



Université de Toulouse

MASTER 2 GEOMATIQUE

« Sciences Géomatiques en environneMent et Aménagement » (SIGMA)

<http://sigma.univ-toulouse.fr>

RAPPORT DE STAGE

Différenciation des occupations du sol selon  
les applications thématiques. Étude d'un cas  
d'utilisation : les zones urbaines.

FONTAINE Agathe



Maître de stage : Virginie DAHINGER  
Enseignant-référent : David SHEEREN

Septembre 2021

## Résumé

Les cartes d'occupation du sol sont des outils d'appui pour des analyses thématiques des territoires, comme l'imperméabilisation des sols, le développement de la nature en ville, la séquestration du carbone, etc. Ce rapport de stage s'intéresse à l'occupation du sol en zone urbaine au sein de la communauté de communes de la Save au Touch. Deux processus de classification supervisée basée objet, dite *OBIA (Object-Based Image Analysis)*, y sont détaillés. Le premier se concentre sur la classification de la végétation avec quatre classes (autre, végétation basse, végétation haute et ombre). Elle est basée sur les orthophotographies très haute résolution (THR) de l'IGN. Un accord global de 94.8 % a été obtenu pour l'année 2019. Le second processus permet d'intégrer huit classes d'occupation du sol (bâtiment, surface imperméabilisée, sol nu, végétation haute, végétation basse, surface en eau, piscine, ombre). Les données d'entrée comprennent aussi les orthophotographies THR de l'IGN, ainsi que la couche « BATI » de la BD TOPO de l'IGN. Les accords globaux obtenus sont de 92.4 % pour l'année 2016 et 87.7 % pour l'année 2019.

Ce rapport présente uniquement une partie du travail effectué lors du stage, équivalent à un peu plus de la moitié. La seconde partie n'est pas abordée pour des questions de confidentialité.

**Mots clés :** Classification supervisée basée objet ; imagerie très haute résolution ; occupation du sol ; zone urbaine.

## Abstract

Land cover maps are support tools for thematic analyses of territories, such as soil sealing, nature development in cities, carbon sequestration, etc. In this internship report, attention is given to land cover in urban areas within the Save au Touch municipality community. Two object-based supervised classification processes, called *OBIA (Object-Based Image Analysis)*, are detailed. The first focuses on the classification of vegetation with four classes (other, low vegetation, high vegetation, and shadow). It is based on the IGN's very high resolution (VHR) imagery. An overall accuracy of 94.8% was reached for the year 2019. The second process makes it possible to integrate eight land use classes (building, impervious surface, bare soil, high vegetation, low vegetation, water surface, pool, shadow). The input data also includes the IGN's VHR imagery, as well as the "BATI" layer of the IGN's « BD TOPO ». The overall accuracies reached are 92.4% for the year 2016 and 87.7% for the year 2019.

This report presents only a part of the work done during the internship, equivalent to a little more than half. The second part is not discussed for confidentiality reasons.

**Keywords :** Land cover ; Object-Based Image Analysis ; supervised classification ; urban area ; very high resolution imagery.

## Remerciements

En arrivant chez MEOSS j'ai rencontré une équipe accueillante, dynamique et motivée, qui a participé au très bon déroulement de ce stage. Je les en remercie.

Je remercie particulièrement Virginie Dahinger, ma maître de stage, pour l'organisation générale du stage, son suivi, tous ses conseils et la relecture de mon rapport. Merci également à Thomas Ferrero de m'avoir accordé sa confiance et permis d'intégrer l'équipe ; et à Nafissa Sfaksi pour ses conseils techniques et son suivi.

## Table des matières

Introduction.....	1
Partie 1 : Contexte général et enjeux du stage .....	2
1. Présentation de MEOSS.....	2
2. Enjeux du stage .....	3
2.1. MEO – Urban Green .....	3
2.2. MEO – Land Cover .....	3
3. Objectifs du stage.....	3
Partie 2 : Méthodes de télédétection appliquées à la cartographie de la végétation et de l’occupation du sol en zone urbaine .....	4
1. Territoire d’étude .....	4
2. Méthodologie.....	4
2.1. Données utilisées .....	4
2.1.1. Images satellites Pléiades.....	4
2.1.2. Orthophotographies.....	5
2.1.3. Données auxiliaires.....	6
2.2. Méthodes de classification envisagées .....	7
2.2.1. Classification supervisée à l’échelle du pixel.....	7
2.2.2. Classification supervisée basée objet.....	7
2.3. Comparaison des méthodes.....	13
2.3.1. Méthodes de segmentation .....	13
2.3.2. Méthodes de classification supervisée basée objet ( <i>OBIA</i> ) .....	15
2.4. Application au territoire de la Communauté de Communes de la Save au Touch .....	18
2.4.1. Extraction de la tache urbaine.....	18
2.4.2. Application des méthodes de segmentation et classifications retenues.....	19
2.4.3. Résultats de la classification de la végétation sur le territoire de la CCST.....	22
2.4.4. Résultats de la classification de l’occupation du sol sur le territoire de la CCST .....	24
3. Conclusion et perspectives.....	28
ANNEXES.....	32
ANNEXE 1 : Diagramme de Gantt.....	33
ANNEXE 2 : Tableaux de comparaison des méthodes de segmentation .....	35
ANNEXE 3 : Tableaux de comparaison des méthodes de classification .....	43
ANNEXE 4 : Diagramme de flux du processus de production de la tache urbaine .....	47
ANNEXE 5 : Diagramme de flux du processus de classification de la végétation en milieu urbain .....	49
ANNEXE 6 : Diagramme de flux du processus de classification de l’occupation du sol en milieu urbain.. ..	52

## Table des figures

Figure 1: Localisation du territoire de la Communauté de Communes de la Save au Touch (CCST).....	4
Figure 2: Comparaison d'une image Pléiades en date de mars 2019 (à gauche) et d'une image de la BD ORTHO (IGN) de 2019 (à droite) sur une portion du territoire de la CCST. ....	5
Figure 3: Orthophotographies de 2016 (à gauche) et 2019 (à droite) sur un secteur proche des limites de la CCST, mettant en évidence les différences de dates localement importantes dans les prises de vue. Les cultures sur l'extrême sud de la zone sont à un état de croissance différent de la partie supérieure. ....	6
Figure 4: Schéma aidant au choix des estimateurs pour la classification supervisée. Ce schéma est un extrait d'un schéma plus général, issu de la documentation de Scikit-Learn (Pedregosa, et al. 2011)..	9
Figure 5: Tracés des fonctions de décisions pour un algorithme de type SVM à noyau linéaire, et SVM à noyau RBF, appliqués à un jeu de données exemples (iris). (Pedregosa, et al. 2011) .....	9
Figure 6: Comparaison des segmentations pour l'image Pléiades (v03), à gauche, et de l'orthophotographie (v18), à droite, sur une portion du territoire de la CCST. Les images sont en fausses couleurs (proche infrarouge, rouge et vert).....	14
Figure 7: Carte présentant le contour de la tache urbaine de la CCST. ....	19
Figure 8 : Répartition de l'échantillonnage entre les classes (outil MEO-Urban Green ; année 2019)	19
Figure 9: Exemples d'histogrammes de répartition - Moyennes des bandes du proche infrarouge et du rouge pour l'ensemble des objets segmentés (MEO-Urban Green ; année 2019). ....	20
Figure 10: Exemples d'histogrammes de répartition - Moyennes des bandes du proche infrarouge et du rouge pour les échantillons (MEO-Urban Green ; année 2019).....	20
Figure 11: Répartition de l'échantillonnage entre les classes (outil MEO-Land Cover; année 2019) ...	20
Figure 12: Exemples d'histogrammes de répartition – Médianes de l'indice spectral NDVI pour l'ensemble des objets segmentés (MEO-Land Cover ; année 2019).....	21
Figure 13 : Exemples d'histogrammes de répartition – Médianes de l'indice spectral NDVI pour les échantillons (MEO-Land Cover ; année 2019). ....	21
Figure 14 : Modèle 4 bandes (IR, R, V, NDVI) – Matrice de confusion moyenne de classification. La précision, le rappel et le score F1 sont exprimés en pourcentage. Les valeurs de classe correspondent à un nombre moyen d'échantillons. Les correspondances des classes sont les suivantes : 1-Autre, 2-Végétation basse, 3-Végétation haute, 4-Ombre. ....	22
Figure 15 : Modèle 4 bandes (IR, R, V, NDVI) – Estimation de la qualité moyenne par classe. Les correspondances des classes sont les suivantes : 1-Autre, 2-Végétation basse, 3-Végétation haute, 4-Ombre.....	22
Figure 16: Comparaison d'extraits de l'ortho-image vraies couleurs de 2019 (IGN) et du résultat de la classification selon le modèle 4 bandes (proche infrarouge, rouge, vert et NDVI). ....	23
Figure 17 : Modèle 10 bandes (IR, R, V, NDVI et SFS'Texture) – Matrice de confusion moyenne de classification. La précision, le rappel et le score F1 sont exprimés en pourcentage, tandis que les valeurs de classe correspondent à un nombre moyen d'échantillons. Les correspondances des classes sont les suivantes : 1-Autre, 2-Végétation basse, 3-Végétation haute, 4-Ombre. ....	23

Figure 18 : Modèle 10 bandes (IR, R, V, NDVI et SFS'Texture) – Estimation de la qualité moyenne par classe. Les correspondances des classes sont les suivantes : 1-Autre, 2-Végétation basse, 3-Végétation haute, 4-Ombre. ....	23
Figure 19: Comparaison d'extraits de l'ortho-image vraies couleurs de 2019 (IGN) et du résultat de la classification de la végétation selon le modèle 10 bandes (proche infrarouge, rouge, vert, NDVI et SFS'Texture).....	24
Figure 20 : Modèle 27 bandes, sans données auxiliaires (couche « BATI » de la BD TOPO) – Estimation de la qualité moyenne par classe pour l'année 2019. Les correspondances des classes sont les suivantes : 11-Bâtiment, 21-Surface imperméable, 31-Sol nu, 41-Végétation haute, 51-Végétation basse, 61-Surface en eau, 71-Piscine, 81-Ombre. ....	24
Figure 21 : Modèle 27 bandes, sans données auxiliaires (couche BATI de la BD TOPO) – Matrice de confusion moyenne de classification. La précision, le rappel et le score F1 sont exprimés en pourcentage, tandis que les valeurs de classe correspondent à un nombre moyen d'échantillons. Les correspondances des classes sont les suivantes : 11-Bâtiment, 21-Surface imperméable, 31-Sol nu, 41-Végétation haute, 51-Végétation basse, 61-Surface en eau, 71-Piscine, 81-Ombre.....	25
Figure 22 : Comparaison d'extraits de l'ortho-image vraies couleurs de 2019 (IGN) et du résultat de la classification de l'occupation du sol selon le modèle 27 bandes ne comprenant pas la couche BATI de la BD TOPO de l'IGN – Zone en construction. ....	25
Figure 23 : Classifications avec données auxiliaires (couche « BATI » de la BD TOPO) – Estimations de la qualité moyenne par classe. Les correspondances des classes sont les suivantes : 11-Bâtiment, 21-Surface imperméable, 31-Sol nu, 41-Végétation haute, 51-Végétation basse, 61-Surface en eau, 71-Piscine, 81-Ombre. Année 2016 à gauche (modèle 35 bandes) et année 2019 à droite (modèle 34 bandes).....	26
Figure 24 : Classifications avec données auxiliaires (couche « BATI » de la BD TOPO) – Matrices de confusion moyennes. La précision, le rappel et le score F1 sont exprimés en pourcentage, tandis que les valeurs de classe correspondent à un nombre moyen d'échantillons. Les correspondances des classes sont les suivantes : 11-Bâtiment, 21-Surface imperméable, 31-Sol nu, 41-Végétation haute, 51-Végétation basse, 61-Surface en eau, 71-Piscine, 81-Ombre. Année 2016 à gauche (modèle 35 bandes) et année 2019 à droite (modèle 34 bandes). ....	26
Figure 25 : Comparaison d'extraits de l'ortho-image vraies couleurs de 2016 (IGN) et du résultat de la classification de l'occupation du sol selon le modèle 35 bandes comprenant la couche BATI de la BD TOPO de l'IGN – Quartier résidentiel composé de maisons individuelles et d'espaces verts. ....	27
Figure 26 : Comparaison d'extraits de l'ortho-image vraies couleurs de 2019 (IGN) et du résultat de la classification de l'occupation du sol selon le modèle 35 bandes comprenant la couche BATI de la BD TOPO de l'IGN – Zone en construction.....	27
Figure 27 : Pyramide WMS MNS sur la Gare Saint Charles (Marseille). (IGN 2020) .....	29
Figure 28 : Carte des 40 départements avec un MNS disponible. (IGN 2020).....	29

## Liste des tableaux

Tableau 1 : Paramètres de segmentation retenus en vue de la classification de l'occupation du sol (MEO-Land Cover) .....	15
Tableau 2 : Méthodes de classification retenues pour la classification de la végétation en zone urbaine (MEO-Urban Green) .....	16
Tableau 3 : Méthodes de classification retenues pour la classification de l'occupation du sol en zone urbaine (MEO-Land Cover).....	18

## Glossaire

CC : Communauté de Communes

CEREMA : Centre d'études et d'Expertise sur les Risques, l'Environnement, la Mobilité et l'Aménagement

CESBIO : Centre d'Études Spatiales de la BIOSphère

CLC : Corine Land Cover

CNES : Centre National d'Études Spatiales

EPCI : Établissement Public de Coopération Intercommunal

ESA BIC : European Space Agency Business Incubation Center

OCS : Occupation du sol

PCAET : Plan Climat Air Énergie Territorial

SCO : Space Climate Observatory

# Introduction

La classification de l'occupation du sol n'est pas une fin en soi, mais sert plutôt de base pour des analyses thématiques. L'occupation des sols en zone urbaine présente de nombreux intérêts. En effet, l'aménagement des villes doit continuer de s'améliorer afin de prendre en compte la problématique de l'imperméabilisation des sols, des îlots de chaleur, de la régulation des eaux pluviales, etc. Il doit également intégrer la nature en ville afin d'améliorer la qualité de vie des citoyens, favoriser la biodiversité, ou encore augmenter la séquestration du carbone par les sols et la biomasse.

D'une manière plus globale, les acteurs locaux doivent mettre les services écosystémiques rendus par les différents types d'occupation du sol dans la balance pour le choix des sites à protéger, à exploiter ou à développer (Sharp, et al. 2020). Les cartes peuvent s'avérer une aide précieuse pour la prise de décisions. Dans ce cadre, MEOSS peut apporter son expertise. L'entreprise crée en effet des données géospatiales et propose des services pour une meilleure compréhension des territoires. Elle est en outre spécialisée sur les enjeux climatiques.

Ce stage se concentre sur la classification de la végétation et de l'occupation du sol en zone urbaine. Un deuxième axe a été abordé au cours du stage mais ne sera pas développé ici pour des questions de confidentialité.

Le rapport présenté est ainsi décliné en deux parties :

- 1- Le contexte général et les enjeux du stage. Une présentation de MEOSS, les enjeux et les objectifs du stage y seront détaillés.
- 2- **Les méthodes de télédétection appliquées à la cartographie de la végétation et de l'occupation du sol en zone urbaine.** Cette partie s'attachera à présenter les méthodes et les résultats de classifications à partir d'images très haute résolution. Le territoire d'application est la Communauté de Communes de la Save au Touch, à l'Ouest de Toulouse.

# Partie 1 : Contexte général et enjeux du stage

## 1. Présentation de MEOSS

**MEOSS** est une start-up créée en octobre 2018, s'appuyant en partie sur l'**imagerie satellite** et les données issues de celle-ci, telles que les données du programme européen Copernicus, pour proposer des outils aux acteurs publics en particulier, mais également privés. Les services proposés participent à une **meilleure compréhension des territoires** par la **création de données géospatiales**, d'une **visualisation spatiale de l'information** et d'indicateurs définis conjointement avec les utilisateurs finaux. Notamment, les outils développés apportent un soutien aux collectivités dans la gestion de leur territoire, les prises de décisions et les actions mises en place, avec une **spécialisation pour les enjeux climatiques**. L'expérience des membres de l'équipe de MEOSS au sein des collectivités territoriales est un atout pour échanger de manière constructive, récolter des besoins précis et ainsi développer des outils et services adaptés à ces derniers.

Plusieurs dates importantes marquent le début du parcours de MEOSS :

- En février 2019, MEOSS participe à l'accélérateur européen de start-up Astropreneur. L'entreprise s'installe ensuite au sein des bureaux d'*Aerospace Valley*.
- En octobre 2019, elle est lauréate de l'Hackathon Copernicus de Toulouse, évènement organisé par le Pôle de compétitivité Aerospace Valley et Epitech, financé et labellisé par la Commission Européenne. Grâce à cela, elle a pu bénéficier du programme européen d'accélération de start-ups Copernicus Accelerator.
- En janvier 2020, l'entreprise adhère au réseau ESA BIC Sud France.

Également, MEOSS affirme son positionnement sur les enjeux liés aux changements climatiques par deux projets labellisés *SCO (Space Climate Observatory)* depuis juin 2020. Le premier porte sur le pilotage des actions liées aux énergies renouvelables, à la gestion des réserves en eau, aux pratiques agricoles ; et le second sur la thématique de l'irrigation en grandes cultures réalisé en partenariat avec le CESBIO, leader du projet. « *Le SCO est un consortium international regroupant des agences spatiales et organisations internationales qui se réunissent régulièrement pour convenir de projets et d'actions répondant à des objectifs communs liés aux engagements internationaux pris par les nations pour s'attaquer aux problèmes du changement climatique. Il a notamment pour vocation d'aider au développement d'outils opérationnels adaptés aux échelles nationales et locales, et ainsi d'aider les territoires à mettre en œuvre des politiques d'adaptation. Le SCO France est la déclinaison nationale de l'initiative internationale, qui rassemble la communauté scientifique, les autorités publiques et les entreprises autour du SCO International. Les projets sont portés par des consortiums et sont sélectionnés au travers d'appels à projets*» (SCO France 2021).

D'une manière générale, MEOSS s'attache à répondre aux problématiques de lutte et de résilience face aux changements climatiques à travers l'ensemble de ses services.

Dans le cadre de plusieurs de ses projets, l'entreprise est partenaire d'institutions publiques et acteurs privés. On pourra notamment citer de façon non exhaustive : le CNES, Aerospace Valley, le CESBIO, ATOS, Audanis, Vivinnov, etc.

## 2. Enjeux du stage

Les travaux menés au cours du stage se focalisent sur deux des outils de l'offre de services de MEOSS.

### 2.1. MEO – Urban Green

L'outil *Meo-Urban Green* de MEOSS permet de visualiser les écarts de température de surface en milieu urbain et met en avant une carte de la végétation en zone urbaine. Cet outil permet notamment d'aider les collectivités à la planification de la politique de re-végétalisation urbaine et au suivi des actions (MEOSS s.d.). Un démonstrateur existe déjà. Sur cet outil, l'enjeu est ici de caler la méthodologie et d'automatiser les traitements.

### 2.2. MEO – Land Cover

*MEO-LandCover* est un outil de suivi et de pilotage des territoires permettant d'avoir une vision de l'usage et de l'occupation du sol, avec des classifications et résolutions différenciées entre zone urbaine, et zone péri-urbaine ou rurale. Plusieurs indicateurs de suivi sont disponibles, notamment l'étalement urbain, les trames vertes, l'artificialisation des sols, etc. Comme dans le cas de l'outil *MEO-UrbanGreen*, un démonstrateur a déjà été créé, et l'enjeu est de caler la méthodologie et mettre en place une automatisation des traitements.

## 3. Objectifs du stage

Des méthodes de télédétection devront être appliquées afin de produire une cartographie de la végétation et de l'occupation du sol en zone urbaine. Les objectifs du stage sont :

- la définition d'une méthodologie pour la classification à partir de données très haute résolution ;
- l'automatisation des traitements.

La classification de la végétation devra permettre de distinguer au minimum trois classes : végétation basse (herbacée), végétation haute (ligneuse) et « autre ».

La classification de l'occupation du sol devra idéalement permettre de distinguer sept classes : bâtiment, surface imperméabilisée, sol nu, végétation haute, végétation basse, surface en eau et piscine. Les post-traitements permettant d'intégrer les parcelles agricoles et de distinguer les routes, les voies ferrées, etc. ne font pas partie des objectifs. Cet aspect sera traité par une autre personne de l'équipe.

# Partie 2 : Méthodes de télédétection appliquées à la cartographie de la végétation et de l'occupation du sol en zone urbaine

## 1. Territoire d'étude

Le territoire considéré pour cette partie est celui de la Communauté de Communes de la Save au Touch (nommée CCST dans la suite du rapport), à l'Ouest de Toulouse. Son emprise est présentée sur la Figure 1. L'étude se concentre uniquement sur la tache urbaine de la CCST.

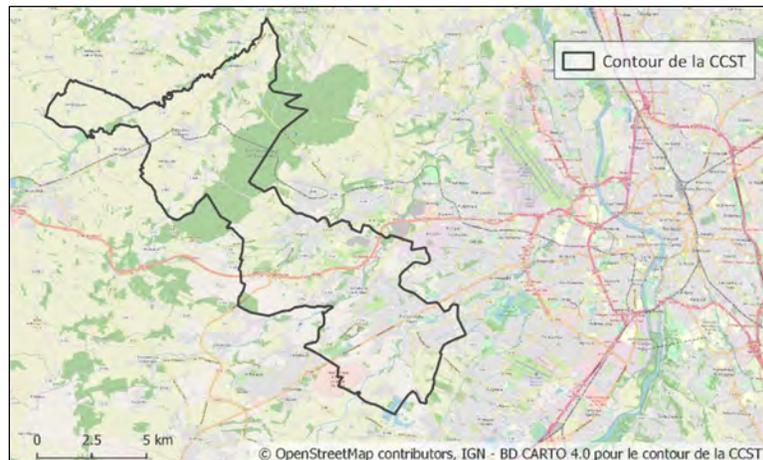


Figure 1: Localisation du territoire de la Communauté de Communes de la Save au Touch (CCST).

## 2. Méthodologie

### 2.1. Données utilisées

Du fait de la variation importante du type d'objets (arbres, bâtiments, surfaces enherbées, routes, ...) sur une surface restreinte, la détection de la végétation en milieu urbain et des différents types d'occupation du sol nécessite des images de très haute résolution spatiale. Deux types de données ont ainsi été mobilisées : des images satellitaires Pléiades et les ortho-images de la BDORTHO de l'IGN, issues de prises de vue aériennes. Les avantages et les inconvénients de chaque type d'image sont détaillés dans ce paragraphe.

#### 2.1.1. Images satellites Pléiades

##### AVANTAGES

Lorsque des archives de la zone d'étude existent, les images Pléiades sont disponibles gratuitement pour les acteurs publics et de la recherche.

Il s'agit d'images optiques comprenant les bandes du rouge, du vert, du bleu et du proche infrarouge. Ces quatre bandes sont assemblées au sein d'une même image et présentent des résolutions spatiales identiques, ce qui facilite les traitements et leur automatisation. Des produits de résolution spatiale 50cm sont disponibles. Ils sont issus de la combinaison des bandes XS (rouge, vert, bleu et proche infrarouge) de résolution 2.8m et de la bande panchromatique de résolution 0.7m. (IGN 2018)

« L'heure de l'observation des territoires par Pléiades se situe systématiquement en fin de matinée, ce qui contribue à obtenir des couvertures de bonne homogénéité radiométrique. » (IGN 2018)

##### INCONVENIENTS

La disponibilité des données est basée sur celle des archives, il n'est donc pas possible de maîtriser la date d'acquisition et la couverture totale de la zone d'étude. Par exemple, les images Pléiades disponibles en 2016 et 2019 sur le territoire de la CCST ont été acquises en mars et une portion Nord-ouest de la zone d'intérêt n'est pas disponible. En outre, le mois de mars n'est pas le plus pertinent pour la détection de la végétation.

Les satellites Pléiades sont des capteurs agiles, ils peuvent ainsi modifier leur orientation dans l'espace, ce qui permet d'augmenter les possibilités de prises de vue au droit d'une zone d'observation. (Beaumet, Verfaille et Charneau 2007). Cependant cette agilité génère des angles d'acquisition et par conséquent des ombres importantes. Ces dernières peuvent pénaliser le processus de classification. Ce phénomène d'ombre est bien visible sur la Figure 2 ci-après.



Figure 2: Comparaison d'une image Pléiades en date de mars 2019 (à gauche) et d'une image de la BD ORTHO (IGN) de 2019 (à droite) sur une portion du territoire de la CCST.

### 2.1.2. Orthophotographies

#### AVANTAGES

Les orthophotographies de la BD ORTHO sont mises à disposition gratuitement par l'IGN. L'ensemble de la France métropolitaine est disponible.

Deux versions existent, la BD ORTHO avec des images à trois bandes correspondant au Rouge, Vert et Bleu, et la BD ORTHO IRC avec des images à trois bandes correspondant au proche Infra-Rouge, au Rouge et au Vert. La résolution spatiale peut être variable selon qu'il s'agisse de la BD ORTHO ou de la BD ORTHO IRC, et selon les années. Au droit du territoire de la CCST, pour 2019, la première présente une résolution spatiale de 50cm et la seconde de 20cm, inversement pour l'année 2016.

Le phénomène d'ombre est nettement moins important que pour les images Pléiades (Figure 2).

#### INCONVENIENTS

Les campagnes d'acquisition se déroulent généralement sur la période estivale, mais la date de la prise de vue n'est pas précisément connue.

Les campagnes d'acquisition sont réalisées à intervalles de 3 ou 4 ans.

« Contrairement aux images Pléiades, pour une grande surface à couvrir, une prise de vue aérienne nécessitera une plage horaire plus large, ce qui peut conduire à une disparité des ombres portées entre les vues » (IGN 2018). Ce point peut engendrer un léger biais dans la segmentation et le processus de classification. Également, les prises de vue peuvent avoir eu lieu à des dates différentes sur un même territoire. Ce point est particulièrement visible sur les photographies aériennes de 2016 et 2019 au niveau de certains secteurs limitrophes de la CCST, comme illustré sur la Figure 3.

Les orthophotographies ne correspondent pas à de la donnée brute. Il y a une harmonisation colorimétrique et l'information spectrale est condensée sur 8 bits. Ces deux aspects génèrent donc une perte d'information.



Figure 3: Orthophotographies de 2016 (à gauche) et 2019 (à droite) sur un secteur proche des limites de la CCST, mettant en évidence les différences de dates localement importantes dans les prises de vue. Les cultures sur l'extrême sud de la zone sont à un état de croissance différent de la partie supérieure.

### 2.1.3. Données auxiliaires

Des données auxiliaires sont mobilisées afin d'affiner la classification de l'occupation du sol. Il s'agit des bâtiments de la BD TOPO de l'IGN, et plus particulièrement :

- La couche « BATI » de la BD TOPO v3.0 en date de 2020. Après une analyse visuelle, cette version a été préférée à la version v2.0 de 2019, les bâtiments correspondant mieux à ceux observés sur les orthophotographies.
- Les couches « BATI\_INDIFFERENCIE », « BATI\_INDUSTRIEL », « CONSTRUCTION\_LEGERE » de la BD TOPO v2.2 en date de 2018. Il y a deux ans d'écart entre cette version de la BD TOPO et la date des orthophotographies de 2016, mais après une analyse visuelle, la concordance entre les bâtiments de la BD TOPO et ceux observés sur les orthophotographies est satisfaisante.

D'autres couches de bâtiments ont été envisagées :

- La couche « BATIMENT » de la BD PARCELLAIRE (IGN) qui présente l'avantage d'avoir une version par date. De très nombreux bâtiments figurant sur les orthophotographies n'y sont cependant pas référencés. Cette source de données n'a donc pas été retenue.
- La couche « buildings » d'Open Street Map. L'inconvénient majeur est l'incapacité d'obtenir un historique des bâtiments. De fait, cette source de données a été écartée.

## 2.2. Méthodes de classification envisagées

### 2.2.1. Classification supervisée à l'échelle du pixel

Les images de haute résolution permettent une visualisation plus fine de la surface du sol, de mieux détecter les petits objets, mais elles présentent l'inconvénient de détecter également la variabilité des pixels au sein d'un même objet. Par exemple, une surface enherbée pourra contenir des petites portions de végétation moins vigoureuses ou de sol presque nu. Les pixels correspondants auront alors un signal spectral peu caractéristique d'une surface végétalisée. L'approche basée sur la classification des pixels entrainera ainsi un effet « poivre et sel » (Ma, et al. 2016).

Compte tenu de ces éléments, la classification supervisée basée sur le pixel n'a pas été retenue dans les tests méthodologiques.

### 2.2.2. Classification supervisée basée objet

#### a) Présentation et intérêt de la méthode

Les techniques d'analyse d'image basée sur l'objet, dites *OBIA (Object-Based Image Analysis)*, aident à prendre en compte la variabilité spectrale inter-objet liée à la haute résolution spatiale des images et la présence de pixels mixtes au sein d'une même cible (Li et Shao 2013).

La classification supervisée basée sur l'objet se déroule en plusieurs étapes. La première consiste en la segmentation de l'image afin d'en sortir des objets, correspondant aux bâtiments, routes, portions de surfaces enherbées, arbres, etc. Cette première étape est cruciale, car de la bonne délimitation des objets découlera une classification pertinente. Pour chaque type de classification (végétation ou occupation du sol), une série de tests a donc été effectuée afin de déterminer les paramètres de segmentation les plus pertinents. La deuxième étape consiste au calcul des statistiques des variables de classification (indices spectraux, textures, etc.) au sein des objets. Le modèle de classification sera ensuite entraîné à partir de ces statistiques. La troisième étape correspond à l'échantillonnage, et la dernière à la classification à proprement parler. **L'ensemble de ce processus est synthétisé dans les diagrammes de flux en annexes 5 et 6** (processus retenus au terme des tests pour *MEO-Urban Green* et *MEO-Land Cover* respectivement). Plusieurs tests ont été menés sur la phase de classification, avec différents algorithmes et combinaisons de variables.

#### b) Technique de segmentation utilisée

Dans la présente étude, la segmentation a été réalisée à l'aide de la bibliothèque de traitements d'image *OTB (Orfeo ToolBox) v7.2.0*. Parmi les différentes fonctions proposées pour la segmentation, *LargeScaleMeanShift* a été retenue. Cette fonction est adaptée à l'analyse basée objet (CNES 2020). Comme indiqué dans la documentation de cette librairie, quatre sous-étapes y sont incluses :

##### 1) *MEANSHIFTSMOOTHING*

« Cette fonction permet de lisser une image en utilisant l'algorithme *MeanShift*. Il s'agit d'un algorithme itératif de lissage d'image préservant les bords. Il peut être appliqué à des images multi-spectrales. Les pixels moyennés sont à la fois proches dans l'espace et dans les signatures spectrales. Deux paramètres importants sont ainsi à considérer :

- **spatialr** : Rayon du voisinage spatial pour le calcul de la moyenne. Des valeurs plus élevées entraîneront un lissage plus important et un temps de traitement plus élevé.
- **ranger** : Seuil de la distance euclidienne de la signature spectrale (exprimé en unité radiométrique). Des valeurs plus faibles entraîneront un moindre lissage du bruit. Ce paramètre n'a pas d'impact sur le temps de traitement.

*Il est possible que des techniques telles que la transformation de l'espace couleur ou la normalisation de l'image soient à appliquer avant d'utiliser cette fonction* ». Ce cas peut par exemple se présenter lors de la combinaison de bandes d'indices spectraux avec les bandes spectrales. Un paramètre ranger de 20 pourra être pertinent pour les bandes de couleurs, mais pas pour un indice spectral dont les valeurs sont initialement comprises entre -1 et 1. Les valeurs d'indices spectraux devront alors être rééchelonnées.

## 2) *LSMSSEGMENTATION*

*« La fonction produit une image étiquetée où les pixels voisins dont la distance de portée est inférieure au rayon de portée, et la distance spatiale inférieure au rayon spatial seront regroupés dans le même cluster ».*

## 3) *LSMSSMALLREGIONSMERGING*

*« Cette fonction fusionne les segments dont la taille en pixels est inférieure au paramètre **minsize** avec le segment adjacent ayant la radiométrie la plus proche et une taille acceptable ».*

## 4) *LSMSVECTORIZATION*

*« La fonction convertit le résultat en un fichier vectoriel SIG contenant un polygone par segment. Chaque polygone contient des champs supplémentaires : moyenne et variance de chaque bande en entrée, l'étiquette de l'image segmentée, le nombre de pixels dans le polygone ». Ce fichier vecteur sera ensuite directement utilisé pour l'échantillonnage, le calcul de valeurs statistiques complémentaires, etc.*

Cette méthode est complète et les tests effectués avec la fonction *LargeScaleMeanShift* ont donné des résultats de segmentation très satisfaisants. En outre, elle est rapide à prendre en main et facile à mettre en œuvre. De fait, bien que d'autres méthodes de segmentation et d'autres bibliothèques soient disponibles (e.g. bibliothèques Python *RGISLib*, *Scikit Learn*, etc.), aucune autre méthode n'a été testée.

## c) Algorithmes de classification testés

La librairie Python *Scikit Learn* a été mobilisée pour la classification des objets. Ce choix se justifie par la flexibilité qu'elle apporte sur le paramétrage des différents algorithmes, avec notamment des fonctions comme *GridSearchCV* qui permet de tester facilement des plages d'hyperparamètres, *StandardScaler* qui permet de standardiser les variables d'entrée, ou encore *RFECV* qui permet de *« classer des variables de classification avec élimination récursive des caractéristiques et sélection par validation croisée du meilleur nombre de variables »* (Pedregosa, et al. 2011). Plusieurs algorithmes ont été testés, des plus simples au plus complexes, tout d'abord sans affiner le paramétrage afin de faire des premiers choix, puis en testant différentes combinaisons d'hyperparamètres. La Figure 4, issue de la documentation de *Scikit-Learn*, permet de mieux cerner les algorithmes pertinents à tester.

Les algorithmes de type *SVM (Support Vector Machine)*, *K-Neighbors*, *Decision Tree* et *Random Forest* sont des modèles non paramétriques. *« Ils ne supposent pas une distribution gaussienne des échantillons et sont plus efficaces sur des classes complexes, comme en télédétection, ou sur des données non spectrales (les textures par exemple). Les méthodes SVM et RF sont utilisées pour la classification de l'occupation du sol de façon très répandue. »* (Gressin 2014)

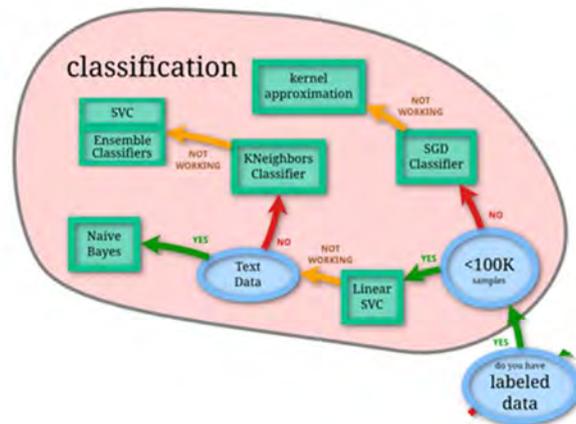


Figure 4: Schéma aidant au choix des estimateurs pour la classification supervisée. Ce schéma est un extrait d'un schéma plus général, issu de la documentation de Scikit-Learn (Pedregosa, et al. 2011).

Au vu de ces éléments, deux algorithmes ont été sélectionnés pour les tests. Ils sont détaillés ci-après.

### 1) SUPPORT VECTOR MACHINE (SVM)

Les algorithmes de type *Support Vector Machine* présentent les avantages suivants (Gressin 2014) :

- « Bonne capacité de généralisation,
- Moins sensibles à l'augmentation du nombre de variables en entrée et à leurs poids respectifs dans la classification,
- Coût calculatoire réduit,
- Performants même sur un nombre réduit d'échantillons ».

Plusieurs types de modèles existent, et en particulier :

- « à noyau linéaire, qui ont des limites de décisions linéaires,
- à noyau non linéaire (dont le noyau *Radial Basis Function*, dit *RBF*), dont les limites de décisions sont plus flexibles ».

« Lors de l'entraînement d'un SVM avec le noyau *Radial Basis Function* (*RBF*), deux paramètres doivent être pris en compte : **C** et **gamma**. Le paramètre **C** permet d'arbitrer entre la mauvaise classification des échantillons d'entraînement et la simplicité de la surface de décision. Un paramètre **C** faible rend la surface de décision lisse, tandis qu'un **C** élevé vise à classer correctement tous les exemples d'apprentissage. **Gamma** définit l'influence d'un seul exemple d'apprentissage. Plus **gamma** est grand, plus les autres exemples doivent être proches pour être affectés. **Le choix de C et de gamma est critique pour la performance du SVM**. En outre, les algorithmes d'apprentissage de type SVM supposent que les variables d'entrée soient centrées autour de 0 et présentent une variance du même ordre ». (Pedregosa, et al. 2011) **Les variables d'entrée doivent donc être standardisées**. La fonction `StandardScaler()` de *Scikit-Learn* a été utilisée.

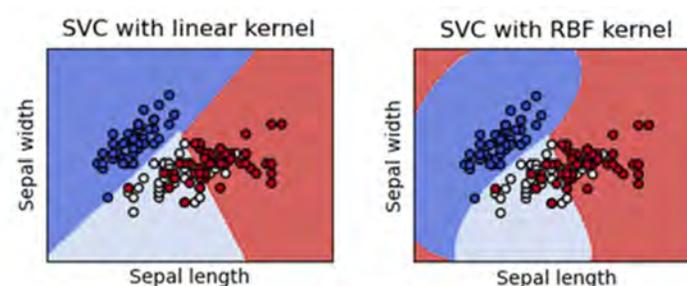


Figure 5: Tracés des fonctions de décisions pour un algorithme de type SVM à noyau linéaire, et SVM à noyau RBF, appliqués à un jeu de données exemples (iris). (Pedregosa, et al. 2011)

## 2) *RANDOM FOREST*

Les algorithmes de type *Random Forest*, qui prennent en compte plusieurs arbres de décisions, sont généralement capables de traiter d'importants jeux de données, avec un grand nombre de dimensions. (Gressin 2014)

De nombreux hyperparamètres permettent de régler le modèle. Plus particulièrement, on retiendra les paramètres suivants (Gautherot 2020) :

- ***n\_estimators*** : contrôle le nombre d'arbres de décision
- ***max\_depth*** : profondeur de l'arbre. Ce paramètre détermine la longueur maximale de l'arbre. Une profondeur importante entrainera un arbre complexe et de fait, un risque de sur-ajustement sur les échantillons d'entraînement.
- ***max\_leaf\_nodes*** : nombre de feuilles de l'arbre de décision. Ce paramètre permet de contrôler la complexité de l'arbre.

L'algorithme *Random Forest* permet d'accéder à l'importance des variables d'entrée dans le processus de classification. Il est ainsi possible de procéder à une sélection des variables selon leur importance. Cette étape permet d'améliorer la performance du modèle. En effet, la présence de variables peu pertinentes peut a contrario dégrader la performance. La fonction *RFECV()* de *Scikit-Learn* a été utilisée pour sélectionner les variables.

### d) Variables d'entrée utilisées

#### BANDES SPECTRALES

Les bandes spectrales du proche infra-rouge, du rouge, du vert et du bleu ont été utilisées pour la segmentation des orthophotographies. Ces quatre bandes n'étant pas regroupées au sein d'une même image et présentant généralement des résolutions différentes, un prétraitement avec un rééchantillonnage et une fusion des orthophotographies IRC avec les bandes du bleu a été menée. Cette étape est intégrée au script général.

La moyenne, la médiane et la variance des valeurs spectrales au sein d'un même objet sont ensuite utilisées pour la classification supervisée.

Un test a été réalisé en intégrant les images Pléiades en données complémentaires dans le processus de classification. Les indices spectraux présentés au paragraphe suivant ont été calculés (NDVI, NDWI, EVI, MSAVI2), puis la moyenne, la médiane et la variance de chaque indice ont été intégrées dans les variables d'entrée.

#### INDICES SPECTRAUX

Quatre indices spectraux ont été sélectionnés : le NDVI, le NDWI, l'EVI et le MSAVI2. Ce choix a été fait en se basant sur les bandes spectrales disponibles et sur les apports de chaque indice.

- NDVI

Il est calculé à partir des bandes du proche Infrarouge (NIR) et du rouge (R) comme suit :

$$\frac{(NIR - R)}{(NIR + R)}$$

Outre la disponibilité des bandes, le choix s'est porté sur cet indice car il est largement utilisé dans le domaine de la télédétection, en particulier pour caractériser la végétation chlorophyllienne. En effet, cette dernière réfléchit fortement le rayonnement dans les longueurs d'ondes du proche infrarouge et absorbe les longueurs d'onde du rouge (Devineau 1990). Il en résulte alors un NDVI plus élevé en présence de végétation.

Le NDVI a été utilisé dans le processus de segmentation préalable à la classification de l'occupation du sol (outil *MEO-Land Cover*), et dans le processus de la classification de la végétation (outil *MEO-Urban Green*) et de l'occupation du sol.

- NDWI

Il est calculé à partir des bandes du proche Infrarouge (NIR) et du vert (V) comme suit :

$$\frac{(NIR - V)}{(NIR + V)}$$

L'indice NDWI est approprié pour détecter les surfaces en eau. Elles présentent en effet une forte absorption et une faible radiance dans les longueurs d'onde situées dans la gamme du rouge à l'infrarouge (Space4Water 2020). Toutefois, cet indice ne supprime pas efficacement le signal issu des surfaces construites et peut ainsi générer une surestimation des surfaces en eau en zone urbaine. L'indice MNDWI pourrait aider à pallier ce problème en réduisant le bruit des terrains bâtis, de la végétation et du sol (Xu 2006). Cependant cet indice est calculé à partir de la longueur d'onde du moyen infrarouge et non du proche infrarouge. Il n'est donc pas applicable sur des images très haute résolution, cette bande n'étant pas incluse.

- EVI

Il est calculé à partir des bandes du proche Infrarouge (NIR), du rouge (R) et du bleu (B) comme suit :

$$2.5 * (NIR - R) / (NIR + 6 * R - 7.5 * B + 1)$$

« L'indice EVI prend entre autres en compte le signal en arrière-plan de végétation. Il est ainsi moins sensible au bruit de fond » (ESRI s.d.). « Le NDVI est sensible à diverses sources d'erreurs et d'incertitudes, notamment en ce qui concerne l'arrière-plan de la canopée. L'EVI a ainsi été proposé pour réduire les effets du sol en arrière-plan » (Matsushita, et al. 2007).

- MSAVI2

Il est calculé à partir des bandes du proche Infrarouge (NIR) et du rouge (R) comme suit :

$$1/2 * (2 * (NIR + 1) - \sqrt{(2 * NIR + 1)^2 - 8 * (NIR - R)})$$

« Cet indice permet de minimiser l'influence du sol nu sur la végétation » (ESRI s.d.). Il peut notamment être intéressant pour distinguer plus facilement les zones avec de la végétation basse éparse et/ou peu vigoureuse des zones de type sol nu ou surface imperméabilisée.

Pour la classification de la végétation en zone urbaine uniquement (*MEO -Urban Green*), la moyenne et la variance des valeurs spectrales au sein d'un même objet sont utilisées pour la classification supervisée. La médiane est également prise en compte pour la classification de l'occupation du sol (*MEO-Land Cover*).

#### INDICES DE TEXTURE

« Il est reconnu que la combinaison de paramètres de textures et de variables spectrales permet d'améliorer la classification de l'occupation du sol » (Huang, Zhang et Li 2007). Dans leur article, Huang et al. utilisent un ensemble de caractéristiques structurelles (*SFS – Structural Feature Set*) basées sur l'extension de lignes de direction en fonction de la similarité spectrale entre un pixel central et les pixels situés le long des différentes lignes de direction. Les longueurs des lignes de direction sont ensuite calculées et six caractéristiques sont alors extraites :

- SFS'Length : maximum des longueurs des lignes de direction ;
- SFS'Width : minimum des longueurs des lignes de direction ;

- SFS'PSI (*Pixel Shape Index*) : moyenne des longueurs des lignes de direction. Elle permet de décrire la structure autour d'un pixel central ;
- SFS'W-Mean : moyenne pondérée par l'écart-type des valeurs spectrales de la ligne de direction. Elle permet de réduire la longueur des lignes de direction instables ;
- SFS'Ratio : ratio *length-width*. Il permet de décrire la forme du contour autour du pixel central ;
- SFS'SD (*Standard Deviation*) : permet de prendre en compte le fait qu'un objet rectiligne (une route par exemple) peut donner lieu aux mêmes valeurs de longueur et de PSI qu'un élément carré (de l'herbe ou un bâtiment par exemple).

Ces indices de texture ont été calculés à partir de l'application *OTB* et de sa fonction *SFSTextureExtraction*. « Il est possible de paramétrer la longueur de la ligne de calcul (*spathre*), et la différence spectrale maximale entre un pixel de la ligne de direction et le pixel central (*spethre*) » (CNES 2020). « Théoriquement, la distance spectrale est fixée à une valeur comprise entre 2.5 et 4.0 fois l'écart-type moyen de la distance euclidienne des données de pixels d'apprentissage par rapport aux moyennes des classes » (Huang, Zhang et Li 2007).

Les textures de l'ensemble des caractéristiques structurelles ont été calculées sur chaque pixel pour la bande du NDVI. Des tests ont été réalisés pour caler les paramètres *spathre* et *spethre*. Ce ne sont finalement pas les valeurs obtenues par la méthode de Huang et al. qui ont été retenues.

De la même manière que pour les indices spectraux, la moyenne et la variance des valeurs spectrales au sein d'un même objet sont ensuite utilisées pour la classification supervisée de la végétation (*MEO-Urban Green*), et la moyenne, la médiane et la variance pour la classification de l'occupation du sol (*MEO-Land Cover*).

#### BATIMENTS

Les couches des bâtiments de la BD TOPO v3.0 de 2020 et de la BD TOPO v2.2 de 2018 ont été rastérisées en affectant une valeur de 2 aux bâtiments et une valeur de 1 sur le reste de l'emprise. Puis une valeur moyenne a été calculée au sein de chaque objet segmentée. Elle est ensuite utilisée pour la classification de l'occupation du sol.

#### e) Gestion des ombres

La présence d'ombres est une problématique récurrente lors des exercices de classification, en particulier sur des images de haute ou très haute résolution. Plusieurs recherches ont été menées afin de solutionner le problème. On citera notamment les travaux de Zhou, et al. (2009), qui ont mené une étude comparative avec différentes méthodes de détection et/ou de restauration des ombres dans les zones urbaines. Trois méthodes sont présentées dans l'article : **(1) La classification (OBIA) des zones ombragées en utilisant l'information spectrale**. Une première segmentation de l'image est réalisée, puis les zones dites « d'ombre » sont extraites à partir d'une valeur de luminosité (*brightness*  $\leq 70$ ). Cette valeur correspond à la moyenne des trois bandes proche infrarouge, rouge et vert au sein d'un même objet (cas de l'utilisation d'une orthophotographie trois bandes, infrarouge, rouge et verte). Les objets ombragés extraits sont alors segmentés plus finement afin « d'atténuer les effets de mélange d'objets en réduisant la variance entre les différents types de surface ombragée ». L'ensemble des objets est ensuite classé à partir du NDVI, de l'information contextuelle (longueur de la limite d'un objet partagée avec les objets voisins) et à partir de la hauteur issue de données LiDAR. **(2) La classification des zones ombragées avec une restauration de l'ombre**. Dans un premier temps, les zones d'ombre sont détectées. Dans un second temps, elles sont restaurées à partir de techniques radiométriques permettant d'obtenir une image dépourvue d'ombres. Enfin, une classification supervisée basée objet est menée. **(3) La classification des zones ombragées à partir de la fusion de données multi-sources**. Dans leur étude, Zhou, et al. (2009) ont utilisé une image de 2009 comme donnée auxiliaire pour aider à la classification des ombres dans l'image de 2004. Finalement, les meilleurs résultats (accord global, Kappa, rappel et précision) de classification des quatre classes

d'occupation du sol de type ombragé (arbre ombragé, herbe ombragée, bâtiment ombragé et chaussée ombragée) sont issus de la méthode 3. Cette méthode améliore significativement les résultats par rapport aux deux autres. Dans leur article, Huang et Zhang (2012) définissent quant à eux la luminosité comme suit  $b(x) = \max_{1 \leq k \leq K} (bande_k(x))$ .

Les méthodes 1 et 3 ont été sélectionnées pour des tests sur une tuile de l'année 2019, dans le cadre de la classification de l'occupation du sol sur le territoire de la présente étude. Pour la méthode 1, les deux luminosités (Zhou, et al. 2009, et Huang et Zhang 2012) ont été testées. Les images servant de données auxiliaires pour l'application de la méthode 3 sont les images Pléiades de mars 2019. L'orthophotographie de 2016 n'a pas été retenue comme donnée auxiliaire pour les raisons suivantes :

- Une classification de l'occupation du sol sera également réalisée sur l'année 2016, ce qui implique la disponibilité d'une orthophotographie antérieure. La BD ORTHO IRC n'est pas disponible gratuitement pour les années antérieures à 2016 ;
- Les changements d'occupation sont localement importants entre 2016 et 2019, ce qui peut entraîner des erreurs de classification.

Les éléments suivants concernant les images Pléiades sont à garder à l'esprit :

- Elles sont affectées par un phénomène d'ombre important ;
- La superposition des bâtiments des images Pléiades sur les bâtiments des orthophotographies n'est pas tout à fait juste ;
- Il manque une portion Nord-ouest du territoire d'étude pour les images de 2016 et 2019 disponibles.

On notera qu'aucune information sur la hauteur suffisamment précise n'est disponible dans notre cas d'étude. Cet élément était une variable d'entrée importante dans l'étude de Zhou, et al. 2009.

## 2.3. Comparaison des méthodes

### 2.3.1. Méthodes de segmentation

La majorité des tests de segmentation a été faite dans le cadre de la classification de la végétation en zone urbaine (outil *MEO-Urban Green*) et sur l'année 2019. Pour rappel, la résolution des orthophotographies de 2019 est de 20cm pour les images fausses couleurs (proche infrarouge, rouge et vert) et 50cm pour les images RVB, ce qui est très élevé. Une telle résolution n'est pas nécessairement utile. Ainsi, des segmentations avec des images rééchantillonnées à 60cm ont également été réalisées. Cette résolution permet un niveau de détails satisfaisant, tout en allégeant les images à traiter.

Des tests complémentaires ont été menés dans le cadre de la classification de l'occupation du sol (outil *MEO-Land Cover*), notamment en vue de s'affranchir des zones d'ombre en appliquant la méthode 1 de Zhou et al. (2009).

#### a) *MEO-Urban Green - Segmentation*

Le tableau 1 présenté en annexe 2 détaille tous les tests effectués. Il en ressort les points suivants :

##### PLEIADES

- Une bonne segmentation des images Pléiades a été obtenue avec les bandes rouge, verte, bleue et proche infrarouge en entrée, *spatialr* égal à 10, *ranger* égal à 160, et *minsize* égal à 25.
- **Les images Pléiades ne seront pas retenues** car les ombres vont pénaliser la classification de façon importante.

## ORTHOPHOTOGRAPHIES

- L'utilisation d'images de résolution spatiale 60cm permet de réduire le temps de calcul de façon importante, à savoir 4min pour un résultat très satisfaisant sur l'image 60cm (Annexe 2 – UG-test 18) contre 10min pour l'image 20cm (Annexe 2 – UG-test 6). La réduction de la taille des fichiers vecteur en sortie est également à considérer, avec 20 109 Ko pour le fichier .shp du test 18, contre 56 805 Ko pour le fichier .shp du test 6. **La résolution spatiale de 60cm a donc été retenue.** En outre, les images à classer par la suite seront moins lourdes.
- Deux segmentations intéressantes ressortent de la série de tests. Elles se basent sur les bandes proche infrarouge, rouge et verte, et les paramètres suivants :
  - 1) UG-test 18 : *spatialr* = 10 ; *ranger* = 20 ; *minsize* = 9
  - 2) UG-test 19 : *spatialr* = 10 ; *ranger* = 15 ; *minsize* = 9

La délimitation des objets est plus fine avec le test 19. Certaines petites zones de végétation basse au sein de zone de végétation haute sont par exemple détectées avec un *ranger* de 15 alors qu'elles ne le sont pas avec un *ranger* de 20. Le contour des haies est également un peu mieux défini. On note toutefois une segmentation plus importante au sein d'une même cible. Les segmentations avec les paramétrages du test 18 (*spatialr* = 10 ; *ranger* = 20 ; *minsize* = 9) et du test 19 (*spatialr* = 10 ; *ranger* = 15 ; *minsize* = 9) ont été retenues pour effectuer tous les tests sur les algorithmes de classification.



Figure 6: Comparaison des segmentations pour l'image Pléiades (v03), à gauche, et de l'orthophotographie (v18), à droite, sur une portion du territoire de la CCST. Les images sont en fausses couleurs (proche infrarouge, rouge et vert).

### b) MEO-Land Cover – Segmentation

De nombreux tests de segmentation ont été menés lors de l'étude sur la classification de la végétation en milieu urbain. Les résultats ont servi d'appui pour *MEO-Land Cover*. Des tests complémentaires ont été réalisés, notamment afin de tenter une classification des zones d'ombres. Ils sont synthétisés dans le tableau 2 en annexe 2. Les segmentations sont toutes basées sur les orthophotographies, aucun test n'a été réalisé avec les images Pléiades du fait de l'analyse réalisée sur *MEO-Urban Green*. Afin de tenter d'appliquer la méthode 1 de Zhou et al. (2009), lors de certains tests, les zones d'ombres ont été extraites à partir d'un seuil de luminosité, puis resegmentées. Les objets extraits incluent bien entendu une certaine proportion d'objets de type bâtiment, surface en eau, végétation, etc.

Finalement, plusieurs paramétrages intéressants ont été retenus pour les tests de classification (cf. Tableau 1).

Tableau 1 : Paramètres de segmentation retenus en vue de la classification de l'occupation du sol (MEO-Land Cover)

N° test	Année	N° tuile	Bandes	Paramètres généraux	Seuil luminosité	Paramètres ombres
LC-test 4 A	2019	0555-6280 (rés. 60cm)	IR, R, V	spatialr = 10 ranger = 20 minsize = 9	< 100 (formule de Huang et Zhang 2012)	spatialr = 5 ranger = 5 minsize = 9
LC-test 7	2019	0555-6280 (rés. 60cm)	IR, R, V, B	spatialr = 10 ranger = 25 minsize = 9	-	-
LC-test 10	2016	0550-6285 (rés. 60cm)	IR, R, V, B, NDVI rééchélonné de 0 à 510	spatialr = 10 ranger = 25 minsize = 9	-	-
LC-test 11	2019	0550-6285 (rés. 60cm)	IR, R, V, B, NDVI rééchélonné de 0 à 510	spatialr = 10 ranger = 25 minsize = 9	-	-

### 2.3.2. Méthodes de classification supervisée basée objet (OBIA)

#### a) MEO-Urban Green – Végétation en zone urbaine

Les tests de classification ont été conduits sur les orthophotographies.

Les classes définies sont les suivantes :

- 1) Autre
- 2) Végétation basse
- 3) Végétation haute
- 4) Ombre

Les premiers tests de classification dite *OBIA* ont été réalisés avec les segments issus de la segmentation v18 et avec les segments issus de la segmentation v19. Un test a été mené avec l'algorithme *SVM* à noyau linéaire. Le résultat n'étant pas intéressant, il a été écarté dès ce premier test. Seuls les algorithmes *Random Forest* et *SVM* à noyau *RBF* ont été retenus pour la suite. Les tests avec les bandes de textures issues de différents paramétrages ont été réalisés sur la segmentation v18, avec l'algorithme *SVM* plus rapide que l'algorithme *Random Forest*. Les temps de calcul comparés correspondent uniquement aux temps de calcul pour la phase d'évaluation de la qualité, à savoir la répétition de 30 entraînements/classifications, avec à chaque itération une estimation des meilleures combinaisons d'hyperparamètres. Le temps de préparation des données et en particulier le temps de calcul des statistiques zonales pour chaque bande (calcul sur QGIS) ne sont pas inclus. Ce point est cependant non négligeable.

L'ensemble des tests est synthétisé dans le tableau 1 en annexe 3. Après analyse de ce tableau, on retiendra les points suivants :

- D'une manière générale, les qualités obtenues sont meilleures sur la segmentation issue du paramétrage 18 (*spatialr* = 10 ; *ranger* = 20 ; *minsize* = 9), et la classification de la classe 2 (végétation basse) est plus pertinente,
- Les indices de qualité sont meilleurs pour l'algorithme *SVM* à noyau *RBF* que pour l'algorithme *Random Forest*,
- Les temps de calcul sont nettement plus faibles avec l'algorithme *SVM* à noyau *RBF* qu'avec *Random Forest*,
- Une présélection des variables d'entrée a un impact favorable sur la qualité de la classification lors de l'utilisation de l'algorithme *Random Forest*. Ce point a été évoqué au paragraphe 2.2.2.c) et confirmé au cours des tests.

À la lumière de ces éléments, la classification de la végétation au sein de la tache urbaine de la CCST sera réalisée sur une **segmentation** effectuée avec la fonction **LargeScaleMeanShift (librairie OTB)** et les paramètres **spatialr, ranger et minsize respectivement égaux à 10, 20 et 9**. La **classification** sera ensuite menée **avec un algorithme SVM à noyau RBF** et des variables d'entrée standardisées. Deux classifications seront finalement réalisées, la première comprenant les moyennes et variances des bandes du proche infrarouge, du rouge, du vert et du NDVI, et la seconde comprenant en plus les moyennes et variances des six bandes de texture. Il a été choisi de réaliser ces deux classifications car le calcul des textures puis le calcul de leurs statistiques zonales sont très coûteux en temps. Si les résultats sont proches, le choix d'un modèle avec uniquement les bandes du proche infrarouge, du rouge, du vert et du NDVI peut être tout à fait pertinent. Les méthodes retenues sont synthétisées dans le Tableau 2.

Tableau 2 : Méthodes de classification retenues pour la classification de la végétation en zone urbaine (MEO-Urban Green)

DONNEES	Orthophotographies			
RESOLUTION	Image IRC : résolution initiale 20 cm, résolution utilisée 60cm			
Algorithme	Variables de classification	Hyperparamètres	Évaluation de la qualité	Temps de calcul
SEGMENTS ISSUS DU PARAMETRAGE SUIVANT : SPATIALR = 10 ; RANGER = 20 ; MINSIZE = 9				
<b>SVM noyau RBF</b>	Moyenne et variance des bandes de l'infrarouge, du rouge, du vert et du NDVI ⇒ <b>variables standardisées</b>	C : np.logspace(-3, 3, 7) gamma : np.logspace(-5, 5, 11)	<b>Accord global = 84.9 +/- 4.2 %</b> F1 score (1) ≈ 85 % F1 score (2) ≈ 85 % F1 score (3) ≈ 84 % F1 score (4) ≈ 85 %	27.9 s
<b>SVM noyau RBF</b>	Moyenne et variance des bandes de l'infrarouge, du rouge, du vert, du NDVI, et des 6 bandes de texture du NDVI ⇒ <b>variables standardisées</b>	C : np.logspace(-3, 3, 7) gamma : np.logspace(-5, 5, 11)	<b>Accord global = 85.8 +/- 3.5 %</b> F1 score (1) ≈ 84 % F1 score (2) ≈ 83 % F1 score (3) ≈ 86 % F1 score (4) ≈ 88 %	39min 27s

#### b) MEO-Land Cover – Occupation du sol en zone urbaine

Les classes définies pour la classification de l'occupation du sol sont les suivantes :

##### Classification des zones d'ombre

- 11 – Bâti
- 12 – Bâti ombragé
- 21 – Surface imperméabilisée
- 22 – Surface imperméabilisée ombragée
- 31 – Sol nu
- 41 – Végétation haute
- 42 – Végétation haute ombragée
- 51 – Végétation basse
- 52 – Végétation basse ombragée
- 61 – Surface en eau
- 71 - Piscine

##### Avec une classe ombre générale

- 11 – Bâti
- 21 – Surface imperméabilisée
- 31 – Sol nu
- 41 – Végétation haute
- 51 – Végétation basse
- 61 – Surface en eau
- 71 – Piscine
- 81 – Ombre

Les sols nus, les surfaces en eau et les piscines n'ont pas été scindées en non ombragé/ombragé soit du fait d'un faible nombre d'objets, ou d'un faible nombre d'objets ombragés.

Deux algorithmes différents ont été appliqués *SVM* à noyau *RBF* et *Random Forest*. Différentes combinaisons de variables d'entrée ont été testées. Compte-tenu de leur nombre important, une sélection de variables a généralement été appliquée (fonction *RFECV()* de *Scikit-Learn*), y compris lors de l'utilisation d'un algorithme *SVM*. L'ensemble des tests est synthétisé dans le tableau 2 en annexe 3. On retiendra les éléments suivants :

- Seule la classe 71 (piscine) est constamment bien classée au cours des tests, avec un score F1 toujours supérieur à 90 % ;
- La classification des zones ombres est délicate, les confusions sont importantes. Les plus remarquables sont entre les classes 11-21-31, 12-22, 42-52, 12-61 et 41-51 ;
- Les résultats étant très médiocres, un seul test a été réalisé avec un algorithme *Random Forest* ;
- La sélection des variables permet une nette amélioration des résultats (+ 3 points environ) ;
- Le passage à 7 classes (objets non ombragés/ombragés assemblés au sein d'une même classe) améliore légèrement les résultats de la classification, mais ils restent peu satisfaisants avec un accord global de 74.0 +/- 2.7 %.
- L'ajout de la couche « BATI » de la BD TOPO tel que mentionné au paragraphe 2.2.2.d) permet une très nette amélioration des résultats (+ 6 ou 7 points) ;
- D'une manière générale, on note une confusion importante entre les classes 11, 21, et 31 du fait de leurs signature spectrale souvent similaire ;
- La classification des surfaces en eau est souvent délicate. Des zones d'ombres, des surfaces imperméabilisées sont régulièrement classées en tant que surface en eau. Sur cette classe 61, les meilleurs résultats sont obtenus lorsque les moyennes, médianes et variances de la bande rouge et des 4 indices de végétation des images Pléiades de mars 2019 sont ajoutées en variables d'entrée ;
- Les variables issues images Pléiades permettent d'améliorer légèrement les résultats de la classification, mais hormis pour les surfaces en eau, l'amélioration n'est pas significative. La disponibilité de cette donnée étant soumise à incertitudes selon la zone géographique, les dates d'acquisition disponibles pouvant être changeantes, et compte tenu de leur apport limité, ces variables d'entrée ne seront pas retenues dans la méthode finale ;
- De bons résultats ont été obtenus lors des tests avec 7 classes (11, 21, 31, 41, 51, 61, 71) sur l'année 2019, permettant une classification des zones d'ombre en tant que bâtiment, végétation, etc. avec un accord global pouvant aller jusqu'à 88.7 +/- 2.4 %. En revanche, le phénomène d'ombre s'est avéré nettement plus important sur l'image de 2016 et une segmentation pertinente des ombres en vue de leur affectation dans des classes spécifiques (bâti, végétation, etc.) n'a pas été obtenue. Ainsi, pour homogénéiser la méthode de classification entre les deux années, une huitième classe (81 – ombre) a été créée, de la même manière que pour l'outil *MEO-Urban Green*.

Les méthodes retenues pour la classification de l'occupation du sol sont synthétisées dans le Tableau 3.

Tableau 3 : Méthodes de classification retenues pour la classification de l'occupation du sol en zone urbaine (MEO-Land Cover)

DONNEES	Orthophotographies	
RESOLUTION	Résolution utilisée 60cm	
SEGMENTS ISSUS DU PARAMETRAGE SUIVANT : SPATIALR = 10 ; RANGER = 25 ; MINSIZE = 9		
Algorithmes	SVM noyau RBF,	
Variables de classification	Moyenne, médiane et variance des bandes : <ul style="list-style-type: none"> <li>- IR, R, V, B,</li> <li>- NDVI, NDWI, MSAVI2, EVI,</li> <li>- 6 bandes de textures SFS</li> </ul> Luminosité : formule de Huang et Zhang (2012) Moyenne de la couche « BATI » de la BD TOPO (cf. § 2.2.2.d)) Paramètres de calcul des SFS'Textures : <i>spathre</i> = 5 ; <i>spethre</i> = 0.05 Variables standardisées et sélectionnées à l'aide de la fonction <i>RFECV()</i> de <i>Scikit-Learn</i>	
Hyperparamètres	C : np.logspace(0, 8, 9) gamma : np.logspace(-8, 0, 9)	
Évaluation de la qualité	<b>2016</b> Accord global = 87.3 +/- 2.3 % F1 score (11) ≈ 94 % ; F1 score (21) ≈ 90 % F1 score (31) ≈ 90 % ; F1 score (41) ≈ 90 % F1 score (51) ≈ 90 % ; F1 score (61) ≈ 90 % F1 score (71) ≈ 90 % ; F1 score (81) ≈ 90 %	<b>2019</b> Accord global = 85.3 +/- 3.7 % F1 score (11) ≈ 94 % ; F1 score (21) ≈ 90 % F1 score (31) ≈ 90 % ; F1 score (41) ≈ 90 % F1 score (51) ≈ 90 % ; F1 score (61) ≈ 90 % F1 score (71) ≈ 90 % ; F1 score (81) ≈ 90 %

## 2.4. Application au territoire de la Communauté de Communes de la Save au Touch

### 2.4.1. Extraction de la tache urbaine

#### a) Méthode

Au préalable, le contour de la CCST a été extrait à partir de la couche « EPCI » de la base de données ADMIN-EXPRESS-COG v2.1 2020 de l'IGN, le champ « NOM\_EPCI » étant « CC de la Save au Touch ». La tache urbaine a ensuite été obtenue à partir de la couche « BATI » de la BD TOPO 2019 (IGN) et de la couche « Parcelles » de la BD PARCELLAIRE 2018 (IGN).

Une zone tampon de 100m a tout d'abord été réalisée autour des bâtiments à usage industriel et autour des centroïdes des autres types de bâtiments, et les objets ainsi obtenus ont été regroupés. Un buffer négatif de 100m a ensuite été généré et les objets d'une surface inférieure à 1 hectare ont été supprimés afin de limiter l'effet de mitage. Une zone tampon de 30m a enfin été appliquée sur les éléments conservés. Une première tache urbaine en a découlé. Cette tache urbaine provisoire a été étendue à l'échelle de la parcelle en extrayant les parcelles dont les centroïdes intersectent la tache. Une zone tampon de 30m a été appliquée et les objets ont ensuite été regroupés. Enfin les trous se trouvant au sein de la tache urbaine et dont la surface était inférieure à 1 hectare ont été supprimés. **L'ensemble de la démarche est synthétisé dans le diagramme de flux présenté en annexe 4.**

## b) Résultat

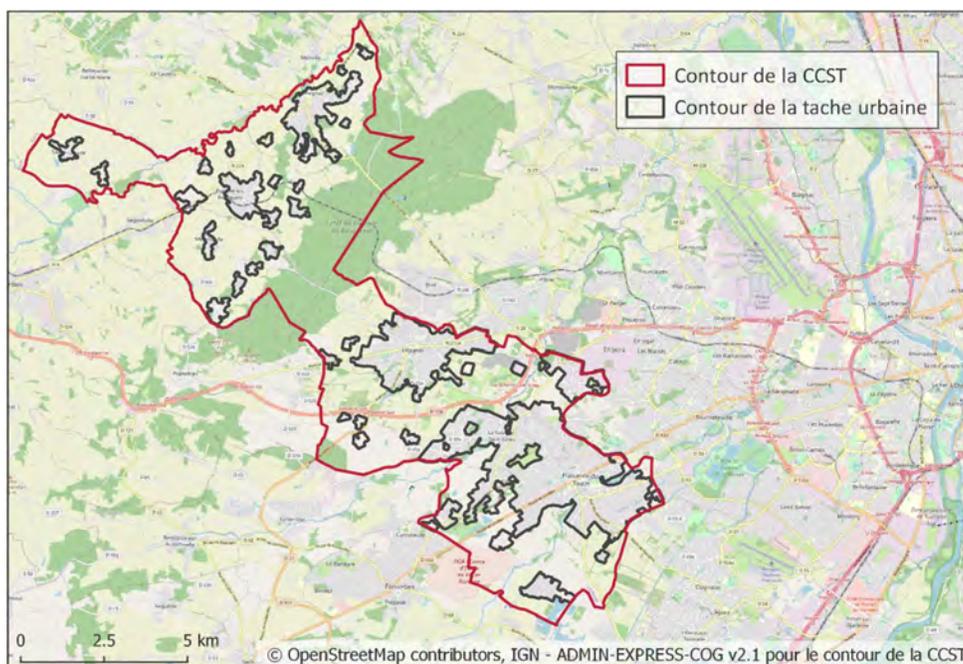


Figure 7: Carte présentant le contour de la tache urbaine de la CCST.

### 2.4.2. Application des méthodes de segmentation et classifications retenues

#### a) Segmentation

Pour rappel, les paramètres retenus pour la segmentation avec la fonction *LargeScaleMeanShift* de la librairie *OTB* sont les suivants :

MEO-Urban Green (année 2019)			MEO-Land Cover (années 2016 et 2019)		
spatialr = 10	ranger = 20	minsize = 9	spatialr = 10	ranger = 25	minsize = 9

#### b) Échantillonnage

##### MEO-URBAN GREEN

Les classes échantillonnées sont les suivantes :

- 1) Autre (sols nus, bâtiments, routes, surfaces en eau, etc.)
- 2) Végétation basse
- 3) Végétation haute
- 4) Ombre

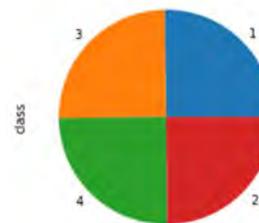


Figure 8 : Répartition de l'échantillonnage entre les classes (outil MEO-Urban Green ; année 2019)

Les **1280 échantillons** ont été sélectionnés de sorte à obtenir une répartition homogène entre les classes (Figure 8). L'échantillonnage a été vérifié en comparant les histogrammes de répartition des moyennes et variances des échantillons avec ceux des objets segmentés. Cette comparaison permet de s'assurer que toutes les gammes de valeurs sont couvertes par les échantillons. Quelques histogrammes sont présentés sur la Figure 9 et la Figure 10.

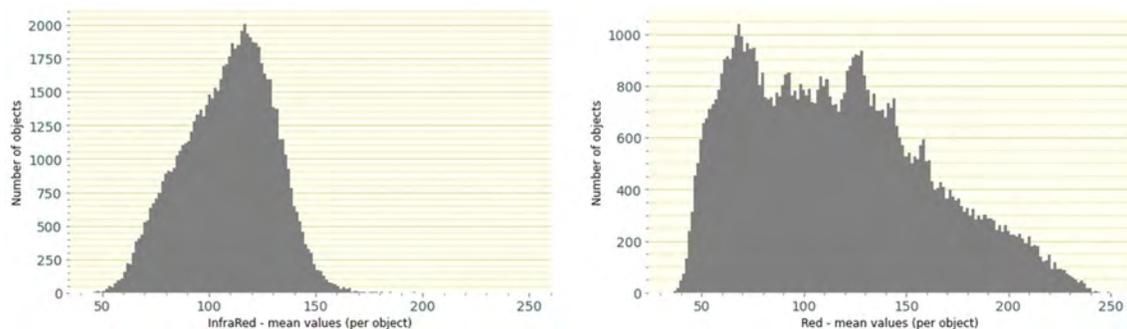


Figure 9: Exemples d'histogrammes de répartition - Moyennes des bandes du proche infrarouge et du rouge pour l'ensemble des objets segmentés (MEO-Urban Green ; année 2019).

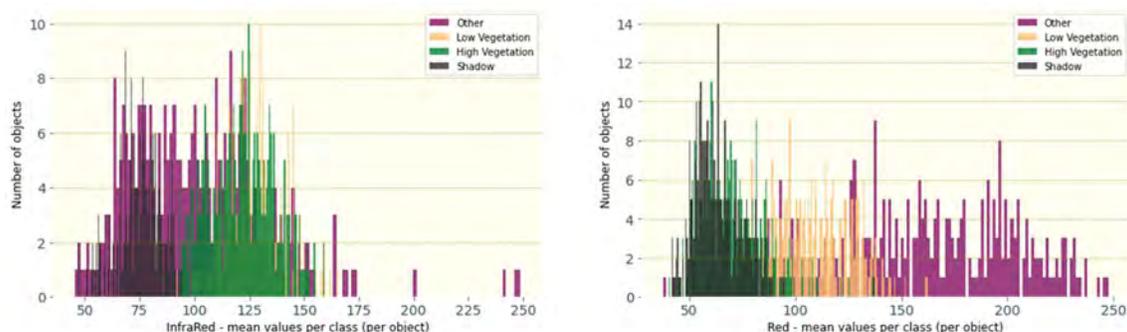


Figure 10: Exemples d'histogrammes de répartition - Moyennes des bandes du proche infrarouge et du rouge pour les échantillons (MEO-Urban Green ; année 2019).

### MEO-LAND COVER

Les classes échantillonnées sont les suivantes :

- 1) 11 – Bâtiment
- 2) 21 – Surface imperméable
- 3) 31 – Sol nu
- 4) 41 – Végétation haute
- 5) 51 – Végétation basse
- 6) 61 – Surface en eau
- 7) 71 – Piscine
- 8) 81 – Ombre

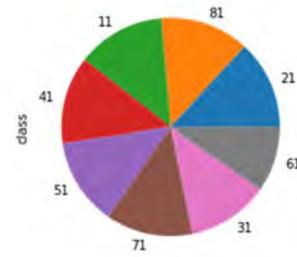


Figure 11: Répartition de l'échantillonnage entre les classes (outil MEO-Land Cover; année 2019)

De la même manière que pour la classification de la végétation (MEO-Urban Green), les échantillons ont été sélectionnés de sorte à obtenir une répartition homogène entre les classes (Figure 11) et couvrir toutes les gammes de valeurs des moyennes, variances et médianes. L'échantillonnage est toutefois un peu déséquilibré pour la classe 61, correspondant aux surfaces en eau. Leur présence est en effet assez limitée sur le territoire d'étude. 984 objets ont été échantillonnés sur l'ensemble de la tache urbaine pour l'année 2016, 1304 pour l'année 2019.

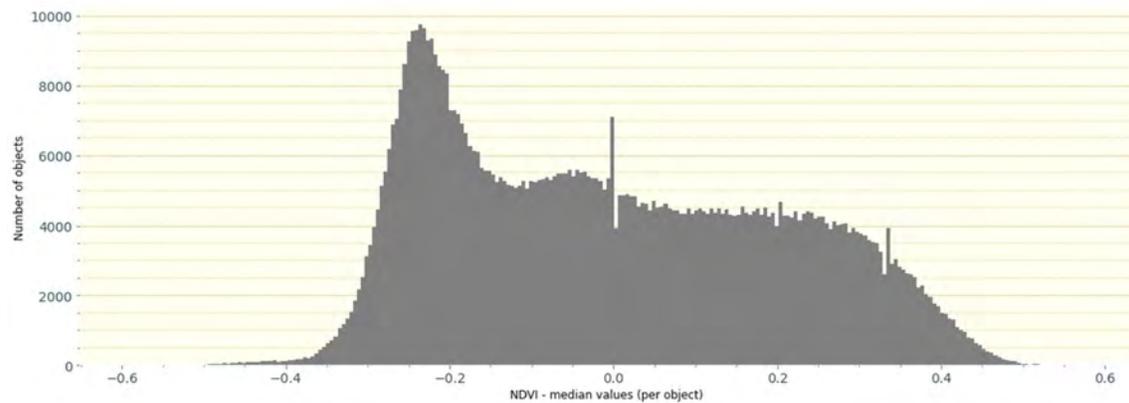


Figure 12: Exemples d'histogrammes de répartition – Médianes de l'indice spectral NDVI pour l'ensemble des objets segmentés (MEO-Land Cover ; année 2019).

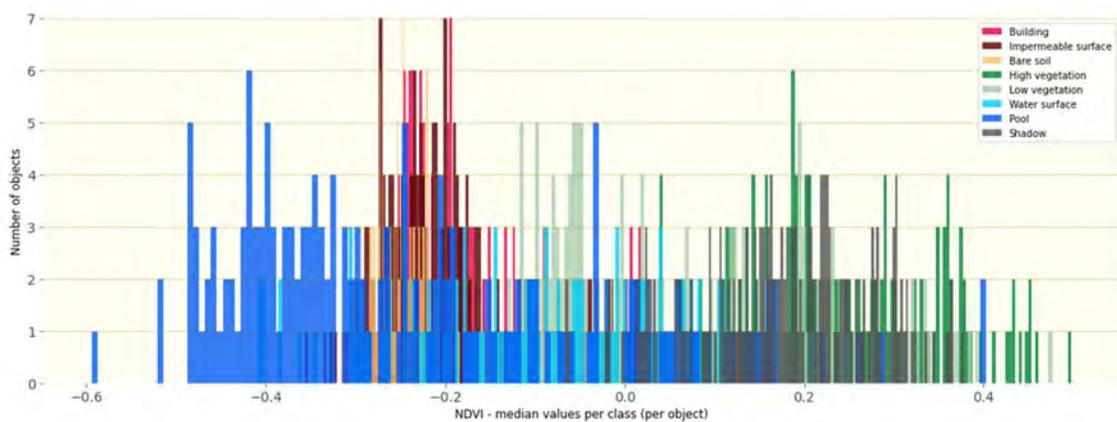


Figure 13 : Exemples d'histogrammes de répartition – Médianes de l'indice spectral NDVI pour les échantillons (MEO-Land Cover ; année 2019).

### c) Classification

L'algorithme de classification est un algorithme de type *Support Vector Machine (SVM)* à noyau *RBF*. Les variables en entrée ont été standardisées (fonction *StandardScaler* de *Scikit-Learn*), puis la qualité du modèle a été estimée en entraînant 30 fois le modèle sur les échantillons séparés aléatoirement en échantillons d'entraînement ( $2/3$ ) et de validation ( $1/3$ ). À chaque itération, la meilleure combinaison d'hyperparamètres est recherchée à l'aide de la fonction *GridSearchCV* de *Scikit-Learn*. Le paramètre *cv* de cette fonction a été fixé à 10, ce qui implique une validation croisée avec une division des échantillons en 10 jeux d'entraînement/validation pour lesquels le pourcentage d'échantillons par classe est préservé. À chaque itération, l'ensemble des gammes de valeurs fournies pour les hyperparamètres est testé. Enfin le modèle a été entraîné sur l'ensemble des échantillons, toujours en cherchant la meilleure combinaison d'hyperparamètres, et l'ensemble des objets segmentés a été classé à partir de ce modèle entraîné. Deux combinaisons de variables d'entrée ont été testées pour la classification de la végétation et pour la classification de l'occupation du sol :

#### MEO-URBAN GREEN

- 1) Moyennes et variances des bandes de l'infrarouge, du rouge, du vert et du NDVI ;
- 2) Moyennes et variances des bandes de l'infrarouge, du rouge, du vert, du NDVI et des textures dites *SFS (Structural Feature Set)*.

## MEO-LAND COVER

### 1) Moyennes, médianes et variances des bandes suivantes :

- infrarouge, rouge, vert, bleu ;
- NDVI, NDWI, EVI, MSAVI2 ;
- SFS'Textures – length, width, PSI, W-mean, ratio, SD ;

Luminosité, correspondant pour rappel au maximum entre la moyenne des bandes de l'infrarouge, du rouge et du vert au sein d'un objet. Formule de Huang et Zhang 2012 ;

### 2) Moyennes, médianes et variances des bandes suivantes :

- infrarouge, rouge, vert, bleu ;
- NDVI, NDWI, EVI, MSAVI2 ;
- SFS'Textures – length, width, PSI, W-mean, ratio, SD ;

Luminosité, correspondant pour rappel au maximum entre la moyenne des bandes de l'infrarouge, du rouge et du vert au sein d'un objet. Formule de Huang et Zhang 2012 ;

Moyennes de la bande correspondant à la couche « BATI » de la BD TOPO (valeurs entre 1 et 2).

Compte-tenu du nombre important de variables d'entrée pour la classification de l'occupation du sol, bien que l'algorithme de type SVM soit relativement peu sensible à l'augmentation du nombre de variables en entrée et à leurs poids respectifs dans la classification (cf. c)2.2.2.c)1)), une sélection de variables a été menée au préalable à l'aide de la fonction *RFECV()* de *Scikit Learn*. La combinaison de variables 1 a été privilégiée afin de mettre en évidence les effets notables de la variable issue de la BD TOPO.

## 2.4.3. Résultats de la classification de la végétation sur le territoire de la CCST

### a) Avec les informations des bandes du proche infrarouge, du rouge, du vert et du NDVI

Ce paragraphe 2.4.3.a) présente les résultats de la classification de la végétation au sein de la tache urbaine à partir des moyennes et variances des bandes du proche infrarouge, du rouge, du vert et du NDVI calculées sur les objets segmentés. L'accord global obtenu est de **93.0 +/- 0.9 %** (Figure 15). Les scores F1, qui correspondent à une combinaison de la précision et du rappel, sont un peu plus faibles pour les classes 2 (végétation basse) et 3 (végétation haute), avec des valeurs de l'ordre de 91 %. Les **confusions les plus importantes sont entre la végétation basse et la végétation haute**. Par exemple, sur une moyenne de 109.4 objets classés en végétation basse, 98.3 sont effectivement des objets de type végétation basse et 8.1 objets sont en fait de type végétation haute (Figure 14).

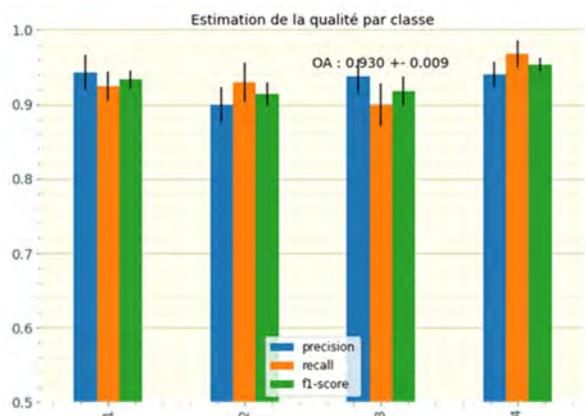


Figure 15 : Modèle 4 bandes (IR, R, V, NDVI) – Estimation de la qualité moyenne par classe. Les correspondances des classes sont les suivantes : 1-Autre, 2-Végétation basse, 3-Végétation haute, 4-Ombre

Benchmark data	Classification				Recall	F1
	1	2	3	4		
1	98.8	3.0	0.5	4.7	92	93
2	2.0	98.3	5.5	0.0	92	91
3	1.3	8.1	97.3	1.6	89	91
4	2.8	0.0	0.5	98.8	96	95
Precision	94	89	93	94		

Figure 14 : Modèle 4 bandes (IR, R, V, NDVI) – Matrice de confusion moyenne de classification. La précision, le rappel et le score F1 sont exprimés en pourcentage. Les valeurs de classe correspondent à un nombre moyen d'échantillons. Les correspondances des classes sont les suivantes : 1-Autre, 2-Végétation basse, 3-Végétation haute, 4-Ombre.



Figure 16: Comparaison d’extraits de l’ortho-image vraies couleurs de 2019 (IGN) et du résultat de la classification selon le modèle 4 bandes (proche infrarouge, rouge, vert et NDVI).

b) Ajout des informations issues des bandes de textures calculées à partir du NDVI

L’ajout des bandes de texture de type **SFS (Structural Feature Set)** a permis d’améliorer la qualité de la classification. Cet ajout entraîne cependant un coût plus important en termes de ressources informatiques. L’accord global obtenu est de **94.8 +/- 0.9 %** (Figure 18). La qualité globale du modèle a été améliorée de 1.8 point avec l’apport des textures SFS, et les scores F1 ont été améliorés de 2 points sur la végétation basse et la végétation haute (93% contre 91% sans les textures). Les **confusions les plus importantes** sont toujours entre les objets de type végétation basse et les objets de type végétation haute (cf. Figure 17 Erreur ! Source du renvoi introuvable.).

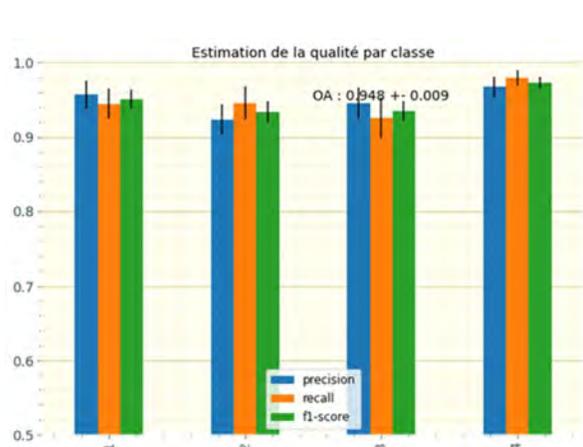


Figure 18 : Modèle 10 bandes (IR, R, V, NDVI et SFS’Texture) – Estimation de la qualité moyenne par classe. Les correspondances des classes sont les suivantes : 1-Autre, 2-Végétation basse, 3-Végétation haute, 4-Ombre.

		Classification				Recall	F1
		1	2	3	4		
Benchmark data	1	102.8	2.6	1.1	2.4	94	95
	2	1.8	97.0	3.8	0.0	94	93
	3	1.3	5.4	97.8	1.2	92	93
	4	1.5	0.0	0.8	103.5	97	97
Precision		95	92	94	96		

Figure 17 : Modèle 10 bandes (IR, R, V, NDVI et SFS’Texture) – Matrice de confusion moyenne de classification. La précision, le rappel et le score F1 sont exprimés en pourcentage, tandis que les valeurs de classe correspondent à un nombre moyen d’échantillons. Les correspondances des classes sont les suivantes : 1-Autre, 2-Végétation basse, 3-Végétation haute, 4-Ombre.



Figure 19: Comparaison d'extraits de l'ortho-image vraies couleurs de 2019 (IGN) et du résultat de la classification de la végétation selon le modèle 10 bandes (proche infrarouge, rouge, vert, NDVI et SFS'Texture).

#### 2.4.4. Résultats de la classification de l'occupation du sol sur le territoire de la CCST

##### a) Sans données auxiliaires

Les résultats de classification de l'occupation du sol sans la couche « BATI » de la BD TOPO étant de qualité médiocre, seule l'année 2019 a été classée de la sorte. Il en ressort un **accord global de 83.8 +/- 1.6 %** (Figure 20). Les résultats sont très hétérogènes, avec notamment les classes 11 et 21 (bâtiment et surface imperméable) qui présentent toutes deux une précision et un rappel nettement plus faibles que les autres classes. Les scores F1 sont de 74 % pour les bâtiments et 68 % pour les sols imperméables. Les confusions les plus importantes sont entre les classes 11 (bâtiments), 21 (sols imperméables) et 31 (sols nus), puis entre les végétations haute (41) et basse (51). Enfin, la matrice de confusion présentée à la Figure 21 met en évidence des erreurs de commission significatives en surfaces en eau (61) et ombres (81). Celles de la classe 61 sont particulièrement remarquables sur l'image classée avec des surfaces en eau au milieu de routes, sur des portions de toit, etc. La Figure 22 illustre bien ce point.

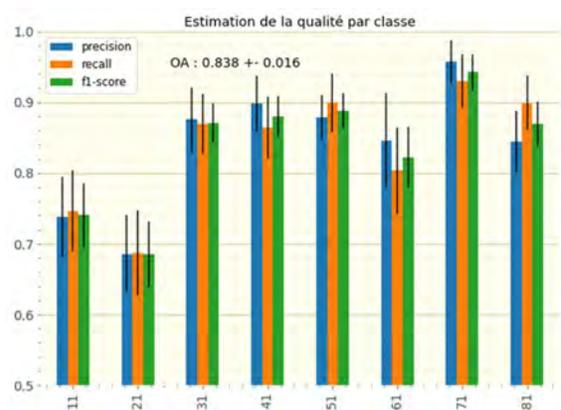


Figure 20 : Modèle 27 bandes, sans données auxiliaires (couche « BATI » de la BD TOPO) – Estimation de la qualité moyenne par classe pour l'année 2019. Les correspondances des classes sont les suivantes : 11-Bâtiment, 21-Surface imperméable, 31-Sol nu, 41-Végétation haute, 51-Végétation basse, 61-Surface en eau, 71-Piscine, 81-Ombre.

		Classification								Recall		F1	
		11	21	31	41	51	61	71	81				
Benchmark data	11	41.4	8.2	2.8	0.0	0.7	1.0	0.4	1.0	74	74		
	21	9.4	38.6	2.5	0.0	0.2	1.4	1.0	2.9	68	68		
	31	2.4	3.5	44.7	0.0	0.6	0.1	0.0	0.2	86	86		
	41	0.2	0.2	0.0	48.9	5.3	0.1	0.0	1.8	86	88		
	51	0.5	0.2	0.6	3.2	49.7	0.0	0.0	1.0	89	88		
	61	1.1	3.5	0.5	0.0	0.0	34.7	1.0	2.3	80	82		
	71	0.6	1.0	0.0	0.0	0.1	1.8	51.7	0.4	92	94		
	81	0.4	1.1	0.0	2.2	0.0	2.1	0.0	51.5	89	86		
Precision		73	68	87	89	87	84	95	84				

Figure 21 : Modèle 27 bandes, sans données auxiliaires (couche BATI de la BD TOPO) – Matrice de confusion moyenne de classification. La précision, le rappel et le score F1 sont exprimés en pourcentage, tandis que les valeurs de classe correspondent à un nombre moyen d'échantillons. Les correspondances des classes sont les suivantes : 11-Bâtiment, 21-Surface imperméable, 31-Sol nu, 41-Végétation haute, 51-Végétation basse, 61-Surface en eau, 71-Piscine, 81-Ombre.



Figure 22 : Comparaison d'extraits de l'ortho-image vraies couleurs de 2019 (IGN) et du résultat de la classification de l'occupation du sol selon le modèle 27 bandes ne comprenant pas la couche BATI de la BD TOPO de l'IGN – Zone en construction.

#### b) Avec données auxiliaires (couche *BATI* de la BD TOPO)

Ce paragraphe 2.4.4.b) présente les résultats des classifications de l'occupation du sol au sein de la tache urbaine à partir de la deuxième combinaison de variables d'entrée détaillée au paragraphe 2.4.2.c).

Pour l'année 2016, l'accord global obtenu est de **92.4 +/- 1.4 %** (Figure 23). 35 des 44 variables d'entrée ont été conservées. Les scores F1 se situent dans une gamme de valeurs comprises entre 83 et 97%. Le score F1 est significativement plus faible pour la classe 21 correspondant aux surfaces imperméables, avec une valeur de 83%. Les classes présentant les meilleurs résultats sont les classes 71 (piscine) et 81 (zones d'ombre) avec des scores F1 respectifs de 97 et 96 %. Les confusions les plus importantes sont entre les classes 11 (bâtiment) et 21 (surface imperméable), 21 et 31 (sol nu), et enfin 41 (végétation haute) et 51 (végétation basse).

La classification de l'occupation du sol en **2019** est moins bonne, avec un **accord global de 87.7 +/- 1.4 %** (Figure 23). D'une manière générale la classification est moins performante sur toutes les classes. Encore une fois, la classe 21 est la moins bien classée avec un score F1 de 76 %. Sur la classe ombre (81), on note une forte baisse de la précision, et dans une moindre mesure du rappel. L'utilisation de la couche « BATI » de la BD TOPO permet une nette amélioration du résultat global, du résultat sur la classe 11 (bâtiment) évidemment, mais aussi sur les classes 21, 31 et 61. La Figure 22 et la Figure 26 illustrent bien ces éléments.

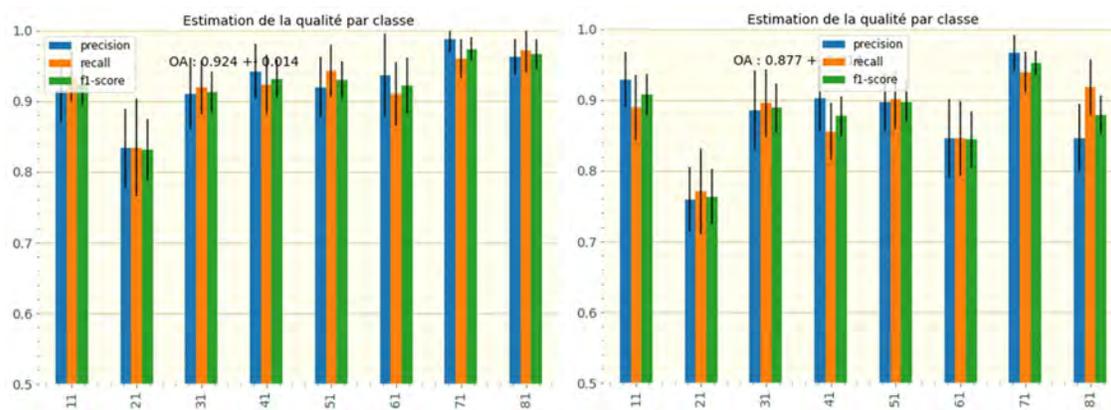


Figure 23 : Classifications avec données auxiliaires (couche « BATI » de la BD TOPO) – Estimations de la qualité moyenne par classe. Les correspondances des classes sont les suivantes : 11-Bâtiment, 21-Surface imperméable, 31-Sol nu, 41-Végétation haute, 51-Végétation basse, 61-Surface en eau, 71-Piscine, 81-Ombre. Année 2016 à gauche (modèle 35 bandes) et année 2019 à droite (modèle 34 bandes).

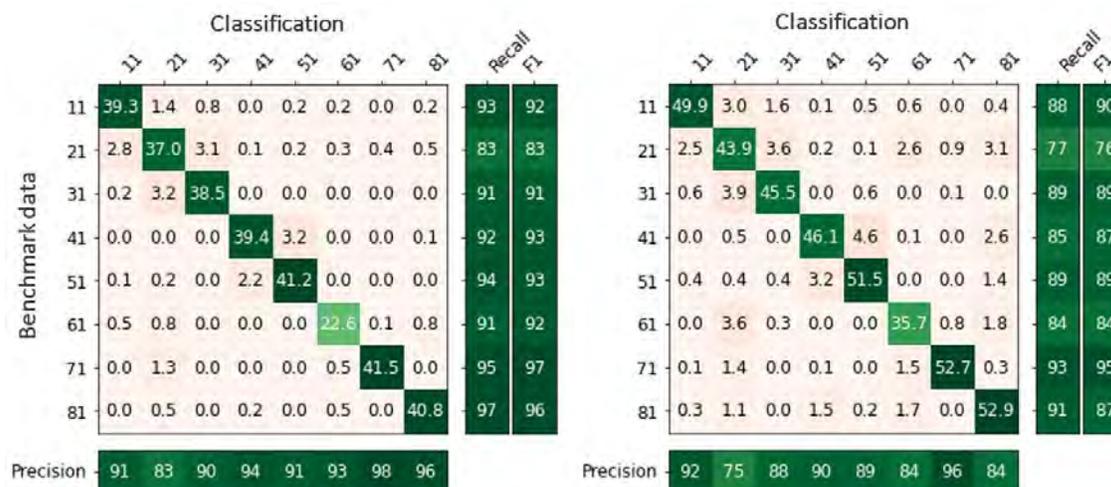


Figure 24 : Classifications avec données auxiliaires (couche « BATI » de la BD TOPO) – Matrices de confusion moyennes. La précision, le rappel et le score F1 sont exprimés en pourcentage, tandis que les valeurs de classe correspondent à un nombre moyen d'échantillons. Les correspondances des classes sont les suivantes : 11-Bâtiment, 21-Surface imperméable, 31-Sol nu, 41-Végétation haute, 51-Végétation basse, 61-Surface en eau, 71-Piscine, 81-Ombre. Année 2016 à gauche (modèle 35 bandes) et année 2019 à droite (modèle 34 bandes).



Figure 25 : Comparaison d'extraits de l'ortho-image vraies couleurs de 2016 (IGN) et du résultat de la classification de l'occupation du sol selon le modèle 35 bandes comprenant la couche BATI de la BD TOPO de l'IGN – Quartier résidentiel composé de maisons individuelles et d'espaces verts.



Figure 26 : Comparaison d'extraits de l'ortho-image vraies couleurs de 2019 (IGN) et du résultat de la classification de l'occupation du sol selon le modèle 35 bandes comprenant la couche BATI de la BD TOPO de l'IGN – Zone en construction.

### 3. Conclusion et perspectives

Cette étude a permis de tester différentes méthodes de **classification orientée objet** (méthode dite *OBI*). Elles ont été appliquées à des orthophotographies dans le but de **classer la végétation** (outil *MEO-Urban Green*) **et l'occupation du sol** (outil *MEO-Land Cover*) **au sein de la tache urbaine** de la Communauté de Communes de la Save au Touch.

Les **ortho-images de la BD ORTHO IRC** (bandes du proche infrarouge, du rouge et du vert) **et RVB** (rouge, vert, bleu) de résolution 20 ou 50 cm ont été préférées aux images Pléiades. En effet, pour le territoire de la CCST, ces dernières ne sont disponibles dans les archives accessibles gratuitement que pour le mois de mars, date non optimale pour extraire la végétation. De plus, les images sont fortement impactées par les ombres du fait des angles d'acquisition. Enfin, les différences dans les dates des images Pléiades disponibles (notamment les mois), et la couverture ou non de la zone ne permettraient pas de généraliser la méthode sur différents territoires.

Pour la phase de segmentation, la fonction *LargeScaleMeanShift* de la **librairie OTB** a été utilisée. Différents algorithmes ont été expérimentés pour la phase de classification supervisée. Finalement **l'algorithme de type Support Vector Machine à noyau RBF** donne les meilleurs résultats. Il est par ailleurs plus rapide que l'algorithme de type *Random Forest*. Ce constat est valable autant pour la classification de la végétation que pour celle de l'occupation du sol. Différentes combinaisons de variables ont été testées. On retiendra en particulier l'apport des bandes de texture *SFS (Structural Feature Set)* qui ont permis d'améliorer la qualité de la **classification de la végétation** de 2 points environ. L'**accord global moyen** obtenu est alors de **94.8 +/- 0.9 %** pour quatre classes (végétation basse, végétation haute, ombre, et autre). Également, on notera l'apport significatif de la couche *BATI* de la BD TOPO (IGN) en tant que variable d'entrée, permettant d'obtenir des **accords globaux moyens** de **92.4 +/- 1.4 % en 2016** et **87.7 +/- 1.4 % en 2019 lors de la classification de l'occupation du sol**, avec huit classes (bâtiment, surface imperméabilisée, sol nu, végétation haute, végétation basse, surface en eau, piscine et ombre). Des inégalités de performance existent toutefois entre les différentes classes, avec notamment des résultats moins performants sur les surfaces imperméabilisées (un score F1 de 76% pour l'année 2019, contre des scores F1 compris entre 84 et 95% pour les sept autres classes : bâtiment, sol nu, végétation haute, végétation basse, surface en eau, piscine et ombre). Les confusions les plus importantes sont entre les classes surface imperméabilisée/sol nu et les classes surface imperméabilisée/bâtiment. En effet, ces trois classes présentent des signaux radiométriques relativement proches. Cependant, au regard des données en entrée (orthophotographies ou images Pléiades, et données en accès libre de l'IGN), de l'objectif d'automatisation des traitements, et de la contrainte de temps sur cette partie de stage limitée à un mois et demi, la qualité générale des résultats est acceptable avec des accords globaux supérieurs à 80% (92.4 +/- 1.4% pour l'année 2016 et 87.7 +/- 1.4% pour l'année 2019). À ce stade, les recherches méthodologiques n'ont donc pas été poussées plus loin et la phase de post-traitement ne faisait pas partie des objectifs du stage.

Des essais ont été menés afin de supprimer la classe ombre lors de la classification de l'occupation du sol, en s'inspirant fortement des travaux de Zhou et al. (2009). Les résultats étaient prometteurs pour l'année 2019, mais les ombres sur les images de 2016 étaient trop importantes et aucune segmentation pertinente n'a été obtenue. Par conséquent la classe ombre a été conservée. Par ailleurs, il peut être préférable d'avoir une classe « floue » plutôt que d'augmenter le pourcentage d'erreur dans les autres classes.

## PERSPECTIVES D'AMELIORATION PAR DES POST-TRAITEMENTS

Les résultats ne sont pas exempts d'erreurs. Les classifications de surfaces imperméabilisées et zones d'ombres en surface en eau sont les confusions les plus remarquables, en particulier pour l'année 2019. Une phase de photo-interprétation et de post-traitements est nécessaire pour améliorer la qualité finale du produit. Plusieurs post-traitements sont envisagés, notamment : un tamisage permettant par exemple de supprimer les voitures, une dilatation-érosion des bâtiments afin de lisser les bords et enlever une partie des artefacts, de la photo-interprétation afin de supprimer les erreurs les plus grossières.

## PISTES D'AMELIORATION DU PROCESSUS DE CLASSIFICATION

D'une manière générale, les résultats obtenus font l'objet de confusions entre végétation basse et végétation haute, entre bâtiments et surfaces imperméabilisées. Un modèle numérique de surface (MNS) pourrait aider à pallier ce problème. Cependant, ce type de données est encore peu disponible et une telle acquisition est coûteuse. L'IGN produit des MNS (Figure 27) dont « la résolution du MNS est comprise entre 5 et 50cm suivant les zones. L'ensemble des départements a été produit, cependant les données n'ont pas encore été publiées hormis pour 40 départements disponibles en web service » (IGN 2020). La Haute Garonne n'est pas encore présente sur la carte des départements pour lesquels un MNS est disponible (Figure 28).

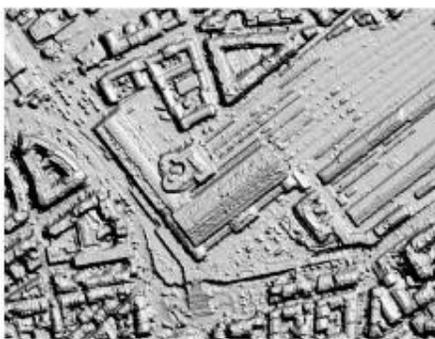


Figure 27 : Pyramide WMS MNS sur la Gare Saint Charles (Marseille). (IGN 2020)



Figure 28 : Carte des 40 départements avec un MNS disponible. (IGN 2020)

Une autre piste d'amélioration pour l'outil *MEO-Land Cover* serait une classification en deux temps, avec tout d'abord une extraction de la végétation haute, de la végétation basse et de l'ombre à l'aide de l'outil *MEO-Urban Green* (scores F1 obtenus de 93, 93 et 97 % respectivement, pour l'année 2019), puis une classification des autres surfaces. Il faudrait ensuite un jeu d'échantillons indépendant pour la validation finale.

Il pourrait également être intéressant d'étudier les courbes d'évolution de l'accord global en fonction du nombre d'échantillons afin de voir si un phénomène de surentraînement pourrait être impliqué dans la moins bonne qualité de la classification sur l'année 2019. Pour rappel l'année 2016 a été classée avec un entraînement sur 984 échantillons, contre 1304 pour 2019. Les accords globaux moyens des deux années présentent une différence de près de 5%.

## Bibliographie

- Beaumet, Grégory, Gérard Verfaillie, et Marie-Claire Charneau. «Estimation des durées minimales de basculement pour un satellite d'observation agile autonome.» *Troisième Journées Francophones de Programmation par Contraintes (JFPC07)*. Rocquencourt / France, 2007.
- CNES. *LargeScaleMeanShift*. 2020. [https://www.orfeo-toolbox.org/CookBook/Applications/app\\_LargeScaleMeanShift.html](https://www.orfeo-toolbox.org/CookBook/Applications/app_LargeScaleMeanShift.html).
- . *SFSTextureExtraction*. 2020. [https://www.orfeo-toolbox.org/CookBook/Applications/app\\_SFSTextureExtraction.html](https://www.orfeo-toolbox.org/CookBook/Applications/app_SFSTextureExtraction.html).
- Devineau, Jean-Louis. «Propriétés spectrales de la végétation.» 1990.
- ESRI. *ArcGIS Pro*. s.d. <https://pro.arcgis.com/fr/pro-app/latest/arcpy/image-analyst/msavi.htm>.
- . *EVI*. s.d. <https://pro.arcgis.com/fr/pro-app/latest/arcpy/image-analyst/evi.htm>.
- Entraîner un modèle de random forest en Python avec Scikit-Learn - LES MODELES D'ARBRES #9*. Réalisé par Morgan Gautherot. 2020.
- Gressin, Adrien. «Mise à jour d'une base de données d'occupation du sol à grande échelle en milieux naturels à partir d'image satellite THR.» Thèse de doctorat, Université Paris-Descartes, Paris, 2014, 226.
- Huang, Xin, Liangpei Zhang, et Pingxiang Li. «Classification and Extraction of Spatial Features in Urban Areas Using High-Resolution Multispectral Imagery.» *IEEE Geosciences and Remote Sensing Letters*, April 2007.
- IGN. «Guide utilisateur Pléiades - Offre de produits et services.» n° V5. 26 07 2018.
- . *Zoom sur les produits altimétriques MNT et MNS*. 10 Décembre 2020. <https://geoservices.ign.fr/blog/2020/12/10/Zoom-alti-mnt-mns.html>.
- Li, Xiaoxiao, et Guofan Shao. «Object-based urban vegetation mapping with high-resolution aerial photography as a single data source.» *International Journal of Remote Sensing*, 10 February 2013: 771-789.
- Ma, Lei, et al. «Object-based change detection in urban areas : the effects of segmentation strategy, scale, and feature space on unsupervised methods.» *Remote Sensing*, 16 September 2016: 761-778.
- Matsushita, Bunkei, Wei Yang, Jin Chen, Yuyichi Onda, et Guoyu Qiu. «Sensitivity of the Enhanced Vegetation Index (EVI) and Normalized Difference Vegetation Index (NDVI) to Topographic Effects: A Case Study in High-Density Cypress Forest.» *Sensors*, 5 November 2007: 2636-2651.
- MEOSS. *MEOSS*. s.d. <https://meoss.net/>.
- Pedregosa, Fabian, et al. «Scikit-learn: Machine Learning in Python.» *Journal of Machine Learning Research*, Novembre 2011: 2825-2830.
- SCO France. «Charte de fonctionnement du SCO France, Juillet 2021.» Space Climate Observatory, 2021, 20.
- Sharp, R., et al. *INVEST 3.9.0. User's Guide. The Natural Capital Project, Stanford University, University of Minnesota, The Nature Conservancy, and World Wildlife Fund*. 2020. <http://releases.naturalcapitalproject.org/invest-userguide/latest/index.html>.

Space4Water. *Normalized Difference Water Index (NDWI)*. 2020.  
<http://space4water.org/taxonomy/term/1315>.

Xu, Hanqiu. «Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery.» *International Journal of Remote Sensing*, 20 July 2006: 3025-3033.