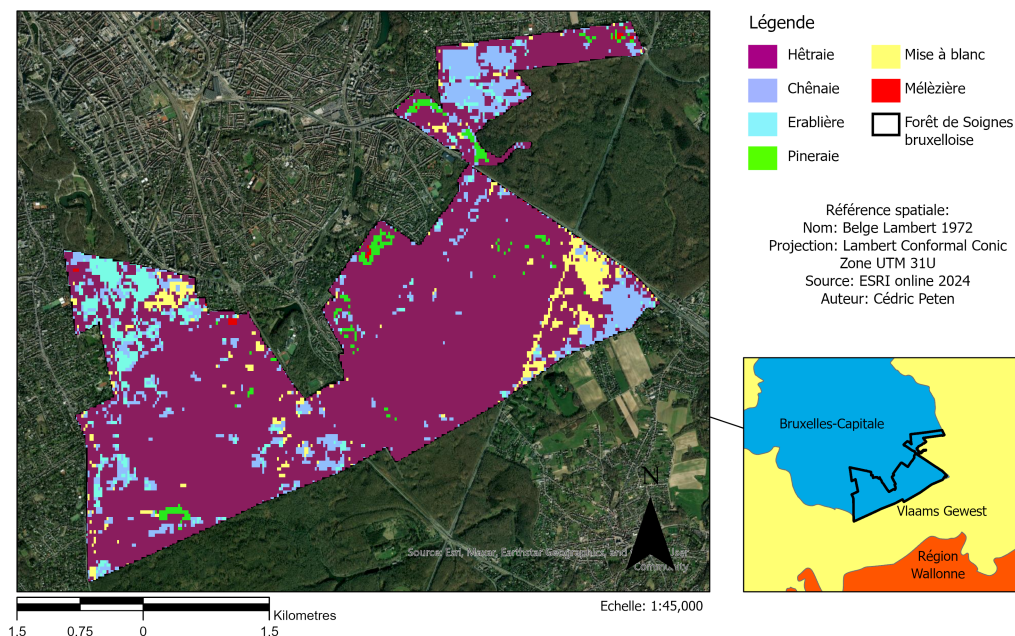
Matrice de confusion

|              | Chêne | Hêtre | Mise à blanc | Mélézière | Pineraie | Érablière |
|--------------|-------|-------|--------------|-----------|----------|-----------|
| Chêne        | 54    | 0     | 0            | 0         | 0        | 5         |
| Hêtre        | 7     | 391   | 5            | 0         | 0        | 2         |
| Mise à blanc | 0     | 12    | 10           | 0         | 0        | 0         |
| Mélézière    | 0     | 6     | 0            | 3         | 18       | 0         |
| Pineraie     | 0     | 5     | 0            | 0         | 3        | 0         |
| Érablière    | 0     | 16    | 0            | 0         | 0        | 6         |

Rapport de classification

|                    | Précision | Rappel | f1-score | Support |
|--------------------|-----------|--------|----------|---------|
| Chêne              | 0.89      | 0.92   | 0.90     | 59      |
| Hêtre              | 0.91      | 0.97   | 0.94     | 405     |
| Mise à blanc       | 0.67      | 0.45   | 0.54     | 22      |
| Mélézière          | 1.00      | 0.11   | 0.20     | 27      |
| Pineraie           | 0.14      | 0.38   | 0.21     | 8       |
| Érablière          | 0.46      | 0.27   | 0.34     | 22      |
| Exactitude globale | 0.86      |        |          |         |
| Moyenne macro      | 0.68      | 0.52   | 0.52     | 543     |
| Moyenne pondérée   | 0.87      | 0.86   | 0.85     | 543     |

# F Classification : 2022/03/11 & 2022/04/21 - PRISMA - Combinaison A



Raster : 2022/03/11 - 2022/04/21 - PRISMA - Combinaison A

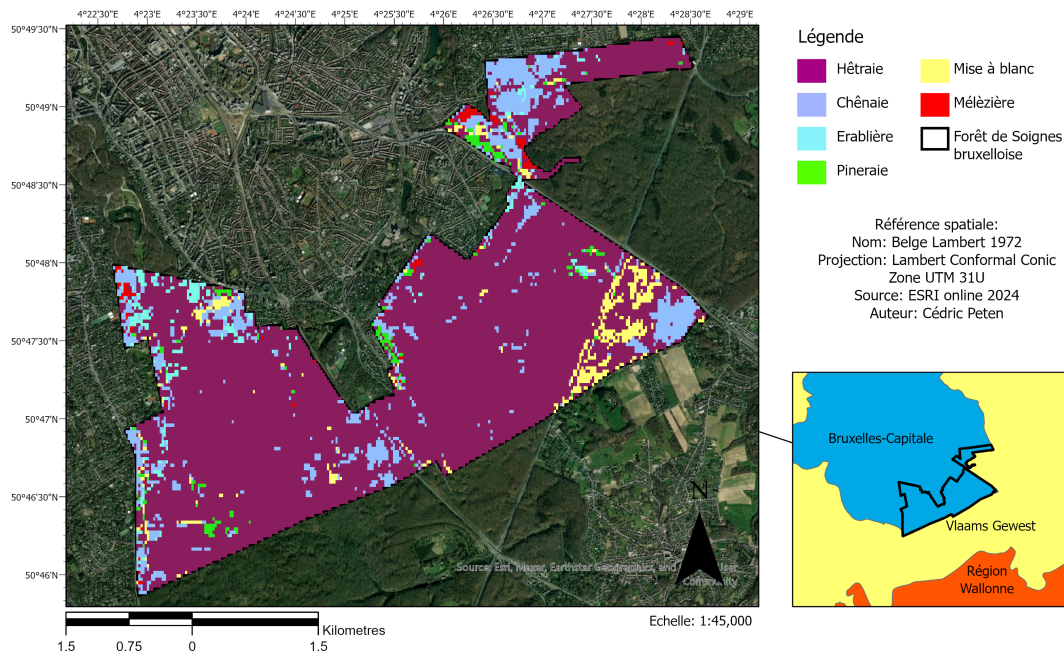
Matrice de confusion

|              | Chêne | Hêtre | Mise à blanc | Mélézière | Pinaie | Erablière |
|--------------|-------|-------|--------------|-----------|--------|-----------|
| Chêne        | 55    | 0     | 0            | 0         | 0      | 4         |
| Hêtre        | 6     | 394   | 3            | 0         | 0      | 2         |
| Mise à blanc | 0     | 16    | 6            | 0         | 0      | 0         |
| Mélézière    | 0     | 11    | 0            | 0         | 16     | 0         |
| Pinaie       | 0     | 5     | 0            | 0         | 3      | 0         |
| Erablière    | 0     | 16    | 0            | 0         | 0      | 6         |

Rapport de classification

|                    | Précision | Rappel | f1-score | Support |
|--------------------|-----------|--------|----------|---------|
| Chêne              | 0.90      | 0.93   | 0.92     | 59      |
| Hêtre              | 0.89      | 0.97   | 0.93     | 405     |
| Mise à blanc       | 0.67      | 0.27   | 0.39     | 22      |
| Mélézière          | 0.00      | 0.00   | 0.00     | 27      |
| Pinaie             | 0.16      | 0.38   | 0.22     | 8       |
| Erablière          | 0.50      | 0.27   | 0.35     | 22      |
| Exactitude globale | 0.85      |        |          |         |
| Moyenne macro      | 0.52      | 0.47   | 0.47     | 543     |
| Moyenne pondérée   | 0.81      | 0.85   | 0.83     | 543     |

# G Classification : 2023/06/24 - PRISMA - Combinaison A



Raster : 2023/06/24 - PRISMA - Combinaison A

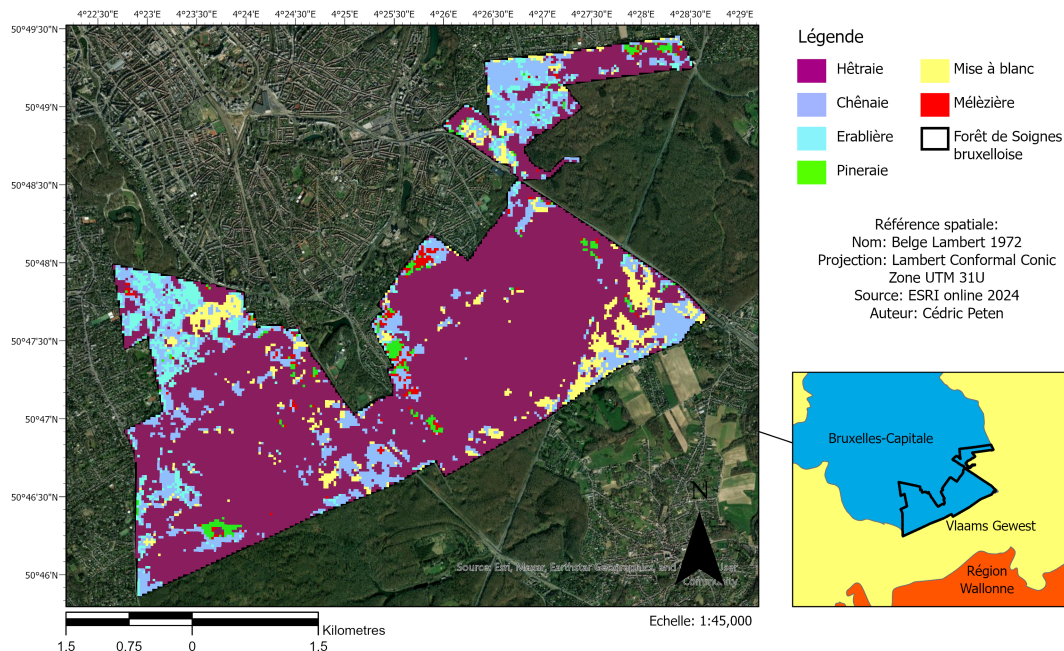
Matrice de confusion

|              | Chêne     | Hêtre      | Mise à blanc | Mélèze   | Pinaire  | Erablière |
|--------------|-----------|------------|--------------|----------|----------|-----------|
| Chêne        | <b>37</b> | 18         | 0            | 0        | 0        | 0         |
| Hêtre        | 4         | <b>395</b> | 1            | 0        | 0        | 0         |
| Mise à blanc | 0         | 19         | <b>1</b>     | 0        | 0        | 0         |
| Mélèze       | 0         | 26         | 0            | <b>0</b> | 0        | 0         |
| Pinaire      | 1         | 8          | 0            | 0        | <b>0</b> | 0         |
| Erablière    | 3         | 15         | 0            | 0        | 3        | <b>3</b>  |

Rapport de classification

|                    | Précision | Rappel | f1-score | Support |
|--------------------|-----------|--------|----------|---------|
| Chêne              | 0.82      | 0.67   | 0.74     | 55      |
| Hêtre              | 0.82      | 0.99   | 0.90     | 400     |
| Mise à blanc       | 0.50      | 0.05   | 0.09     | 20      |
| Mélèze             | 0.00      | 0.00   | 0.00     | 26      |
| Pinaire            | 0.00      | 0.00   | 0.00     | 9       |
| Erablière          | 1.00      | 0.13   | 0.22     | 24      |
| Exactitude globale | 0.82      |        |          |         |
| Moyenne macro      | 0.52      | 0.31   | 0.32     | 534     |
| Moyenne pondérée   | 0.76      | 0.82   | 0.76     | 534     |

# H Classification : 2023/04/21 - EnMAP - Combinaison A



Raster : 2023/04/21 - EnMAP - Combinaison A

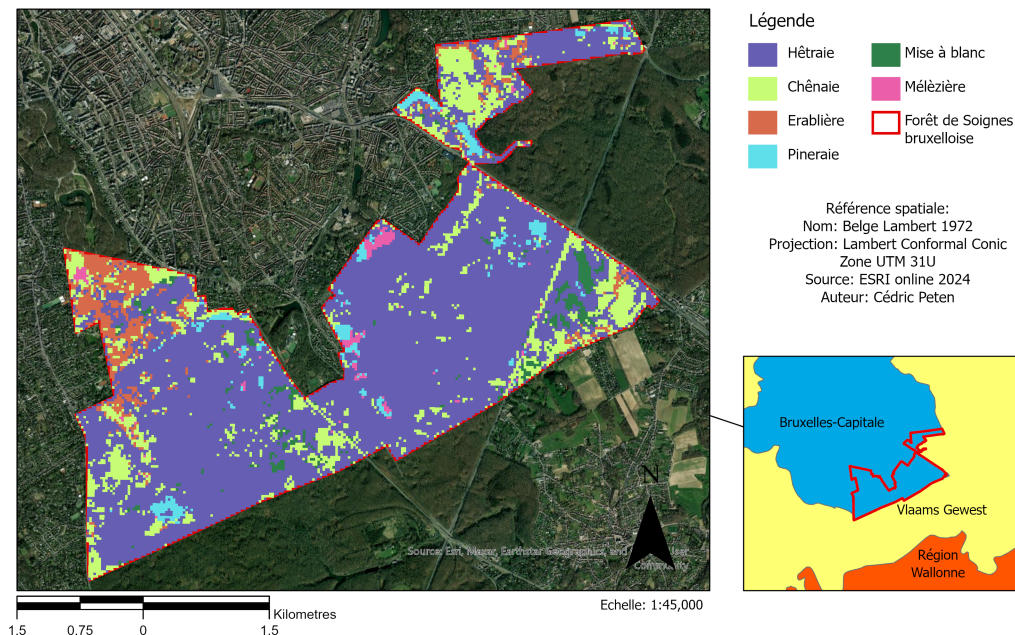
Matrice de confusion

|              | Chêne | Hêtre | Mise à blanc | Mélézière | Pineraie | Érablière |
|--------------|-------|-------|--------------|-----------|----------|-----------|
| Chêne        | 58    | 0     | 0            | 0         | 0        | 5         |
| Hêtre        | 3     | 436   | 2            | 0         | 0        | 0         |
| Mise à blanc | 4     | 2     | 16           | 0         | 0        | 0         |
| Mélézière    | 21    | 0     | 0            | 9         | 0        | 1         |
| Pineraie     | 0     | 3     | 0            | 4         | 3        | 0         |
| Érablière    | 13    | 3     | 0            | 0         | 0        | 10        |

Rapport de classification

|                    | Précision | Rappel | f1-score | Support |
|--------------------|-----------|--------|----------|---------|
| Chêne              | 0.59      | 0.92   | 0.72     | 63      |
| Hêtre              | 0.98      | 0.99   | 0.99     | 441     |
| Mise à blanc       | 0.89      | 0.73   | 0.80     | 22      |
| Mélézière          | 0.69      | 0.29   | 0.41     | 31      |
| Pineraie           | 1.00      | 0.30   | 0.46     | 10      |
| Érablière          | 0.63      | 0.38   | 0.48     | 26      |
| Exactitude globale | 0.90      |        |          |         |
| Moyenne macro      | 0.80      | 0.60   | 0.64     | 593     |
| Moyenne pondérée   | 0.91      | 0.90   | 0.89     | 593     |

# I Classification : 2023/05/03 - EnMAP - Combinaison A



Raster : 2023/05/03 - EnMAP - Combinaison A

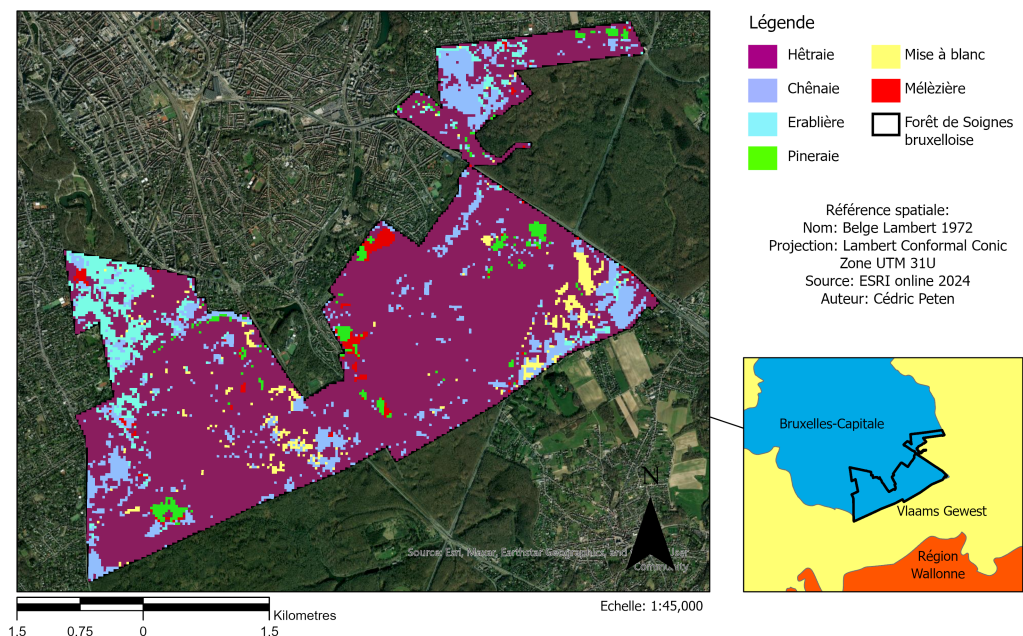
Matrice de confusion

|              | Chêne | Hêtre | Mise à blanc | Mélèze | Pineraie | Érable |
|--------------|-------|-------|--------------|--------|----------|--------|
| Chêne        | 61    | 2     | 0            | 0      | 0        | 0      |
| Hêtre        | 18    | 416   | 6            | 1      | 0        | 0      |
| Mise à blanc | 3     | 5     | 14           | 0      | 0        | 0      |
| Mélèze       | 0     | 2     | 0            | 29     | 0        | 0      |
| Pineraie     | 0     | 6     | 0            | 0      | 4        | 0      |
| Érable       | 2     | 7     | 0            | 0      | 0        | 17     |

Rapport de classification

|                    | Précision | Rappel | f1-score | Support |
|--------------------|-----------|--------|----------|---------|
| Chêne              | 0.73      | 0.97   | 0.83     | 63      |
| Hêtre              | 0.95      | 0.94   | 0.95     | 441     |
| Mise à blanc       | 0.70      | 0.64   | 0.67     | 22      |
| Mélèze             | 0.97      | 0.94   | 0.95     | 31      |
| Pineraie           | 1.00      | 0.40   | 0.57     | 10      |
| Érable             | 1.00      | 0.65   | 0.79     | 26      |
| Exactitude globale | 0.91      |        |          |         |
| Moyenne macro      | 0.89      | 0.76   | 0.79     | 593     |
| Moyenne pondérée   | 0.92      | 0.91   | 0.91     | 593     |

# J Classification : 2023/04/21 & 2023/05/03 - EnMAP - Combinaison A



Raster : 2023/04/21 2023/05/03 - EnMAP - Combinaison A

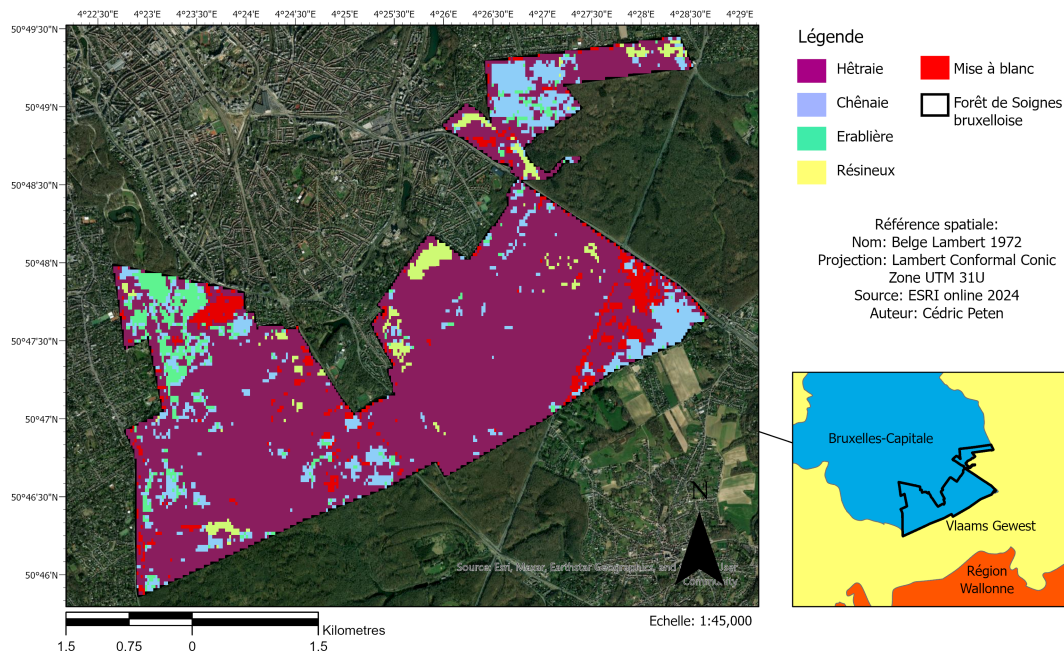
Matrice de confusion

|              | Chêne     | Hêtre      | Mise à blanc | Mélèzière | Pineraie | Erablière |
|--------------|-----------|------------|--------------|-----------|----------|-----------|
| Chêne        | <b>59</b> | 4          | 0            | 0         | 0        | 0         |
| Hêtre        | 13        | <b>425</b> | 3            | 0         | 0        | 0         |
| Mise à blanc | 4         | 4          | <b>14</b>    | 0         | 0        | 0         |
| Mélèzière    | 0         | 1          | 0            | <b>30</b> | 0        | 0         |
| Pineraie     | 0         | 6          | 0            | 0         | <b>4</b> | 0         |
| Erablière    | 1         | 9          | 0            | 0         | 0        | <b>16</b> |

Rapport de classification

|                    | Précision | Rappel | f1-score | Support |
|--------------------|-----------|--------|----------|---------|
| Chêne              | 0.77      | 0.94   | 0.84     | 63      |
| Hêtre              | 0.95      | 0.96   | 0.96     | 441     |
| Mise à blanc       | 0.82      | 0.64   | 0.72     | 22      |
| Mélèzière          | 1.00      | 0.97   | 0.98     | 31      |
| Pineraie           | 1.00      | 0.40   | 0.57     | 10      |
| Erablière          | 1.00      | 0.62   | 0.76     | 26      |
| Exactitude globale | 0.92      |        |          |         |
| Moyenne macro      | 0.92      | 0.75   | 0.81     | 593     |
| Moyenne pondérée   | 0.93      | 0.92   | 0.92     | 593     |

# K Classification : 2022/04/21 - PRISMA - Combinaison B



Raster : 2022/04/21 - PRISMA - Combinaison B

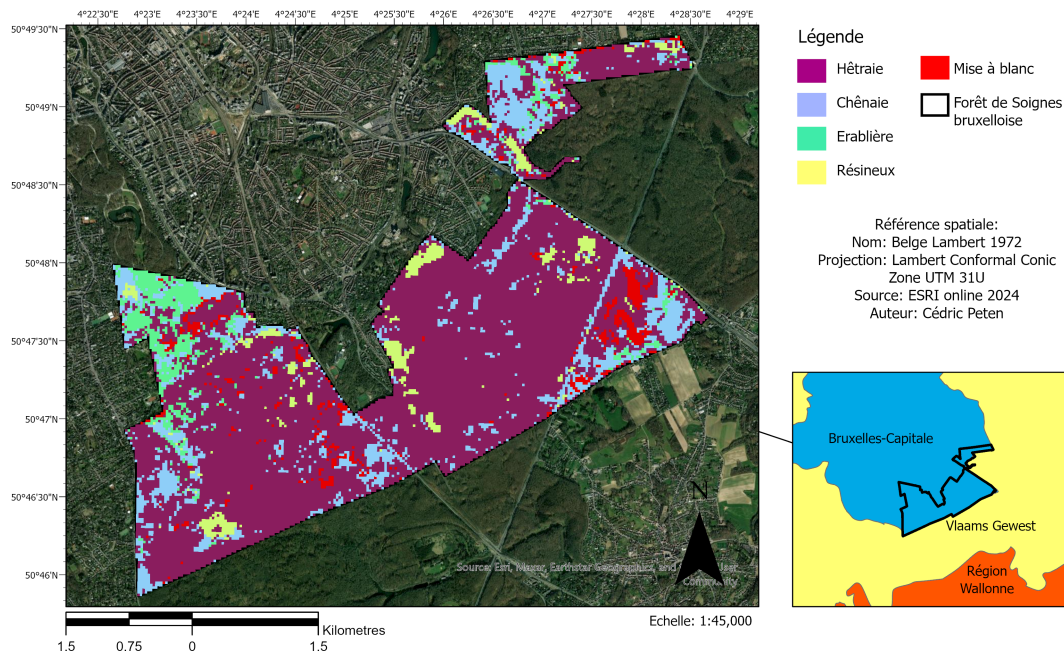
Matrice de confusion

|              | Chêne | Hêtre | Mise à blanc | Résineux | Érable |
|--------------|-------|-------|--------------|----------|--------|
| Chêne        | 56    | 0     | 0            | 0        | 3      |
| Hêtre        | 6     | 393   | 4            | 0        | 2      |
| Mise à blanc | 0     | 13    | 9            | 0        | 0      |
| Résineux     | 0     | 0     | 0            | 35       | 0      |
| Érable       | 0     | 16    | 0            | 0        | 6      |

Rapport de classification

|                    | Précision | Rappel | F1-score | Support |
|--------------------|-----------|--------|----------|---------|
| Chêne              | 0.90      | 0.95   | 0.93     | 59      |
| Hêtre              | 0.93      | 0.97   | 0.95     | 405     |
| Mise à blanc       | 0.69      | 0.41   | 0.51     | 22      |
| Résineux           | 1.00      | 1.00   | 1.00     | 35      |
| Érable             | 0.55      | 0.27   | 0.36     | 22      |
| Exactitude globale | 0.92      |        |          |         |
| Moyenne macro      | 0.81      | 0.72   | 0.75     | 543     |
| Moyenne pondérée   | 0.91      | 0.92   | 0.91     | 543     |

# L Classification : 2023/05/03 - EnMAP - Combinaison B



Raster : 2023/05/03 - EnMAP - Combinaison B

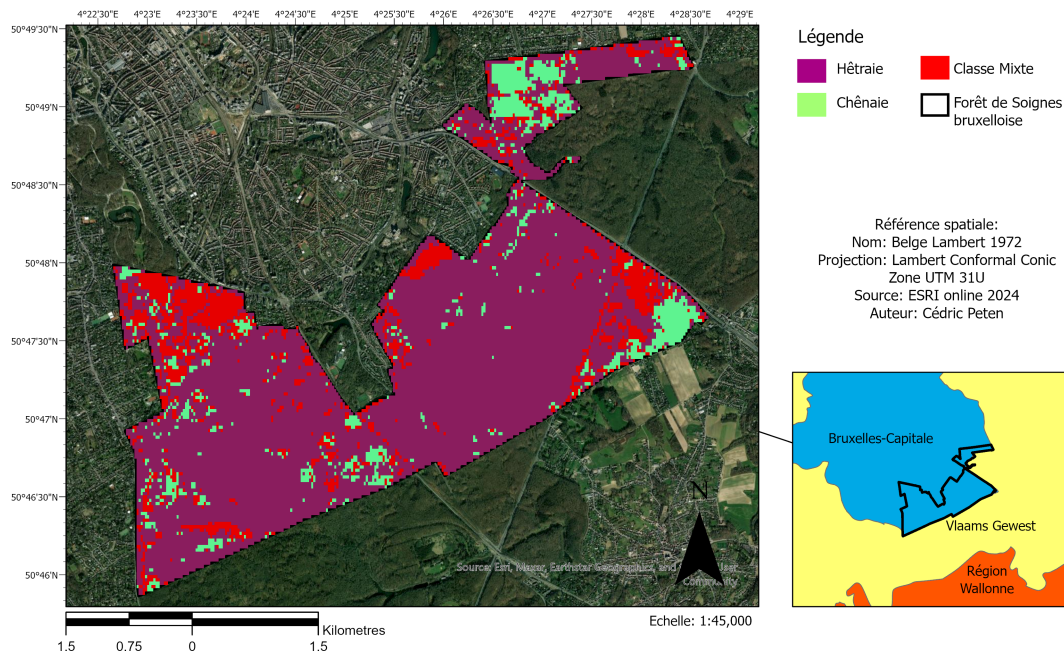
Matrice de confusion

|              | Chêne | Hêtre      | Mise à blanc | Résineux  | Érablière |
|--------------|-------|------------|--------------|-----------|-----------|
| Chêne        | 59    | 3          | 0            | 0         | 1         |
| Hêtre        | 18    | <b>413</b> | 7            | 3         | 0         |
| Mise à blanc | 4     | 4          | <b>14</b>    | 0         | 0         |
| Résineux     | 0     | 9          | 0            | <b>32</b> | 0         |
| Érablière    | 2     | 7          | 1            | 0         | <b>16</b> |

Rapport de classification

|                    | Précision | Rappel | F1-score | Support |
|--------------------|-----------|--------|----------|---------|
| Chêne              | 0.71      | 0.94   | 0.81     | 63      |
| Hêtre              | 0.95      | 0.94   | 0.94     | 441     |
| Mise à blanc       | 0.64      | 0.64   | 0.64     | 22      |
| Résineux           | 0.91      | 0.78   | 0.84     | 41      |
| Érablière          | 0.94      | 0.62   | 0.74     | 26      |
| Exactitude globale | 0.90      |        |          |         |
| Moyenne macro      | 0.83      | 0.78   | 0.79     | 593     |
| Moyenne pondérée   | 0.91      | 0.90   | 0.90     | 593     |

# M Classification : 2022/04/21 - PRISMA - Combinaison C



Raster : 2022/04/21 - PRISMA - Combinaison C

Matrice de confusion

|              | Chêne | Classe mixte | Hêtre |
|--------------|-------|--------------|-------|
| Chêne        | 55    | 4            | 0     |
| Classe mixte | 1     | 45           | 33    |
| Hêtre        | 3     | 10           | 392   |

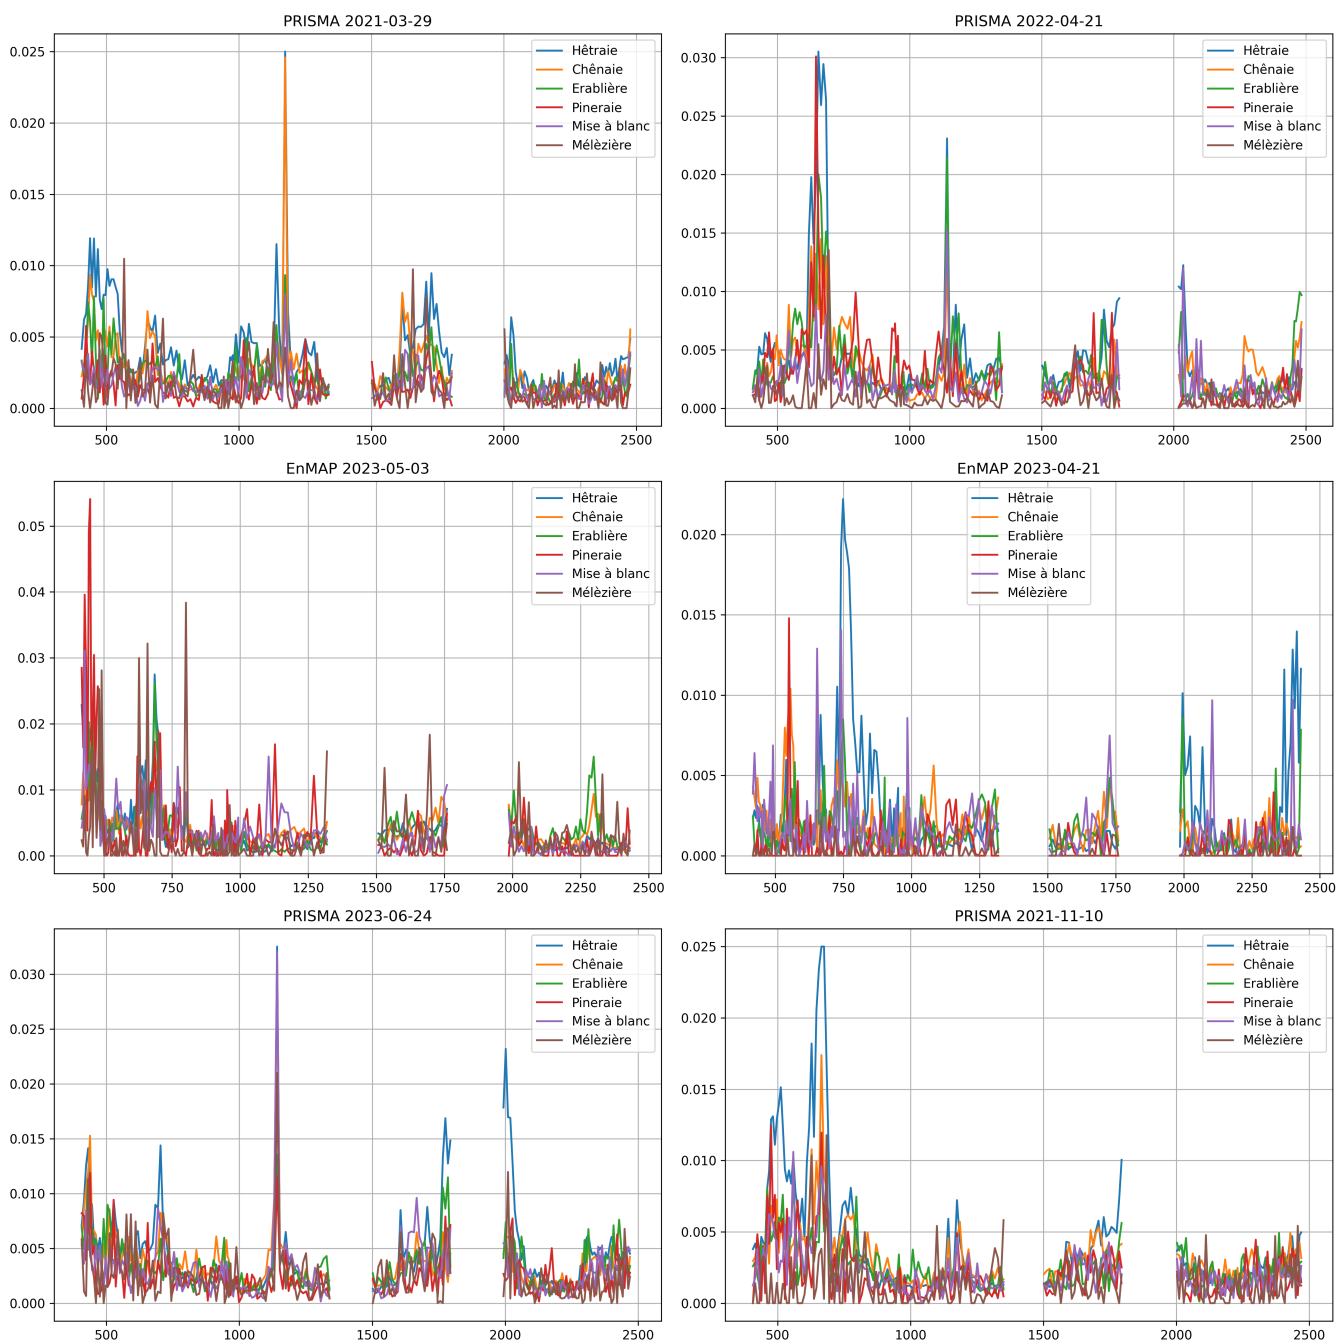
Rapport de classification

|                    | Précision | Rappel | F1-score | Support |
|--------------------|-----------|--------|----------|---------|
| Chêne              | 0.93      | 0.93   | 0.93     | 59      |
| Classe mixte       | 0.76      | 0.57   | 0.65     | 79      |
| Hêtre              | 0.92      | 0.97   | 0.94     | 405     |
| Exactitude globale | 0.91      |        |          |         |
| Moyenne macro      | 0.87      | 0.82   | 0.84     | 543     |
| Moyenne pondérée   | 0.90      | 0.91   | 0.90     | 543     |



# O Pouvoir de discrimination des bandes spectrales dans la classification des peuplements forestiers

Les graphiques présentés ci-dessous illustrent le pouvoir de discrimination des bandes spectrales dans la classification des peuplements forestiers. L'axe des ordonnées ( $y$ ) représente les valeurs quantitatives de contribution, tandis que l'axe des abscisses ( $x$ ) indique les longueurs d'onde correspondantes. Ces contributions sont calculées à partir de la capacité des bandes spectrales à réduire l'impureté des nœuds dans les arbres du modèle Random Forest, facilitant ainsi la séparation des classes. En identifiant les bandes spectrales ayant la plus grande influence sur la classification, ces graphiques permettent de visualiser les longueurs d'onde jouant un rôle clé dans le processus de prise de décision du modèle.



## **Discrimination des peuplements forestiers en Forêt de Soignes : Apports des images hyperspectrales PRISMA et EnMAP**

Présenté par Cédric Peten

La Forêt de Soignes, hêtraie emblématique de Belgique, subit des pressions environnementales croissantes dues aux changements climatiques et aux activités anthropiques. Ce mémoire examine le potentiel des images hyperspectrales obtenues des satellites PRISMA et EnMAP pour discriminer les peuplements forestiers. En combinant des analyses de signatures spectrales, l'étude explore l'impact des périodes phénologiques, des combinaisons de dates d'acquisition et de la quantité de données disponibles sur la précision de la classification. Les résultats mettent en évidence l'efficacité des capteurs hyperspectraux pour une cartographie des essences forestières, mais révèlent également leurs limites par rapport aux données multispectrales en termes de performance. Cette étude souligne à la fois les opportunités et les défis des capteurs hyperspectraux pour la gestion durable des écosystèmes, et propose des perspectives méthodologiques applicables à d'autres contextes environnementaux.