



DOSSIER DE STAGE DU CERTIFICAT COMPLEMENTAIRE EN GEOMATIQUE

Télédétection et classification des revêtements des sols du canton
de Genève

Komaromi Elizabeth

Sous la direction de José Lopez – Mayeul Gaillet (DIT)
et la co-direction de Grégory Giuliani (UNIGE)

Certificat de géomatique de l'université de Genève
2025



UNIVERSITÉ
DE GENÈVE



REPUBLIQUE
ET CANTON
DE GENEVE

POST TENEBRAS LUX



SITG | LE TERRITOIRE GENEVOIS
À LA CARTE

Remerciements

Je remercie José Lopez (Pépito) et Mayeul Gaillet pour leur accueil à la Direction de l'Information et leur suivi de mon stage. Merci d'avoir pris le temps chaque semaine de vérifier que tout allait bien et de discuter des avancements du projets.

Je remercie également Sophie Komaromi avec qui nos discussions m'ont aidé à orienter mes essais et cette recherche.

Je remercie toutes les personnes de la DIT pour leur accueil et Alessandro Cerioni pour ses réponses passionnées en matière d'intelligence artificielle, de code et d'apprentissage automatique.

Enfin, je remercie Grégory Giuliani pour sa réactivité et sa positivité dans le suivi de ce travail.

Résumé

Cette étude teste l'automatisation de la détection des revêtements à partir d'images satellites Pléiades Neo de juin 2025. L'objectif principal vise à compléter les types de revêtements classés comme "dur - autre dur" dans la future carte de couverture du sol. L'objectif secondaire propose des pistes d'automatisation et d'évolution technique pour la collecte des données.

Une première approche de classification non supervisée ISO Cluster dans ArcGIS Pro a segmenté les images en cinq classes après filtrage des objets dépassant 40 cm de hauteur via le modèle numérique de hauteur. Une deuxième approche de classification supervisée Random Forest dans R a utilisé sept classes de revêtements sur 19 871 pixels d'entraînement. Le résultat a ensuite été appliqué aux polygones de la couverture du sol selon leur classe majoritaire à 80% minimum. L'enrichissement final a intégré les données collaboratives OpenStreetMap par intersection spatiale.

La classification non supervisée permet une segmentation rapide mais reste limitée par les ombres et les matériaux à signatures spectrales proches. La classification supervisée Random Forest atteint 98,36% de précision globale à l'échelle pixel avec une erreur de 1,64%. Le passage à l'échelle objet ne permet de classifier que 31,2% des polygones principalement des surfaces arborées homogènes. Les 68,8% de polygones non classifiés correspondent aux zones urbaines composites où coexistent plusieurs matériaux. L'intégration d'OpenStreetMap complète les données manquantes dans les zones bien documentées.

L'automatisation partielle serait réalisable pour les surfaces homogènes de grande taille. Une stratégie hybride combinant classification automatisée, enrichissement semi-automatique via OpenStreetMap et validation ciblée semblerait optimale. Les limites principales concernent l'occlusion par les bâtiments et la végétation, la sensibilité aux conditions d'acquisition et l'hétérogénéité du tissu urbain. Les perspectives incluent l'intégration de données LiDAR, l'imagerie oblique, les séries temporelles et les modèles d'apprentissage profond comme AlphaEarth Foundations qui réduisent les besoins en données d'entraînement et fonctionnent avec des sources multiples.

Table des abréviations

AEF	AlphaEarth Foundations
API	Application Programming Interface
CJBG	Conservatoire et Jardin botaniques de Genève
DDPS	Département fédéral de la défense, de la protection de la population et des sports
DIT	Direction de l'Information du Territoire
DT	Département du Territoire
EPSG	European Petroleum Survey Group
LIDAR	Light Detection and Ranging
MN	Milieux naturels
MNH	Modèle numérique de hauteur
MNS	Modèle numérique de surface
MNT	Modèle numérique de terrain
NDBI	Normalized Difference Built-up Index
NDVI	Normalized Difference Vegetation Index
NIR	Near Infrared (Proche infrarouge)
OCAN	Office cantonal de l'agriculture et de la nature
OCEau	Office cantonal de l'eau
OCEV	Service de géologie, sols et déchets
ODbL	Open Database License
OGC	Open Geospatial Consortium
OOB	Out-of-Bag
OSM	OpenStreetMap
OTEMO	Ordonnance technique du DDPS sur la mensuration officielle
PIR	Proche infrarouge
RGB	Rouge-Vert-Bleu
SIG	Système d'Information Géographique
SIPV	Système d'Information du Patrimoine Vert
SITG	Système d'Information du Territoire à Genève

Table des matières

1	Introduction.....	1
1.1	Présentation de la structure d'accueil.....	1
1.2	Contexte et enjeux	2
2	Analyse des processus actuels de gestion et de mise à jour des revêtements	3
2.1	Problématique	5
2.2	Objectifs du stage	6
3	Historique	6
3.1	Création de la Carte de la couverture du sol	6
4	Ressources disponibles	6
4.1	Données SITG	6
4.2	Données externes.....	7
4.3	Outils.....	11
5	Méthodologie.....	12
5.1	Acquisition des données	12
5.2	Classification non-supervisée dans ArcGIS Pro	15
5.2.1	Processus général.....	15
5.2.2	Évaluation critique de l'approche	21
5.2.3	Perspectives d'amélioration.....	21
5.3	Classification supervisée Random Forest sur la commune de Carouge	21
5.3.1	Processus général.....	22
5.3.2	Analyse des Résultats de Classification Supervisée Pléiades Neo.....	23
5.3.3	Classification pixel basée	30
5.3.4	Généralisation aux polygones.....	31
5.4	Résultat classification supervisée	34
5.4.1	Conclusion Random Forest	36
6	Limites	36
7	Pistes et recommandation.....	37
8	Conclusion et discussion	38
9	Réflexions sur le déroulement du stage.....	39

Figure 1 : organigramme du Département du Territoire	1
Figure 2 : la clé surface décrit le matériau ou le revêtement de la voie avec des valeurs documentées classées en grandes catégories.....	10
Figure 3 : processus général de la classification non-supervisée dans ArcGIS Pro	16
Figure 4 : filtrage altimétrique des objets en hauteur grâce au Modèle Numérique de Hauteur .	17
Figure 5 : image fausse couleur 6-4-3 de la zone d'étude.....	18
Figure 6 : classification non supervisée ISO5 du secteur Gazomètres à 40cm du sol avec ombres	18
Figure 7 : classification non supervisée ISO5 du secteur Gazomètres à 45cm du sol sans ombres	19
Figure 8 : images satellites d'après les polygones de la couverture du sol à 40cm du sol.....	20
Figure 9 : classification non supervisée ISO5 du secteur Cologny sur les images satellites d'après les polygones de la couverture du sol à 40cm du sol	20
Figure 10 : processus général de la classification supervisée random forest dans RStudio	22
Figure 11 : image satellite de la zone d'étude de Carouge en RGB.....	23
Figure 12 : image satellite de la zone d'étude de Carouge IRC	24
Figure 13 : polygones d'entraînement des 7 classes sur la commune de Carouge.....	24
Figure 14 : histogramme de la distribution des pixels d'entraînement par bande spectrale	26
Figure 15 : nombre de pixels par classe d'entraînement de l'image satellite de Carouge	27
Figure 16 : signature spectrale des classes pour chaque bande de l'image satellite de Carouge	28
Figure 17 : analyse de l'importance de chaque bande Pléiade Néo.....	29
Figure 18 : courbe d'erreur Out-of-bag.....	29
Figure 19 : juxtaposition de l'image RGB originale et de la classification	30
Figure 20 : l'histogramme de distribution des pourcentages de classe majoritaire par polygone	31
Figure 21 : cartographie des polygones classifiés	32
Figure 22 : distribution des polygones de la couverture du sol par revêtement	33
Figure 23 : l'analyse des statistiques détaillées par classe	34
Figure 24 : polygone de la couverture du sol dont la détection est arborée	34
Figure 25 : incohérences géométriques entre OpenStreetMap et la couverture du sol.....	35
 Tableau 1 : synthèse de la mise à jour des données de la carte des milieux naturels	4
Tableau 2 : champ numérique de la carte Nature-Sol.....	4
Tableau 3 : champ numérique de la carte Domaine Routier	5
Tableau 4 : classifieurs disponibles dans ArcGIS Pro.....	11
Tableau 5 : champ numérique de la carte de la Couverture du Sol	13
Tableau 6 : tableau explicatif des longueurs d'ondes des bandes spectrales des images Pléiade Néo	14

1 Introduction

1.1 Présentation de la structure d'accueil

Le stage, d'une durée de 4 mois à 60%, s'est déroulé au sein de la Direction de l'Information du Territoire (DIT) rattachée au Département du Territoire (DT). Le Département du Territoire de l'État de Genève pilote le développement territorial du canton. Elle est l'entité référente et constitue le centre de compétences du Système d'Information Territorial Genevois (SITG). Elle veille, notamment, à la diffusion, à la promotion et à la valorisation des données territoriales, à la gestion et à la diffusion du catalogue des géométadonnées, à la garantie de la cohérence et de la qualité des géodonnées de référence, à la collaboration avec l'ensemble des partenaires institutionnels sur des projets liés à la gestion du territoire ainsi qu'à la gestion des interactions avec les utilisateurs. La DIT assure également la gestion du référentiel des données, la direction, la surveillance et la vérification de la mensuration officielle et du cadastre du sous-sol. (Direction de l'information du territoire (DIT))

Le Système d'Information du Territoire à Genève est fondé sur un réseau de partenaires publics avec pour objectif de coordonner, centraliser et diffuser largement les données relatives au territoire genevois ainsi que les outils de gestion, de consultation et de restitution. La DIT comprend plusieurs services. Les services généraux assurent le support, l'information au public et aux professionnels, la formation et la gestion des archives. Le service expertise et prestations gère le catalogue de métadonnées, configure les plateformes, diffuse les données géographiques et BIM, conseille en géomatique et exploite les données pour produire des indicateurs ou des outils d'aide à la décision. Le service production et gestion des données veille à la qualité des données de référence à leur modélisation et à leur mise à jour, tout en assurant l'acquisition, le traitement et le contrôle. Enfin, le service recherche et développement se concentre sur la conception de projets innovants et le test de nouvelles technologies.




Figure 1 : organigramme du Département du Territoire

1.2 Contexte et enjeux

Dans un contexte de gestion durable de la ressource sol, il semble nécessaire de cartographier finement la nature des sols, de mesurer et documenter leurs propriétés, d'étudier leur évolution dans le temps, de mesurer l'impact des activités humaines sur cette évolution, d'estimer les conséquences des modifications de ses propriétés sur l'environnement et d'anticiper l'impact d'événements météorologiques. (Cercle Couverture du Sol, 2024). L'exploitation des données de couverture du sol pour une gestion durable répond, en effet, à une série de besoins exprimés par différents services publics dans le cadre du Cercle de la Couverture du Sol du Département du Territoire. Je dois chercher plus d'informations spécifiques sur les cercles d'utilisateurs du SITG de Genève. Un cercle est un espace d'échange organisé pour traiter une thématique précise. Les cercles permettent aux participants d'échanger, de partager des informations ou d'expérimenter sur un sujet défini. Chaque cercle possède un responsable. Ce responsable décide de l'ouverture au public, invite des personnes intéressées et organise les modalités de fonctionnement. Le cercle des contributeurs et usagers est un organe de la communauté de la géoinformation. La communauté regroupe toutes les parties prenantes de la géoinformation de la région genevoise : l'administration cantonale, les gestionnaires et producteurs de géodonnées et les usagers. Les cercles permettent de rassembler les acteurs au niveau opérationnel et technique. Ils servent à suivre les usages, échanger sur les besoins et proposer des évolutions. Enfin, toute personne peut demander à rejoindre un cercle existant ou proposer la création d'un nouveau cercle.

Notamment, l'Office Cantonal de la Nature et de l'Agriculture (OCAN) a souligné la nécessité d'améliorer l'efficacité des mises à jour des changements liés aux zones artificialisées afin de pouvoir concentrer davantage les efforts sur l'observation et la gestion des milieux naturels. Dans le même esprit, ce service a eu besoin de données permettant le suivi de la loi climat urbain L1.07, en particulier pour le monitoring de la végétalisation, de l'arborisation et de la mobilité douce. Plusieurs services ont insisté sur l'importance de disposer d'une carte précise et détaillée des sols, notamment autour du domaine public comme les routes cantonales. L'Office Cantonal de l'eau (OCEau) et le SIPV ont exprimé le besoin d'une cartographie qui intègrent des informations sur l'imperméabilisation. De même, l'Office Cantonal des transports s'intéresse à l'utilisation des sols et les types de revêtements. Le Conservatoire du Jardin Botanique (CJB) a quant à lui exprimé le besoin de créer une carte unique et fédératrice, structurée autour d'indices harmonisés (imperméabilité, fragmentation, naturalité) qui puisse servir de base commune. À partir de cette carte de référence, des cartes dérivées pourront alors être produites ou adaptées aux différents besoins des services. Le CJB a également mis en avant la nécessité de disposer d'un modèle de données unique, évolutif et collaboratif, afin de répondre de manière cohérente et durable aux attentes de l'ensemble des acteurs. L'OBSTER a souhaité utiliser ces données pour surveiller l'artificialisation des sols et évaluer les impacts des projets d'aménagement sur le territoire. De son côté, le Département du Territoire (DT) a mis en avant le besoin d'analyses quinquennales ou décennales des évolutions des sols, afin de suivre les effets des projets d'infrastructure dans le cadre de la Vision Territoriale Transfrontalière 2050. Le DT a également souligné l'importance de mettre en place une base de données commune à l'échelle du Grand Genève qui puisse permettre un suivi homogène de l'imperméabilisation et de l'artificialisation des sols dans une perspective transfrontalière. L'OCEau a quant à lui insisté sur le renforcement de la qualité des informations, en vue d'une meilleure préservation des sols. Il s'agirait notamment

d'améliorer la connaissance des phénomènes d'infiltration et de ruissellement ainsi que l'identification des zones inconstructibles proches des cours d'eau et des secteurs sensibles.

Enfin, en tant qu'entité responsable des données de la mensuration officielle, la DIT a pour mission de coordonner et centraliser les données de la couverture du sol faisant partie intégrante de la mensuration officielle dans le modèle de données minimal fédéral en vigueur.

Dans l'ensemble, ces besoins convergent vers des enjeux communs : améliorer l'efficacité des mises à jour, accroître la précision et la qualité des données, développer des outils partagés et un modèle de données commun, et renforcer la collaboration entre services pour une gestion plus cohérente, durable et concertée du territoire. (Cercle Couverture du Sol, 2025).

2 Analyse des processus actuels de gestion et de mise à jour des revêtements

La gestion de la couverture du sol constitue un enjeu majeur pour l'aménagement du territoire et la mise en œuvre des politiques publiques. Le système de mensuration officielle s'appuie sur un processus de mise à jour permanente impliquant trois catégories d'acteurs : les propriétaires fonciers, l'Association des Géomètres Genevois pour le relevé technique, et la DIT pour l'intégration des données. Le processus actuel traite plusieurs centaines de dossiers de mutations techniques annuellement. Une gestion précise des sols dans le Canton de Genève entraîne des questionnements et notamment sur les revêtements associés aux différents objets qui constituent la surface sol cantonale. La qualité de l'information sur les types de surfaces ou revêtements dépend fortement des cartes, de leurs types de relevés et de la fréquence de ces relevés.

La carte des milieux naturels (MN) a pour objectif de recenser et de cartographier les milieux naturels du canton de Genève. Pour ce faire, différentes sources de données sont mobilisées (tab.1) : orthophotos, données cadastrales, relevés et observations de terrain, ainsi que des contributions d'acteurs externes (communes, offices cantonaux, tiers). La carte fait l'objet de révisions annuelles qui intègrent notamment les données issues du référentiel végétal, des couches de base de la mensuration officielle ainsi que des données acquises par des partenaires institutionnels. Les observations et données collectées lors des relevés sont d'abord consignées dans les couches de travail, puis transférées vers la carte MN, conformément à un tableau d'équivalence défini par les instances compétentes. Inversement, la carte MN permet aussi de documenter et de compléter les zones du canton qui ne sont pas couvertes ou suffisamment décrites par les données cadastrales. Actuellement, le canton ne bénéficie pas d'un relevé homogène. En effet, les espaces publics et accessibles sont relevés selon un niveau de détails plus élevé que les zones privées ou difficiles d'accès.




Tableau 1 : synthèse de la mise à jour des données de la carte des milieux naturels

Dans la carte Nature-Sol Sous la terminologie usuelle de nature du sol sont regroupés les 6 types de nature du sol (tab.2) : revêtement dur, verte, eau, boisée, sans végétation, autres natures. Seule la nature "revêtement dur" fait partie de la mise à jour permanente (Art. 23 OMO) effectuée dans le cadre de la conservation, contrairement aux autres natures dont la mise à jour est réalisée périodiquement.

Tableau 2 : champ numérique de la carte Nature-Sol

PROVENANCE	Texte	Provenance de la donnée :- Terrestre (acquis sur la base de relevés terrestres ,chevillière, théodolite,..., à l'exception du niveling géométrique ou de précision)- Digitalisation (acquis par digitalisation sur plan)- GNSS (acquis par observations GNSS uniquement)-Combiné GNSS/terrestre- Photogrammétrie- Nivellement technique et de précision- Autre- Orthophoto (acquis par l'intermédiaire de digitalisation sur orthophoto)
TYPE	Texte	Type de nature du sol- revêtement dur- verte- eau- boisée- sans végétation- autres natures

L'infrastructure du Domaine routier est cataloguée en 9 objets distincts et chaque objet est découpé selon sa nature de revêtement (tab.3). Elle est mise à jour selon le principe de la mise à jour permanente (art. 23 OMO). Natures de revêtements : arbustes, autre, béton, béton bitumineux, gazon, gravier, grille gazon, pavés, plates-bandes, prairie et terre.

Tableau 3 : champ numérique de la carte Domaine Routier

REVETEMENT	Texte	Nature du revêtement
PROVENANCE	Texte	Provenance de la donnée : - Terrestre (acquis sur la base de relevés terrestres ,chevillière, théodolite,..., à l'exception du nivelllement géométrique ou de précision) - Digitalisation (acquis par digitalisation sur plan) - GNSS (acquis par observations GNSS uniquement) -Combiné GNSS/terrestre - Photogrammétrie - Nivellement technique et de précision - Autre - Orthophoto (acquis par l'intermédiaire de digitalisation sur orthophoto)

La carte Nature Sol couplée à celle des bâtiments hors sol ainsi que du domaine routier et la carte des milieux naturels offrent une partition complète du territoire ainsi que la connaissance des revêtements de certains objets qui peut être complétée par les codes MN des revêtements de la carte des Milieux Naturels.

2.1 Problématique

Actuellement, de nombreux acteurs gèrent des informations liées à la couverture du sol, sans qu'il existe une documentation complète des processus mis en place pour acquérir, mettre à jour et intégrer les données de la couverture du sol. Chaque service métier se charge d'acquérir des données pour ses besoins, selon des définitions et des classifications qui lui sont propres. L'objectif actuel de la DIT consiste, au-delà de l'exigence réglementaire de production mensuelle de la carte de couverture du sol conforme au modèle fédéral de la MO, d'enrichir le modèle de données standard par la complétion de l'attribut revêtement pour l'ensemble des objets publics et privés de la prochaine carte master de couverture des sols tout en optimisant le processus de collecte et de mise à jour des informations sur les revêtements en garantissant la soutenabilité opérationnelle.

Dans ce but, ce travail cherche à répondre aux questions suivantes :

- Est-il possible de détecter tous les types de revêtements ?
- Est-il possible d'automatiser tout ou partie de la mise à jour des revêtements des objets de la couverture du sol?
- L'apprentissage automatique (machine learning) est-il une piste d'amélioration et d'automatisation des processus ?

2.2 Objectifs du stage

L'objectif principal de ce stage consiste à rechercher et expérimenter des outils et des traitements pour compléter les revêtements de la couverture du sol de Genève. Plus spécifiquement, ce travail vise à préciser les types de revêtements de type « dur - autre dur ».

L'objectif secondaire de ce travail et de proposer des pistes d'automatisation de récolte de donnée ainsi que des évolutions techniques potentielles à questionner ou à poursuivre.

3 Historique

3.1 Création de la Carte de la couverture du sol

L'OTEMO (Ordonnance technique du DDPS sur la mensuration officielle, 10 juin 1994) définit un catalogue fédéral de couverture du sol (art. 7-b) appliqué à tout le territoire suisse. La couche « couverture du sol » distingue 6 genres (CODE_OTEMO_1) et 25 sous-genres (CODE_OTEMO_2) qui regroupe notamment les bâtiments, les surfaces à revêtement dur, les surfaces vertes, les eaux, les surfaces boisées et les surfaces sans végétation, chacun subdivisé en catégories plus précises.

Pour répondre à cette norme, la carte OTEMPO résulte de la compilation de deux sources cantonales :

- La Mensuration Officielle (MO), gérée par la Direction de l'information du territoire, qui fournit les données cadastrales officielles basées sur le modèle fédéral MD.01-MO-CH à partir d'un modèle de donnée cantonale plus riche.
- La carte des milieux naturels du Grand Genève, produite par le SIPV et les Conservatoire et Jardin botaniques, mise à jour chaque année à partir d'orthophotos, d'observations terrain et d'autres données partenaires.

Les données de la mensuration officielle, qui définissent la propriété foncière et alimentent le SITG, servent de référence : lorsqu'un géomètre relève une surface, celle-ci est intégrée dans la mensuration officielle puis transférée dans la MN via une table d'équivalence établie par la DIT et les CJBG. Inversement, la MN permet de documenter les zones non relevées par la MO, notamment dans les secteurs privés moins prospectés.

4 Ressources disponibles

4.1 Données SITG

Satellite Pléiade Néo

Les données raster participent à la production et l'actualisation de la couverture du sol. Elles permettent d'obtenir une information continue sur le territoire et constituent une source complémentaire aux données vectorielles, notamment pour l'identification des textures ou des revêtements par télédétection. Les quatre satellites Pléiades Neo fournissent des produits orthographiques avec une résolution standard de 0,3 mètre. (Image Satellite Pléiades Néo Juin 2025 (Pixel 25 Cm) | Catalogue SITG, 2025.)

LIDAR

Les données LIDAR (Light Detection and Ranging) constituent une autre source de données. Elles permettent de produire des modèles numériques de terrain (MNT) et des modèles numériques de surface (MNS) avec une précision altimétrique centimétrique. Le nuage de points LIDAR, acquis lors de campagnes spécifiques, est utilisé pour dériver des informations telles que la hauteur de la végétation, la volumétrie des bâtiments ou la structure des surfaces. Ces données sont particulièrement utiles pour enrichir les indicateurs liés à la perméabilité et à la composition de la couverture du sol bâti.

4.2 Données externes

Open Street Map

Les données vectorielles d'OpenStreetMap (OSM) constituent un ensemble de représentations géographiques structurées en entités géométriques (points, lignes et polygones) qui offrent une précision géométrique et thématique élevée. Chaque entité peut être enrichie d'attributs descriptifs si ces derniers ont été renseignés par la communauté. En effet, OSM est une base de données géospatiale collaborative et libre alimentée par une communauté mondiale de contributeurs. Les données y sont produites par numérisation, relevés GPS, imagerie satellitaire ou encore intégration de données publiques compatibles avec la licence ODbL (Open Database License).

Dans OpenStreetMap, la clé `surface` permet de décrire le matériau ou le revêtement de la voie (route, chemin, piste cyclable, trottoir, etc.), avec des valeurs documentées classées en grandes catégories (pavée, non pavée, et surfaces spéciales sportives). Toutefois, l'usage de ce tag présente des limites : l'absence de couverture complète des surfaces dans certaines zones, le mélange d'échelles de précision (par ex. gravier lâche versus gravier compacté), et des variations dans les pratiques de contribution.

Value	Comment	Photo	Abundance
Paved			
<code>paved</code>	A feature that is predominantly paved; i.e., it is covered with paving stones, concrete or bitumen. This value gives general description; use a more precise value if possible, like <code>asphalt</code> , <code>concrete</code> , <code>paving_stones</code> and other options below.		<ul style="list-style-type: none"><input checked="" type="checkbox"/> 4 374 096 6,03 %<input type="checkbox"/> 15 579 4,35 %<input type="checkbox"/> 4 353 007 6,04 %<input type="checkbox"/> 5 510 5,58 % Plus de détails dans taginfo
<code>asphalt</code>	Short for <code>asphalt concrete</code> - mineral aggregate bound by asphalt.		<ul style="list-style-type: none"><input checked="" type="checkbox"/> 33 175 324 45,71 %<input type="checkbox"/> 131 126 36,59 %<input type="checkbox"/> 33 014 515 45,77 %<input type="checkbox"/> 29 683 30,04 % Plus de détails dans taginfo
<code>chipseal</code>	Less expensive alternative to asphalt concrete, using a thin base of hot bitumen or asphalt with aggregate pushed into it. Common in many American countries and Oceania. Often hard to distinguish from asphalt concrete by laypersons, some consider it as subtype of asphalt rather separate surface. In the end vast majority of chipsealed roads are tagged as <code>surface=asphalt</code> instead.		<ul style="list-style-type: none"><input checked="" type="checkbox"/> 6 453 0,01 %<input type="checkbox"/> 4 0 %<input type="checkbox"/> 6 447 0,01 %<input type="checkbox"/> 2 0 % Plus de détails dans taginfo
<code>concrete</code>	Portland cement concrete, forming a large surface, typically cast in place and may have predetermined breaking joints. For pre-fabricated plates, please use <code>concrete:plates</code> or <code>concrete:lanes</code> if you know how the concrete is laid out and one of these tags fits.		<ul style="list-style-type: none"><input checked="" type="checkbox"/> 4 521 709 6,23 %<input type="checkbox"/> 27 018 7,54 %<input type="checkbox"/> 4 487 740 6,22 %<input checked="" type="checkbox"/> 6 951 7,04 % Plus de détails dans taginfo
<code>concrete:lanes</code>	Long, narrow concrete elements for a two-tracked vehicle (motorcars) so that the tires always hit the concrete. There might be sand, ground, grass, pavers, asphalt, etc. in between them. Note that if you tag a single-tracked way just use <code>concrete</code> , since there are no lanes.		<ul style="list-style-type: none"><input checked="" type="checkbox"/> 32 297 0,04 %<input type="checkbox"/> 41 0,01 %<input type="checkbox"/> 32 244 0,04 %<input checked="" type="checkbox"/> 12 0,01 % Plus de détails dans taginfo

`concrete:plates`	Large, heavy duty prefabricated concrete plates placed closely together.	<img alt="A paved surface made of small, rectangular concrete plates." data-bbox="710

<code>metal_grid</code>	Metal grids are often used as a surface on industrial-style bridges or stairs. When wet, the surface can become very slippery, especially for bikes. The surface can also be unsuitable for dogs, due to the sharp edges and the look-through effect. This surface is sometimes known as metal grate, metal grating, steel grate/grating, or open grate.		<table border="1"><tr><td>4 355</td><td>0.01 %</td></tr><tr><td>250</td><td>0.07 %</td></tr><tr><td>4 102</td><td>0.01 %</td></tr><tr><td>3</td><td>0 %</td></tr></table> Plus de détails dans taginfo	4 355	0.01 %	250	0.07 %	4 102	0.01 %	3	0 %
4 355	0.01 %										
250	0.07 %										
4 102	0.01 %										
3	0 %										
<code>wood</code>	Used for wood surfaced bridges, plank walkways, and garden decking.		<table border="1"><tr><td>260 850</td><td>0.38 %</td></tr><tr><td>3 997</td><td>1.12 %</td></tr><tr><td>256 111</td><td>0.36 %</td></tr><tr><td>542</td><td>0.55 %</td></tr></table> Plus de détails dans taginfo	260 850	0.38 %	3 997	1.12 %	256 111	0.36 %	542	0.55 %
260 850	0.38 %										
3 997	1.12 %										
256 111	0.36 %										
542	0.55 %										
<code>stepping_stones</code>	Stones or plates individually arranged in a row, allowing to walk on, surrounded by an unpaved medium such as grass or water		<table border="1"><tr><td>2 984</td><td>0 %</td></tr><tr><td>48</td><td>0.01 %</td></tr><tr><td>2 931</td><td>0 %</td></tr><tr><td>7</td><td>0.01 %</td></tr></table> Plus de détails dans taginfo	2 984	0 %	48	0.01 %	2 931	0 %	7	0.01 %
2 984	0 %										
48	0.01 %										
2 931	0 %										
7	0.01 %										
<code>rubber</code>	Playground safety surfacing made of recycled rubber tire products such as poured rubber, rubber tiles or loose rubber mulch. These surfaces are usually made of rubber designed specifically for aesthetics, child safety, and/or ADA wheelchair accessibility.		<table border="1"><tr><td>6 515</td><td>0.01 %</td></tr><tr><td>1 236</td><td>0.34 %</td></tr><tr><td>5 162</td><td>0.01 %</td></tr><tr><td>117</td><td>0.12 %</td></tr></table> Plus de détails dans taginfo	6 515	0.01 %	1 236	0.34 %	5 162	0.01 %	117	0.12 %
6 515	0.01 %										
1 236	0.34 %										
5 162	0.01 %										
117	0.12 %										
<code>tiles</code>	Ceramic tiles. Those are commonly used for paving <i>indoor</i> corridors in public spaces such as airports or shopping malls. Outdoors, they are sometimes encountered on smaller footways in parks and terraces.		<table border="1"><tr><td>2 381</td><td>0 %</td></tr><tr><td>16</td><td>0 %</td></tr><tr><td>2 338</td><td>0 %</td></tr><tr><td>27</td><td>0.03 %</td></tr></table> Plus de détails dans taginfo	2 381	0 %	16	0 %	2 338	0 %	27	0.03 %
2 381	0 %										
16	0 %										
2 338	0 %										
27	0.03 %										
<code>fibre_reinforced_polymer_grate</code>	Often used on outdoor walkways, they provide good grip due to the rough surface and open grate allows water to go through the surface. Also known as FRP Grate/Grating.		<table border="1"><tr><td>107</td><td>0 %</td></tr><tr><td>0</td><td>0 %</td></tr><tr><td>107</td><td>0 %</td></tr><tr><td>0</td><td>0 %</td></tr></table> Plus de détails dans taginfo	107	0 %	0	0 %	107	0 %	0	0 %
107	0 %										
0	0 %										
107	0 %										
0	0 %										
<code>user_defined</code>	All commonly used values according to Taginfo .										

Unpaved

<code>unpaved</code>	A feature that is predominantly unsealed (unpaved); i.e., it has a loose covering ranging from compacted stone chippings to soil. Unpaved roads may, in aerial imagery, show evidence of water along their course; in such circumstances, the waterway should not be tagged as a stream, though it might appear as such. <i>This value gives only a rough description; use a more precise value if possible.</i>		<table border="1"><tr><td>12 589 999</td><td>17.35 %</td></tr><tr><td>96 090</td><td>26.81 %</td></tr><tr><td>12 492 851</td><td>17.32 %</td></tr><tr><td>1 058</td><td>1.07 %</td></tr></table> Plus de détails dans taginfo	12 589 999	17.35 %	96 090	26.81 %	12 492 851	17.32 %	1 058	1.07 %
12 589 999	17.35 %										
96 090	26.81 %										
12 492 851	17.32 %										
1 058	1.07 %										
<code>compacted</code>	A mixture of larger (e.g., gravel) and smaller (e.g., sand) parts, compacted (e.g., with a roller), so the surface is more stable than loose gravel. Used, for example, for park paths, better tracks, some service ways, ... Best sort of ways below paving with asphalt, concrete, paving stones. Sometimes known as water-bound macadam. Mixture and compacting leads to more grip and stability.		<table border="1"><tr><td>1 322 204</td><td>1.82 %</td></tr><tr><td>1 830</td><td>0.51 %</td></tr><tr><td>1 319 389</td><td>1.83 %</td></tr><tr><td>985</td><td>1 %</td></tr></table> Plus de détails dans taginfo	1 322 204	1.82 %	1 830	0.51 %	1 319 389	1.83 %	985	1 %
1 322 204	1.82 %										
1 830	0.51 %										
1 319 389	1.83 %										
985	1 %										
<code>fine_gravel</code>	This tag is used somewhat inconsistently; see its detail page. It may be used to specify fine loose gravel (as shown in the picture) which makes it unsuitable for road bicycles, but it is also sometimes used as an alias for <code>compacted</code> , which is easy to cycle on. If the gravel is fixed instead of loose, please consider using well-defined <code>compacted</code> instead.		<table border="1"><tr><td>506 572</td><td>0.7 %</td></tr><tr><td>2 534</td><td>0.71 %</td></tr><tr><td>503 342</td><td>0.7 %</td></tr><tr><td>796</td><td>0.81 %</td></tr></table> Plus de détails dans taginfo	506 572	0.7 %	2 534	0.71 %	503 342	0.7 %	796	0.81 %
506 572	0.7 %										
2 534	0.71 %										
503 342	0.7 %										
796	0.81 %										
<code>gravel</code>	This tag has very large meaning range. Used for cases ranging from huge gravel pieces like track ballast used as surface, through small pieces of gravel to compacted surface.		<table border="1"><tr><td>2 304 979</td><td>3.18 %</td></tr><tr><td>6 821</td><td>1.9 %</td></tr><tr><td>2 295 089</td><td>3.18 %</td></tr><tr><td>3 069</td><td>3.11 %</td></tr></table> Plus de détails dans taginfo	2 304 979	3.18 %	6 821	1.9 %	2 295 089	3.18 %	3 069	3.11 %
2 304 979	3.18 %										
6 821	1.9 %										
2 295 089	3.18 %										
3 069	3.11 %										
<code>shells</code>	Crushed or whole seashells, commonly seen on footways and cycleways in the Netherlands.		<table border="1"><tr><td>1 205</td><td>0 %</td></tr><tr><td>11</td><td>0 %</td></tr><tr><td>1 190</td><td>0 %</td></tr><tr><td>4</td><td>0 %</td></tr></table> Plus de détails dans taginfo	1 205	0 %	11	0 %	1 190	0 %	4	0 %
1 205	0 %										
11	0 %										
1 190	0 %										
4	0 %										
<code>rock</code>	Big pieces of rock used to improve path quality or exposed bare rock, including trails across <code>natural=bare_rock</code> . Typically in mountainous areas.		<table border="1"><tr><td>30 134</td><td>0.04 %</td></tr><tr><td>188</td><td>0.05 %</td></tr><tr><td>29 815</td><td>0.04 %</td></tr><tr><td>131</td><td>0.13 %</td></tr></table> Plus de détails dans taginfo	30 134	0.04 %	188	0.05 %	29 815	0.04 %	131	0.13 %
30 134	0.04 %										
188	0.05 %										
29 815	0.04 %										
131	0.13 %										
<code>pebblestone</code>	Pebbles are stones rounded by waves or river flow. Typical size range from 2 to 8 cm. Describing a surface in OSM they are loosely arranged. Like gravel pebbles can be used as a building part of <code>compacted</code> .		<table border="1"><tr><td>151 047</td><td>0.21 %</td></tr><tr><td>459</td><td>0.13 %</td></tr><tr><td>149 804</td><td>0.21 %</td></tr><tr><td>784</td><td>0.79 %</td></tr></table> Plus de détails dans taginfo	151 047	0.21 %	459	0.13 %	149 804	0.21 %	784	0.79 %
151 047	0.21 %										
459	0.13 %										
149 804	0.21 %										
784	0.79 %										
<code>ground</code>	No special surface, the ground itself has marks of human or animal usage. <i>This value gives only a rough description; if possible, use a more precise value such as <code>grass</code>, <code>clay</code>, <code>sand</code>, <code>dirt</code>, <code>gravel</code> or <code>pebblestone</code>.</i>		<table border="1"><tr><td>3 571 728</td><td>4.92 %</td></tr><tr><td>6 861</td><td>1.91 %</td></tr><tr><td>3 563 965</td><td>4.84 %</td></tr><tr><td>902</td><td>0.91 %</td></tr></table> Plus de détails dans taginfo	3 571 728	4.92 %	6 861	1.91 %	3 563 965	4.84 %	902	0.91 %
3 571 728	4.92 %										
6 861	1.91 %										
3 563 965	4.84 %										
902	0.91 %										
<code>dirt</code>	Used for where surface is exposed <code>soil</code> , also commonly referred to as earth or dirt, but it is not sand, gravel, or rock. Gravel is sometimes mistakenly called dirt. Some compacted surfaces are sometimes called "dirt" too, please consider the definition of <code>compacted</code> .		<table border="1"><tr><td>1 816 832</td><td>2.5 %</td></tr><tr><td>2 631</td><td>0.73 %</td></tr><tr><td>1 813 477</td><td>2.51 %</td></tr><tr><td>724</td><td>0.73 %</td></tr></table> Plus de détails dans taginfo	1 816 832	2.5 %	2 631	0.73 %	1 813 477	2.51 %	724	0.73 %
1 816 832	2.5 %										
2 631	0.73 %										
1 813 477	2.51 %										
724	0.73 %										
<code>earth</code>	The same meaning as <code>dirt</code> . Use the more common <code>dirt</code> instead.		<table border="1"><tr><td>152 855</td><td>0.21 %</td></tr><tr><td>110</td><td>0.03 %</td></tr><tr><td>152 687</td><td>0.21 %</td></tr><tr><td>58</td><td>0.06 %</td></tr></table> Plus de détails dans taginfo	152 855	0.21 %	110	0.03 %	152 687	0.21 %	58	0.06 %
152 855	0.21 %										
110	0.03 %										
152 687	0.21 %										
58	0.06 %										
<code>grass</code>	Grass covered ground. Mostly nice to walk. May turn into <code>surface=dirt</code> or become overgrown and disappear.		<table border="1"><tr><td>1 378 718</td><td>1.9 %</td></tr><tr><td>10 588</td><td>2.95 %</td></tr><tr><td>1 355 637</td><td>1.88 %</td></tr><tr><td>12 493</td><td>12.65 %</td></tr></table> Plus de détails dans taginfo	1 378 718	1.9 %	10 588	2.95 %	1 355 637	1.88 %	12 493	12.65 %
1 378 718	1.9 %										
10 588	2.95 %										
1 355 637	1.88 %										
12 493	12.65 %										

mud	Similar to ground but most of the year wet which gives a soft ground with low carrying capacity. Mostly found on wetland like swamps or in tidal areas. Sometimes also found on slopes draining onto a way.		<table border="1"> <tr><td>31 895</td><td>0.04 %</td></tr> <tr><td>185</td><td>0.05 %</td></tr> <tr><td>31 196</td><td>0.04 %</td></tr> <tr><td>514</td><td>0.52 %</td></tr> </table> Plus de détails dans taginfo	31 895	0.04 %	185	0.05 %	31 196	0.04 %	514	0.52 %
31 895	0.04 %										
185	0.05 %										
31 196	0.04 %										
514	0.52 %										
sand	Small to very small fractions (less than 2 mm) of rock.		<table border="1"> <tr><td>604 091</td><td>0.83 %</td></tr> <tr><td>4 838</td><td>1.35 %</td></tr> <tr><td>589 315</td><td>0.82 %</td></tr> <tr><td>9 938</td><td>10.06 %</td></tr> </table> Plus de détails dans taginfo	604 091	0.83 %	4 838	1.35 %	589 315	0.82 %	9 938	10.06 %
604 091	0.83 %										
4 838	1.35 %										
589 315	0.82 %										
9 938	10.06 %										
woodchips	Woodchips as a surface, perhaps for a playground or walking trail. Can consist of either chips of actual wood, or of bark only. Sometimes written as wood chips.		<table border="1"> <tr><td>14 960</td><td>0.02 %</td></tr> <tr><td>562</td><td>0.16 %</td></tr> <tr><td>14 313</td><td>0.02 %</td></tr> <tr><td>85</td><td>0.09 %</td></tr> </table> Plus de détails dans taginfo	14 960	0.02 %	562	0.16 %	14 313	0.02 %	85	0.09 %
14 960	0.02 %										
562	0.16 %										
14 313	0.02 %										
85	0.09 %										
snow	Winter roads surfaced with compacted snow.		<table border="1"> <tr><td>452</td><td>0 %</td></tr> <tr><td>5</td><td>0 %</td></tr> <tr><td>436</td><td>0 %</td></tr> <tr><td>11</td><td>0.01 %</td></tr> </table> Plus de détails dans taginfo	452	0 %	5	0 %	436	0 %	11	0.01 %
452	0 %										
5	0 %										
436	0 %										
11	0.01 %										
ice	Ice roads, winter roads		<table border="1"> <tr><td>2 624</td><td>0 %</td></tr> <tr><td>22</td><td>0.01 %</td></tr> <tr><td>2 578</td><td>0 %</td></tr> <tr><td>24</td><td>0.02 %</td></tr> </table> Plus de détails dans taginfo	2 624	0 %	22	0.01 %	2 578	0 %	24	0.02 %
2 624	0 %										
22	0.01 %										
2 578	0 %										
24	0.02 %										
salt	Dry salt lakes		<table border="1"> <tr><td>368</td><td>0 %</td></tr> <tr><td>5</td><td>0 %</td></tr> <tr><td>338</td><td>0 %</td></tr> <tr><td>29</td><td>0.03 %</td></tr> </table> Plus de détails dans taginfo	368	0 %	5	0 %	338	0 %	29	0.03 %
368	0 %										
5	0 %										
338	0 %										
29	0.03 %										
Special (sports, etc.)											
clay	Most common on tennis courts. Sometimes used for other sports: soccer, athletic tracks, boules, etc.		<table border="1"> <tr><td>39 395</td><td>0.05 %</td></tr> <tr><td>212</td><td>0.06 %</td></tr> <tr><td>38 591</td><td>0.05 %</td></tr> <tr><td>592</td><td>0.6 %</td></tr> </table> Plus de détails dans taginfo	39 395	0.05 %	212	0.06 %	38 591	0.05 %	592	0.6 %
39 395	0.05 %										
212	0.06 %										
38 591	0.05 %										
592	0.6 %										
tartan	A synthetic, all-weather surface typically used in running and other sport tracks. Although Tartan is a trademark, it is used as a generic term due to its widespread usage. Other well-known brand names include Rekotart or Mondotrack.		<table border="1"> <tr><td>44 087</td><td>0.06 %</td></tr> <tr><td>539</td><td>0.15 %</td></tr> <tr><td>38 997</td><td>0.05 %</td></tr> <tr><td>4 551</td><td>4.61 %</td></tr> </table> Plus de détails dans taginfo	44 087	0.06 %	539	0.15 %	38 997	0.05 %	4 551	4.61 %
44 087	0.06 %										
539	0.15 %										
38 997	0.05 %										
4 551	4.61 %										
artificial_turf	An all-weather surface made from synthetic fibres to look and feel like natural grass. Often used for tracks and pitches of sports such as football, baseball, etc.		<table border="1"> <tr><td>48 505</td><td>0.07 %</td></tr> <tr><td>688</td><td>0.19 %</td></tr> <tr><td>47 495</td><td>0.07 %</td></tr> <tr><td>322</td><td>0.33 %</td></tr> </table> Plus de détails dans taginfo	48 505	0.07 %	688	0.19 %	47 495	0.07 %	322	0.33 %
48 505	0.07 %										
688	0.19 %										
47 495	0.07 %										
322	0.33 %										
acrylic	An artificial surface covered with acrylic resin-bound coating. Often used for tennis courts, basketball courts, etc. Prominent brands include: DecoTurf, GreenSet and so on.		<table border="1"> <tr><td>6 830</td><td>0.01 %</td></tr> <tr><td>38</td><td>0.01 %</td></tr> <tr><td>6 748</td><td>0.01 %</td></tr> <tr><td>48</td><td>0.05 %</td></tr> </table> Plus de détails dans taginfo	6 830	0.01 %	38	0.01 %	6 748	0.01 %	48	0.05 %
6 830	0.01 %										
38	0.01 %										
6 748	0.01 %										
48	0.05 %										
carpet	Carpet may be used for some sport courts such as indoor tennis courts and appear on some highway=corridor .		<table border="1"> <tr><td>340</td><td>0 %</td></tr> <tr><td>11</td><td>0 %</td></tr> <tr><td>328</td><td>0 %</td></tr> <tr><td>2</td><td>0 %</td></tr> </table> Plus de détails dans taginfo	340	0 %	11	0 %	328	0 %	2	0 %
340	0 %										
11	0 %										
328	0 %										
2	0 %										
plastic	An artificial surface made from plastic, can be used on pitches and playgrounds.		<table border="1"> <tr><td>5 228</td><td>0.01 %</td></tr> <tr><td>3 818</td><td>1.07 %</td></tr> <tr><td>1 403</td><td>0 %</td></tr> <tr><td>7</td><td>0.01 %</td></tr> </table> Plus de détails dans taginfo	5 228	0.01 %	3 818	1.07 %	1 403	0 %	7	0.01 %
5 228	0.01 %										
3 818	1.07 %										
1 403	0 %										
7	0.01 %										
user_defined	All commonly used values according to Taginfo.										

Figure 2 : la clé surface décrit le matériau ou le revêtement de la voie avec des valeurs documentées classées en grandes catégories

4.3 Outils

ArcGIS Pro

ArcGIS Pro est le principal logiciel de système d'information géographique (SIG) de bureau, conçu avec des innovations axées sur l'utilisateur et offrant des outils et capacités inégalées pour soutenir le travail géospatial. ArcGIS Pro offre des capacités complètes pour visualiser, gérer, traiter et analyser les images et les données raster issues de la télédétection. Ces capacités sont étendues dans l'extension ArcGIS Image Analyst qui propose des outils avancés d'analyse d'images pour la télédétection avancée et l'extraction semi-automatisée de caractéristiques. La télédétection extrait des informations significatives à partir d'images en appliquant des techniques de traitement pour identifier et extraire divers types d'informations telles que la santé de la végétation, ou le développement urbain. Les fonctionnalités incluent l'imagerie en perspective, la classification d'images et la reconnaissance de formes, l'apprentissage profond pour la reconnaissance de caractéristiques, la détection de changements entre plusieurs dates, ainsi que l'analyse multidimensionnelle et hyperspectrale (Esri, n.d.). Ainsi, ArcGIS Pro, grâce à ses classifiers (tab.4), permet la télédétection par classification des images PléïadeNéo 6 bandes de juin 2025.

Tableau 4 : classifieurs disponibles dans ArcGIS Pro

Classifieurs ArcGIS Pro			
Classifieur	Type	Points forts	Limites
Maximum Likelihood	Statistique	Méthode classique, bonne pour classes gaussiennes bien séparées	Suppose distribution normale ; sensible au bruit et corrélation de bandes
Support Vector Machine (SVM)	Machine Learning	Excellente généralisation, très bon sur peu d'échantillons, efficace pour zones bâties	Paramétrage du kernel parfois délicat
Random Trees / Random Forest	Machine Learning	Très robuste, gère bruit, corrélations et variables nombreuses (textures, NDVI, etc.)	Peut être un peu plus lent sur grandes scènes
ISO Cluster / K-Means	Non supervisée	Pas besoin d'échantillons	Moins précis ; utile en pré-analyse
Deep Learning (Pixel Classification / Object Detection)	Apprentissage profond	Très puissant si pas de labels et GPU	Nécessite beaucoup de données et préparation spécifique

R dans RStudio

RStudio est un environnement de développement intégré conçu pour supporter plusieurs langages dont R (Posit, n.d.). Il est disponible en versions open source et commerciales. RStudio inclut une console, un éditeur avec coloration syntaxique qui prend en charge l'exécution directe de code, ainsi qu'une variété d'outils robustes pour la création de graphiques, la visualisation de l'historique, le débogage et la gestion de l'espace de travail (Posit, n.d.).

Classification supervisée par Random Forest dans R

Random Forest est une méthode d'apprentissage par ensemble utilisée en *machine learning*, qui fonctionne en construisant plusieurs arbres de décision et en combinant leurs prédictions pour améliorer la précision globale et réduire le surapprentissage (Ozturk, 2023). L'algorithme Random Forest est un algorithme de classification et de régression supervisé qui, comme son nom l'indique, crée aléatoirement une forêt composée de plusieurs arbres. En général, plus il y a d'arbres dans la forêt, plus celle-ci est robuste et plus la précision des résultats est élevée (GeeksforGeeks, 2024). Random Forest peut gérer à la fois des variables numériques et catégorielles, ce qui le rend adapté à diverses tâches d'apprentissage automatique. Il peut être appliqué dans R en utilisant le package randomForest (Ozturk, 2023). La fonction randomForest() permet de classifier les données en spécifiant la variable à prédire en fonction de toutes les autres variables du jeu de données. Le modèle utilise généralement 500 arbres de décision pour effectuer les prédictions, et l'erreur Out-of-Bag (OOB) reflète la précision du modèle basée sur les données non utilisées durant l'entraînement (Statology, 2021).

5 Méthodologie

5.1 Acquisition des données

Les données utilisées dans ce travail sont produites par deux organismes OpenstreetMap pour les données surfaces et la DIT pour les données du cadastre et la future carte master de la couverture du sol.

Couverture du Sol

Depuis 2024, la DIT travaille à une nouvelle carte de la couverture du sol. Le modèle proposé, dénommé "COUVERTURE_DU_SOL_2025_V0.01", repose sur la fusion de sept couches métier issues de la base Oracle de gestion ArcSDE PRDH (modèle Topogéo) dont la fusion des couches et l'attribution initiale des valeurs ont été réalisées par des algorithmes de traitement spatial automatique

1. A.CAD_NATURE_SOL
2. A.CAD_DOMROUTIER_SURFACES_NIVO
3. A.CAD_DOMROUTIER_SURFACES_NIV1
4. A.CAD_DOMROUTIER_SURFACES_NIV_1
5. A.CAD_OBJDS_PISCINE
6. A.CAD_OBJDS_STEP_BASSIN
7. A.CAD_OBJDS_TERRAIN_SPORT

Le modèle étendu présente plusieurs bénéfices opérationnels comme la simplification de la collecte et de la mise à jour des informations, une meilleure interopérabilité avec d'autres systèmes d'information géographique et une capacité d'analyse spatiale enrichie pour les politiques d'aménagement. Cette évolution proposée du modèle de données de couverture du sol représente une avancée significative vers une gestion territoriale optimisée qui adresse à la fois les exigences réglementaires fédérales et aussi les besoins cantonaux spécifiques.

Tableau 5 : champ numérique de la carte de la Couverture du Sol

Attributs		
Nom	Type	Description
OBJECTID	Entier	Champ automatique avec l'identifiant de la base de chaque objet (Attention, ne pas l'utiliser comme identifiant unique permanent)
PROVENANCE	Texte	Provenance de la donnée :- Terrestre (acquis sur la base de relevés terrestres ,chevillière, théodolite,...., à l'exception du niveling géométrique ou de précision)- Digitalisation (acquis par digitalisation sur plan)- GNSS (acquis par observations GNSS uniquement)-Combiné GNSS/terrestre- Photogrammétrie- Nivellement technique et de précision- Autre- Orthophoto (acquis par l'intermédiaire de digitalisation sur orthophoto)
OBJET	Texte	Type d'objet- Cours d'eau - Eau canalisée souterraine - Fleuve - Autre - revêtement dur - Route chemin - Jardin - Autre verte - Eau stagnante - Champ pré - Autre sans végétation - Vigne - Autre boisée - Chemin de fer - Place aviation - Tourbière - Trottoir - Ilot - Gravière décharge - Forêt dense - Roselière - Indéfini - Culture intensive - Lac - Eboulis sable - Ilot latéral - Surface latérale - Chemin - Espace de stationnement - Chaussée - Site propre transport en commun - Ilot circulation - Piste cyclable - Parking - Déchetterie - Pied d'arbre - Piscine privée - Piscine publique - Bassin - Terrain de sport
REVETEMENT	Texte	Type de revêtement précise le revêtement de l'objet - Eau Type.dur - Type.vert - Type.sans végétation - Type.boisé - Ballast - Tourbière - Roselière - Inconnu - Prairie - Béton bitumineux - Pavés - Autre - Béton - Gazon - Terre - Graviers - Arbustes - Grille gazon - Plates-bandes
MUTNUM	Texte	Numéro de mutation
LAST_EDITED_DATE	Date	Date de mise à jour
NIVEAU	Entier	Niveau par rapport au sol

D'après les renseignements disponibles sur le portail SITG: "Dates d'acquisition : 10-18-25 juin 2025

Image satellite Pléiades Néo

Les quatre satellites Pléiades Neo sont des satellites optiques de pointe qui fournissent des produits orthographiques d'une résolution de 0,3 mètre en standard. Placés sur la même orbite, en quadrature, avec un système optimisé et intelligent de répartition des tâches, auxquels s'ajoutent une liaison de communication laser vers les satellites de télécommunications géostationnaires SpaceDataHighway (également connus sous le nom de European Data Relay System, EDRS) et une gestion améliorée des prévisions météorologiques, ils fournissent des images de la plus haute qualité avec une réactivité sans précédent.

Avec une durée de vie prévue de 10 ans, ils garantissent la fourniture d'images d'une résolution de 30 cm jusqu'en 2032 au moins.

En combinant les bandes panchromatiques et multispectrales (tab.6), les images peuvent être visualisées en noir et blanc (résolution de 30 cm), en couleurs naturelles, en fausses couleurs (résolution de 1,2 m) ou sous forme de produit fusionné (image couleur panchromatique) avec la résolution d'une image panchromatique" (Airbus Defence and Space, 2021).

Tableau 6 : tableau explicatif des longueurs d'ondes des bandes spectrales des images Pléiade Néo

Deep Blue	(400-450 nm)	bathymétrie, aérosols atmosphériques
Blue	(450-520 nm)	pénétration eau, sols nus
Green	(530-590 nm)	réflectance végétation
Red	(625-695 nm)	discrimination végétation/sols
Red Edge	(705-745 nm)	stress végétal, chlorophylle
Near Infrared	(770-880 nm)	biomasse, contenu en eau

Modèle Numérique de Hauteur

Le modèle numérique de hauteur (MNH) 2019 est obtenu en soustrayant le MNT du MNS ; il indique ainsi, en mètres, la hauteur des éléments présents sur le terrain — bâtiments, végétation, ponts, et autres objets — pour chaque point du territoire.

Données Open Street Map

Les données peuvent être téléchargées grâce à différents outils liés au projet OSM dont notamment :

- Le site Geofabrik propose des extractions journalières « prêtes à l'emploi » de données OSM découpées par territoire. Elles peuvent être récupérées dans les formats spécifiques à OSM (osm zippé, pbf) ou directement en format Shape.
- Overpass-turbo est un site qui propose une interface graphique multilingue par-dessus l'Overpass API afin d'en faciliter la prise en main par les utilisateurs. Il est possible de les exporter vers des formats de données géographiques (GPX, KML, GeoJSON).

- QuickOSM est une extension (*plugin*) du logiciel libre QGIS. Le téléchargement des données peut être effectué sur l'étendue de la carte affichée dans QGIS, l'emprise d'une des couches ou une entité géographique nommée. Les données téléchargées sont directement intégrées comme de nouvelles couches dans le logiciel.
- Overpass API est une API qui permet d'interroger la base de données OSM depuis des serveurs distants. Elle propose un langage de requête très complet qui permet de sélectionner les données à télécharger selon un grand nombre de critères (tags des objets, types d'objets, localisation géographique, etc.). C'est la méthode utilisée dans RStudio.

(Contributeurs aux projets Wikimedia, 2025)

5.2 Classification non-supervisée dans ArcGIS Pro

5.2.1 Processus général

Le schéma ci-dessous (fig. 3) résume les étapes principales appliquées lors de la classification non-supervisé. Après l'acquisition des images Pléiades Neo, du modèle numérique de hauteur (MNH) et de la couche « Couverture du sol », les données sont d'abord restreintes à la zone d'étude. Un filtrage altimétrique est ensuite appliqué afin de conserver uniquement les éléments dont la hauteur dépasse 40 cm, avant de reclasser ces objets en valeurs NODATA pour éliminer les structures élevées. Une composition en fausse couleur (bandes 6-4-3) est générée pour améliorer la distinction visuelle des surfaces, puis une classification non supervisée (ISO Cluster) est réalisée en cinq classes avec 25 itérations. Le résultat est affiné par un post-traitement visant à supprimer les ombres et à reclassifier les valeurs indésirables. Enfin, la classification est validée par des observations de terrain et l'orthophoto 2024, aboutissant à une cartographie finale des surfaces à revêtement dur.




Figure 3 : processus général de la classification non-supervisée dans ArcGIS Pro

L'ensemble des traitements a été réalisé à l'aide du logiciel ArcGIS Pro 3.3.1 pour identifier et classifier les revêtements durs au sein de la zone d'étude localisée dans la ville de Genève sans supervision dans le but de comprendre et de visualiser les possibilités et les limites de la télédétection pour les revêtements des objets de la couverture du sol. Les étapes méthodologiques sont décrites ci-après.

Définition de la zone d'étude

Des polygones vectoriels des zones d'étude ont été créés et utilisés comme *mask* spatial afin de réduire la taille des données et permettre leur analyse. L'outil *Clip* a permis de découper l'ensemble des couches raster et vectorielles selon ces limites afin de garantir la cohérence spatiale des analyses suivantes.

Sélection des surfaces d'études

Le Modèle Numérique de Hauteur a été exploité afin d'exclure les objets qui dépassaient 0,40 m de hauteur soit la hauteur moyenne d'un banc. Le banc est un objet sélectionné arbitrairement pour décider d'une hauteur minimale à respecter afin d'isoler des revêtements de sols et non d'objets. L'outil Raster *Calculator* a été mobilisé pour appliquer un seuil altimétrique pour permettre de ne conserver que les surfaces considérées comme correspondantes à des revêtements durs potentiels. En sélectionnant $1 > 0.40m$ et $0 > 0.40m$. Puis grâce à l'outil *reclassify*, la valeur zéro a été reclassifiée en NODATA. La figure 4 présente l'extrait d'image Pléiades Neo après application du filtrage altimétrique.



Figure 4 : filtrage altimétrique des objets en hauteur grâce au Modèle Numérique de Hauteur

Classification non-supervisée

Une classification non-supervisée a été effectuée sur les surfaces du raster PléiadeNéo2025 avec les bandes 6, 4 et 3 (fig.5) Cette combinaison des bandes correspond à une composition en fausses couleurs Proche Infrarouge (PIR, 750-900 nm) - Rouge (620-690 nm) - Vert (530-590 nm) (Airbus Defence and Space, 2021). La combinaison 6-4-3 exploite le "saut spectral" entre le rouge et le PIR, caractéristique fondamentale de la végétation (Schuster et al., 2012). Cette composition facilite l'identification visuelle et la classification automatisée des trois classes cibles (Weng et al., 2008).

Classification non supervisée du secteur Gazomètres à Genève




Figure 5 : image fausse couleur 6-4-3 de la zone d'étude

La discrimination fine asphalte-béton reste limitée en raison de leurs signatures spectrales proches liée au vieillissement des matériaux (Herold et al., 2004). Cinq classes et 25 itérations ont été sélectionnées pour représenter la diversité des revêtements durs la plus optimum. Les classes générées automatiquement ont été interprétées et spécifiées à partir de deux sources : (i) l'imagerie aérienne disponible, et (ii) des observations de terrain, réalisées sur site pour vérifier la correspondance réelle des classes. La figure 6 montre cette segmentation en cinq classes distinctes qui met clairement en évidence les principaux types de revêtements dans le périmètre des Gazomètres.

Classification non supervisée du secteur Gazomètres à Genève



Figure 6 : classification non supervisée ISO5 du secteur Gazomètres à 40cm du sol avec ombres

Suppression de la classe « ombre »

La classification supervisée a généré une classe spécifique liée aux zones d'ombre. Cette classe a été retirée afin de ne pas biaiser l'analyse des revêtements. Le nettoyage a été réalisé par reclassement en attribuant la valeur NODATA à la classe des ombres comme peut être observé dans la figure 7 ci-après.



Figure 7 : classification non supervisée ISO5 du secteur Gazomètres à 45cm du sol sans ombres

Classification non supervisée sur l'image Pléiade Néo d'après les objets de la couverture du sol

La zone étudiée ici se situe proche du Lac et majoritairement sur la commune de Choulex. Cette zone a été choisie en place de la zone des gazomètres pour offrir un meilleur nombre d'objets dont les revêtements étaient classés en type.dur autre dur sans toutefois être trop nombreux pour empêcher la bonne lisibilité des résultats. Enfin, c'est une zone suffisamment étendue sans demander des temps de traitement extrêmement longs. Un filtrage thématique a été réalisé sur les données vectorielles disponibles. À l'aide d'une requête attributaire, seules les entités correspondant aux catégories de type « surfaces autre dur » ont été conservées dans une nouvelle couche. Cette nouvelle couche de polygones a servi à appliquer un clip sur le raster issu du filtrage altimétrique des volumes.



Figure 8 : images satellites d'après les polygones de la couverture du sol à 40cm du sol

La classification ISO cluster non supervisée en 5 classes a ensuite été appliquée aux morceaux d'images correspondant aux polygones de la carte de la couverture du sol. Ce test a été effectué afin d'observer si la sélection des objets permettait de diminuer le « bruit » dans l'analyse en ne se concentrant que sur les zones d'intérêt. La figure 9 montre des résultats plutôt probants bien que toujours simplifiés puisque les 5 classes ne représentent pas la totalité des surfaces possibles. Ce test permet également d'observer que les polygones dont le revêtement est autre que dur sont constitués d'une grande variété de surfaces différentes.



Figure 9 : classification non supervisée ISO5 du secteur Cologny sur les images satellites d'après les polygones de la couverture du sol à 40cm du sol

5.2.2 Évaluation critique de l'approche

L'approche de classification non supervisée mise en œuvre dans ArcGIS Pro a permis d'obtenir des résultats assez satisfaisants pour la détection des revêtements après validation visuelle et validation terrain des résultats. L'imagerie Pléiade Néo est une base pertinente pour la discrimination des matériaux de surface du fait de ses 6 bandes spectrales. Mais la présence d'ombres impacte la signature spectrale des pixels et entraîne des confusions dans la classification. L'application d'un seuil altimétrique via le M NH s'est révélée utile pour exclure les objets non pertinents (mobilier urbain, végétation haute, bâtiments), mais la hauteur retenue reste arbitraire.

L'utilisation d'une méthode non supervisée ISO Cluster en 5 classes a l'avantage de ne pas nécessiter d'échantillons d'apprentissage. Mais cette approche repose sur une interprétation a posteriori des classes, ce qui peut introduire une part de subjectivité lors de l'association des clusters à des types de revêtements réels. De plus, les matériaux qui présentent des signatures spectrales proches comme le béton clair et gravier compacté sont souvent regroupés dans une même classe.

5.2.3 Perspectives d'amélioration

Les zones d'ombre sont un facteur de confusion majeur. Malgré leur suppression a posteriori, certaines zones partiellement ombrées conservent une signature spectrale intermédiaire qui peut affecter les résultats. La validation par observation de terrain et comparaison avec des images aériennes a confirmé la pertinence générale des classes identifiées. Mais cette validation reste subjective. Une évaluation quantitative, par exemple via une matrice de confusion ou des indices de précision pourrait permettre d'objectiver la qualité de la classification et de mesurer les taux de confusion entre classes proches.

Pour renforcer la robustesse de l'approche, plusieurs pistes peuvent être envisagées comme multiplier les indices spectraux NDVI, NDBI, etc. afin d'améliorer la discrimination entre surfaces minérales et végétales. Enfin, les images satellite Pléiade Néo présentent une limitation du fait d'occlusions causées par les bâtiments et autres structures verticales. Ce qui empêche l'observation des zones masquées par les bâtiments.

5.3 Classification supervisée Random Forest sur la commune de Carouge

Carouge est une commune fortement construite et traversée par l'Arve avec une présence limitée d'espaces agricoles ou forestiers. Cette zone rassemble au moins une fois chaque objet de la couverture du sol ainsi que la presque totalité des revêtements. Enfin, c'est une zone suffisamment étendue pour permettre un nombre important d'échantillons pour la classification supervisée sans toutefois demander des temps de traitement extrêmement longs.

Une classification supervisée des images satellitaires Pléiade Néo avec apprentissage automatique Random Forest et généralisation objets-basée a été appliquée avec le langage R dans RStudio. La méthodologie a tenté de télédéetecter automatiquement les revêtements de sols et de les généraliser aux polygones de la Couverture des sols avec un niveau de confiance contrôlé ($\geq 80\%$).

5.3.1 Processus général

Le schéma ci-dessous (fig. 10) résume les étapes principales appliquées lors de la classification supervisée par Random Forest qui permet de cartographier automatiquement l'occupation du sol à partir de l'image satellite Pléiades Néo. La méthode s'articule en sept étapes dans RStudio. D'abord, les données sources sont préparées et alignées géométriquement. Ensuite, les zones d'entraînement des sept classes sont sélectionnées manuellement. Elles permettent d'extraire près de 20 000 pixels avec leurs signatures spectrales. Ces données servent à entraîner un modèle Random Forest composé de 500 arbres de décision. Le modèle est alors appliqué à toute l'image pour produire une classification pixel par pixel. Une généralisation aux polygones de la carte de la couverture du sol est effectuée d'après sa classe majoritaire de plus de 80%. Cette approche permet de classer 650 polygones soit 31%. Les polygones restants sont complétés grâce aux données OpenStreetMap. Enfin, les résultats sont validés et exportés.




Figure 10 : processus général de la classification supervisée random forest dans RStudio

5.3.2 Analyse des Résultats de Classification Supervisée Pléiades Neo

Données et prétraitements

Image Satellite RGB

L'image Pléiades Neo (fig.11) en composition colorée naturelle (bandes Rouge-Vert-Bleu) présente la zone d'étude de Carouge découpée d'après les polygones de la carte de la couverture du sol avec une résolution spatiale de 30 cm. Les différentes typologies y sont observables distinctement. La bonne qualité radiométrique de l'image sera ensuite une plus-value dans la discrimination des surfaces artificielles des surfaces naturelles.



Figure 11 : image satellite de la zone d'étude de Carouge en RGB

Composition Infrarouge

La composition en fausse couleurs NIR-Rouge-Vert de la figure 12 révèle l'activité photosynthétique de la végétation en rouge. Cette visualisation met en évidence le contraste entre les surfaces végétalisées et les surfaces minérales. On note particulièrement les bords de l'Arve en rouge et les espaces verts urbains dispersés dans le tissu bâti. Les surfaces en eau apparaissent en bleu.



Figure 12 : image satellite de la zone d'étude de Carouge IRC

Zones d'Entraînement

Les polygones d'entraînement visible sur la figure 13 sont distribués sur l'ensemble de la zone d'étude. Chaque classe (Arboré, Béton, Bitume, Eau, Herbe, Pierre, Terre) est représentée par plusieurs zones de l'images satellites afin de garantir la diversité spectrale intra-classe. La distribution des zones d'entraînement (les petits polygones noirs disséminés sur tout l'image RGB) montre la multiplicité des échantillons sur le terrain.




Figure 13 : polygones d'entraînement des 7 classes sur la commune de Carouge

Distribution des Valeurs Spectrales par Bande

Les six histogrammes de la Figure 14 montrent la distribution statistique des valeurs de réflectance pour l'ensemble des pixels d'entraînement (19 871 pixels) à travers chaque bande spectrale Pléiades Neo. Cette analyse permet de comprendre la signature radiométrique composite de l'image satellite de Carouge.

Bandé rouge

La bimodalité de la bande rouge caractérise la dichotomie végétation/surfaces artificielles. Le pic gauche (500-800) correspond aux surfaces qui absorbent fortement dans le rouge soit la végétation photosynthétiquement active et les surfaces sombres. Le pic droit quant à lui (1200-1500) représente les surfaces réfléchissantes comme le béton clair, la pierre calcaire, les toitures claires ou les sols nus secs. Cette distribution démontre l'hétérogénéité radiométrique du milieu urbain composé de surfaces absorbantes et surfaces réfléchissantes.

Bandé verte

Le vert présente une distribution plus étalée que le rouge avec trois pics. Le pic de gauche montre la végétation dont l'absorption chlorophyllienne moins prononcée qu'en rouge, donne un "pic vert" de réflectance. Le pic central dominant des surfaces urbaines diverses comme le béton, l'asphalte vieilli ou toitures composites. Et enfin le troisième pic à droite qui concerne les surfaces très claires. La position intermédiaire du pic principal (1000-1200) illustre que le vert capture une réflectance moyenne caractéristique des matériaux urbains courants.

Bandé bleue

La concentration dans les valeurs basses de la bande bleue s'explique par : une faible réflectance des surfaces urbaines car la plupart des matériaux peu dans le bleu et la pénétration dans l'eau car le bleu pénètre plus profondément dans l'eau ce qui réduit la réflectance de surface. Le pic dominant autour de 0-200 indique que la majorité des surfaces urbaines sont optiquement sombres dans le bleu.

Bandé NIR

La distribution de la bande souligne le contraste végétation/non-végétation le plus marqué. Le pic principal (0-500) correspond aux surfaces non-végétalisées qui ont une faible réflectance NIR par absence de structure cellulaire réfléchissante. La queue étendue (2000-6000) concerne la végétation active qui a une réflectance NIR très élevée du fait de sa structure cellulaire des feuilles et les valeurs maximales (4000-6000) correspondent à une végétation dense, saine et stratifiée comme la canopée. Enfin, la zone intermédiaire (500-2000) reflète une végétation épars ou stressée. Cette distribution démontre que le NIR est bien la bande la plus discriminante pour séparer végétation et surfaces artificielles.

Bandé red edge

Interprétation physique : La Red Edge se situe dans la zone de transition spectrale entre le rouge et le NIR. Le pic de gauche (500-1000) concerne les surfaces non-végétalisées et la végétation stressée alors que le pic droit (1500-3000) concerne la végétation active. Cette bande permet de

discriminer les types de végétation et d'évaluer la santé végétale. Elle apporte donc une information complémentaire sans être aussi discriminante que le rouge ou le NIR.

Bandes bleu et bleu profond

On lit ici une concentration extrême dans les très basses valeurs du fait de l'absorption généralisée puisque la plupart des surfaces naturelles et artificielles absorbent fortement dans le bleu profond. Ainsi, seules les surfaces exceptionnellement claires réfléchissent significativement. Le pic massif entre 0 et 200 indique que dans un contexte urbain, le Deep Blue apporte surtout une information sur les conditions atmosphériques et les ombres.

Contraste Inter-Bandes

La bande NIR avec son histogramme entre 0-6000 est la plus variable et la bande Deep Blue avec son histogramme entre 0-2000 est la moins variable. Cette gradation démontre que la bande infrarouge est la plus essentielle pour discriminer les surfaces en milieu urbain.

Implications pour la Classification

Les bandes de végétation (NIR, Red Edge, Red) avec leur distribution bimodale marquées permettent une bonne séparation végétation et non-végétation avec une haute capacité discriminante. La bande verte avec sa distribution trimodale renseigne la diversité des surfaces artificielles. Quant aux bandes bleue et bleu profond, bien que leur distribution soit concentrée, elles renseignent sur les ombres et l'eau.

Validité de l'Échantillonnage

La continuité des distributions montre que l'échantillonnage d'entraînement couvre bien l'espace spectral de la zone d'étude. Les 19 871 pixels d'entraînement représentent la diversité radiométrique de l'image satellite de Carouge.




Figure 14 : histogramme de la distribution des pixels d'entraînement par bande spectrale

Distribution des Pixels par Classe d'Entraînement

L'échantillonnage présente une répartition déséquilibrée mais représentative (fig.15). Cette distribution reflète la surreprésentation des différentes surfaces dans la zone urbaine étudiée dont l'Herbe qui a la classe dominante avec environ 8200 pixels et la terre qui est la classe la plus basse avec 250 pixels. Ce qui est représentatif de la création des classes d'entraînement car la classe terre est plus difficile à détecter sur des images satellite et même sur orthophoto et se confond facilement avec d'autres types de surfaces. De plus, c'est une classe parfois « éphémère » comme dans le cas de jardin en cours de plantation ou de pelouses abîmées. Cependant, le déséquilibre est géré par l'algorithme Random Forest qui pondère automatiquement les classes.




Figure 15 : nombre de pixels par classe d'entraînement de l'image satellite de Carouge

Signatures Spectrales par Classe

Les boxplots (fig.16) révèlent la « séparabilité » spectrale des classes. La végétation soit l'herbe et l'arboré ont une faible réflectance dans le rouge du fait de l'absorption chlorophyllienne) mais une forte réflectance dans le NIR. L'arboré présente une réflectance NIR légèrement supérieure à l'Herbe. Les surfaces artificielles telles que le béton le bitume ou la pierre dans des *ranges* proches. Cependant le bitume a réflectance plus faible dans plusieurs bandes grâce à sa surface sombre. Le béton a une réflectance moyenne à élevée avec augmentation progressive du bleu au NIR et la pierre la réflectance la plus élevée des trois. L'eau a une réflectance très faible dans toutes les bandes quoique légèrement supérieure dans le bleu et la terre une réflectance moyenne avec augmentation vers le rouge et NIR




Figure 16 : signature spectrale des classes pour chaque bande de l'image satellite de Carouge

La Figure 16 montre donc que les signatures spectrales observées correspondent bien aux principes de base de la télédétection : la végétation absorbe dans le visible et réfléchit fortement dans le NIR, tandis que les matériaux urbains suivent un gradient lié à leur couleur et leur état. Les six bandes Pléiades Neo sont complémentaires, avec le Red et le NIR offrant la meilleure séparation entre classes. Les boxplots montrent quelles classes sont très fiables et lesquelles autres demandent plus de vérifications. Au final, la classification repose sur des signatures plutôt claires.

Performances du modèle Random Forest

L'analyse de l'importance (fig.17) révèle la contribution de chaque bande. Le MeanDecreaseAccuracy est l'impact sur la précision et le MeanDecreaseGini concerne la pureté des nœuds. La bande rouge se révèle la plus discriminante pour séparer les classes, suivie du NIR crucial pour identifier la végétation. La complémentarité des six bandes assure une classification robuste.

Importance des bandes Pléiades Neo




Figure 17 : analyse de l'importance de chaque bande Pléiade Néo

Convergence de l'Erreur OOB

La courbe d'erreur Out-Of-Bag (fig.18) montre une convergence rapide après environ 100 arbres, se stabilisant à 1,64%. Cette faible erreur témoigne d'un apprentissage optimal avec 500 arbres. L'absence d'oscillations en fin de courbe confirme que le modèle n'est pas en surajustement.




Figure 18 : courbe d'erreur Out-of-bag

5.3.3 Classification pixel basée

La comparaison de l'image RGB originale et de la classification (fig.19) permet de valider visuellement la cohérence de l'analyse. Les espaces verts sont correctement identifiés, le réseau hydrographique est bien délimité. Les infrastructures routières sont fidèlement représentées et les zones bâties montrent une mosaïque réaliste de matériaux différents.

La classification complète pixel par pixel met quant à elle bien en évidence la diversité de l'occupation du sol urbain. L'Herbe, en beige clair est largement présente dans les différents espaces verts tandis que l'Arboré, en rouge, se situe surtout le long de l'Arve et dans les grands parcs. Le Béton, en vert clair, correspond aux toitures claires et aux parkings et le Bitume, en vert foncé, représente le réseau routier. La Pierre, en bleu foncé, semble renvoyer aux toitures en tuiles et aux surfaces minérales claires, alors que l'Eau, en cyan, suit l'Arve et les zones aquatiques. La Terre, en magenta, n'apparaît que sur quelques surfaces nues. L'ensemble montre une bonne lecture de l'hétérogénéité spatiale à 30 cm, même si un léger effet « sel-poivre » reste visible.




Figure 19 : juxtaposition de l'image RGB originale et de la classification

5.3.4 Généralisation aux polygones

Distribution des pourcentages de classe majoritaire et justification du seuil de classification

L'histogramme de distribution des pourcentages de classe majoritaire par polygone (Figure 20) révèle une structure bimodale caractéristique de l'hétérogénéité du tissu urbain. Un pic majeur se situe à 100% de pureté, représentant environ 230 polygones parfaitement homogènes, tandis qu'une distribution étalée entre 30% et 75% caractérise les espaces mixtes combinant plusieurs types d'occupation du sol. Le seuil de classification retenu à 80%, matérialisé par une ligne rouge verticale, constitue un compromis méthodologique entre exhaustivité et fiabilité. Ce seuil permet d'isoler les polygones présentant une dominance claire d'une classe unique, garantissant ainsi une attribution robuste, tout en excluant les zones trop hétérogènes dont la classification univoque serait artificiellement réductrice. Cette approche conservatrice reconnaît explicitement que certains espaces urbains, par leur nature intrinsèquement composite, nécessitent une représentation multi-classe plutôt qu'une simplification catégorielle qui pourrait induire des erreurs d'interprétation dans les analyses ultérieures.




Figure 20 : l'histogramme de distribution des pourcentages de classe majoritaire par polygone

Répartition spatiale des polygones classifiés et identification des typologies urbaines homogènes

La cartographie des polygones classifiés (Figure 21) met en évidence une dichotomie spatiale nette entre les 650 polygones classifiés en couleur, représentant 31,2% du total, et les 1 430 polygones non classifiés en gris, constituant 68,8% de l'ensemble cadastral. L'analyse de la distribution spatiale des polygones classifiés révèle qu'ils se concentrent dans des typologies

urbaines spécifiques caractérisées par leur uniformité fonctionnelle et matérielle. Les grands espaces verts publics tels que les parcs, les infrastructures de transport comme les parkings et les axes routiers continus, les grandes emprises bâties aux toitures uniformes, ainsi que les surfaces hydrographiques présentent une homogénéité suffisante pour satisfaire au critère des 80%. À l'inverse, les polygones non classifiés correspondent majoritairement aux parcelles résidentielles où coexistent végétation et bâti, aux zones de transition entre différentes affectations du sol, ainsi qu'aux petits polygones pour lesquels l'effet de bord introduit une mixité spectrale artificielle liée à la résolution spatiale du capteur. Cette partition spatiale témoigne donc moins d'une défaillance méthodologique que d'une représentation fidèle de l'hétérogénéité intrinsèque du paysage urbain, où seules certaines configurations spatiales se prêtent à une classification univoque sans perte d'information.




Figure 21 : cartographie des polygones classifiés

Synthèse statistique

Distribution finale des classes et prédominance des surfaces arborées

L'analyse statistique des 650 polygones ayant satisfait au critère de classification révèle une distribution fortement déséquilibrée en faveur de la classe Arboré, qui représente 500 polygones soit 76,9% de l'ensemble classifié (Figure 22). Cette dominance écrasante contraste avec les six autres classes dont les effectifs demeurent modestes : le Béton compte 115 polygones représentant 17,7% du total, tandis que Terre, Pierre, Bitume, Herbe et Eau ne totalisent ensemble que 5,4% avec respectivement 40, 38, 18, 15 et 4 polygones. Cette répartition s'explique par

deux facteurs concomitants. D'une part, elle reflète la composition réelle de la zone d'étude de Carouge, caractérisée par une végétation arborée abondante dans les parcs, les alignements d'arbres et les espaces verts publics. D'autre part, elle illustre un biais de sélection inhérent à la méthode : les surfaces arborées forment naturellement des étendues homogènes continues répondant plus facilement au critère des 80%, contrairement aux surfaces minérales urbaines qui se présentent fréquemment sous forme de mosaïques hétérogènes mêlant différents matériaux. La prédominance de l'Arboré dans les résultats ne signifie donc pas nécessairement sa prédominance surfacique absolue sur le territoire, mais plutôt sa plus grande propension à former des unités spatiales homogènes détectables par classification supervisée.




Figure 22 : distribution des polygones de la couverture du sol par revêtement

Validation de la cohérence méthodologique par les indices de pureté

L'analyse des statistiques détaillées par classe (Figure 23) confirme la robustesse du protocole de classification adopté. Le graphique illustrant le pourcentage moyen de pureté démontre que l'ensemble des sept classes présentent des valeurs comprises entre 87% et 90%, avec des variations inter-classes inférieures à 5%. Cette homogénéité remarquable des indices de pureté, malgré les différences substantielles d'effectifs entre classes, valide empiriquement la pertinence du seuil fixé à 80%. En effet, l'absence d'écart significatif entre la classe Arboré dominante et les classes minoritaires comme Eau ou Terre indique que le critère de classification ne favorise aucune classe particulière mais applique un standard de qualité uniforme. Les pourcentages moyens systématiquement supérieurs au seuil de 80%, avec une marge de 7 à 10 points, témoignent d'une application conservatrice du critère évitant les cas limites ambigus. Cette convergence des indicateurs de pureté autour de 88-89% suggère l'existence d'une limite naturelle de l'homogénéité spatiale en contexte urbain, au-delà de laquelle même les espaces les plus uniformes présentent une variabilité résiduelle de 10-12% liée aux effets de bord, aux ombres portées ou à la microvariabilité des matériaux.




Figure 23 : l'analyse des statistiques détaillées par classe

5.4 Résultat classification supervisée

La classification supervisée atteint une précision de 98,36% à l'échelle pixel, mais cette performance ne garantit pas la correspondance avec les revêtements réels au sol. Les images satellites Pléiades Neo captent la surface visible et non nécessairement le revêtement effectif (fig.24). Par exemple, les arbres masquent les surfaces sous leur canopée, ce qui conduit à classifier de l'herbe ou de l'arboré là où se trouvent des parkings, des chemins ou des terrasses. Un autre exemple sont les chantiers en cours qui présentent des surfaces temporaires qui ne correspondent pas au revêtement final. En effet, les zones en transition entre deux états (démolition, construction, rénovation) peuvent générer des signatures spectrales alors ambiguës. Les objets verticaux comme les bâtiments créent des occlusions qui empêchent l'observation des cours intérieures, des allées latérales ou des espaces entre constructions. La classification détecte ce qui est visible dans l'image, non ce qui existe au sol.



Figure 24 : polygone de la couverture du sol dont la détection est arborée

Résultats enrichissement par données OpenStreetMap

L'intersection spatiale entre les polygones OpenStreetMap et ceux de la couverture du sol présente des incohérences géométriques (fig.25). Les données OSM sont structurées en lignes pour les voies de circulation, avec un attribut de revêtement qui décrit la surface linéaire, tandis que la couverture du sol utilise des polygones surfaciques. L'intersection d'une ligne OSM avec un polygone de couverture du sol ne garantit pas que le revêtement de la ligne corresponde au revêtement dominant du polygone. Un chemin en gravier qui traverse un parc herbeux peut conduire à attribuer "gravier" à tout le polygone du parc. Les décalages planimétriques entre les référentiels géométriques OSM et cadastraux génèrent des intersections avec des polygones adjacents parfois non pertinentes. La granularité des données OSM ne correspond pas à celle de la couverture du sol : une rue peut avoir plusieurs revêtements (chaussée bitumineuse, trottoirs béton, pistes cyclables pavées) alors que OSM n'en renseigne qu'un seul. La méthode de sélection par aire maximale d'intersection introduit donc un biais lorsque plusieurs entités OSM se chevauchent ou lorsque les géométries sont imprécises.

FID	OBJET	REVETEM	Porcntg	Ttl_pxl	Clss_mj	revetement OSM
55	Autre verte	Type.vert	57,92	877	Terre	concrete
398	Autre revêtement dur	Type.dur	58,61	3750	Terre	concrete
418	Autre revêtement dur	Type.dur	55,56	27	Pierre	concrete
488	Autre revêtement dur	Type.dur	54,16	613	Arboré	concrete
757	Jardin	Type.vert	45,13	113	Arboré	concrete
758	Jardin	Type.vert	40,27	2297	Arboré	concrete
759	Jardin	Type.vert	73,18	302	Arboré	concrete
818	Autre revêtement dur	Type.dur	42,62	854	Pierre	concrete
952	Jardin	Type.vert	53,95	8017	Arboré	concrete
1049	Eau stagnante	Eau	49,57	1396	Béton	concrete
1051	Jardin	Type.vert	54,98	7877	Arboré	concrete
1052	Autre revêtement dur	Type.dur	27,78	36	Arboré	concrete
1097	Autre revêtement dur	Type.dur	45,96	1793	Arboré	concrete
1100	Autre revêtement dur	Type.dur	27,6	3569	Pierre	concrete
1114	Jardin	Type.vert	41,73	1088	Herbe	concrete
1115	Jardin	Type.vert	34,96	698	Arboré	concrete
1128	Jardin	Type.vert	56,35	2495	Arboré	concrete
1130	Autre revêtement dur	Type.dur	49,27	4498	Béton	concrete



Figure 25 : incohérences géométriques entre OpenStreetMap et la couverture du sol

5.4.1 Conclusion Random Forest

La classification supervisée sur l'imagerie Pléiades Neo de Carouge atteint une précision de 98,36% à l'échelle du pixel, avec une erreur Out-Of-Bag de 1,64%. Ces résultats s'expliquent par la séparabilité spectrale des sept classes d'occupation du sol dans l'espace formé par les six bandes spectrales de Pléiades Neo, du bleu profond au proche infrarouge. La complémentarité de ces bandes permet une discrimination entre surfaces végétalisées, surfaces minérales et surfaces hydrographiques.

Le passage de l'échelle pixel vers l'échelle objet révèle les limites de toute classification en milieu urbain hétérogène. L'approche fondée sur un seuil de pureté de 80% garantit une fiabilité des attributions au prix d'une couverture spatiale de 31,2% des polygones cadastraux. Cette limitation constitue un choix scientifique qui priviliege la qualité à l'exhaustivité.

La dominance des surfaces arborées parmi les polygones classifiés, représentant 77% du total, reflète le caractère semi-végétalisé de Carouge et la propension de la végétation à former des ensembles homogènes classifiables. Les 68,8% de polygones non classifiés ne constituent pas un échec mais une reconnaissance de la diversité du tissu urbain. Cette situation suggère l'intérêt de méthodes complémentaires : classification orientée-objet, intégration de données auxiliaires ou approches multi-échelles pour caractériser l'occupation du sol.

6 Limites

OpenStreetMap est une base de données collaborative dont la complétude et la précision varient spatialement (Haklay, 2010 ; Barrington-Leigh & Millard-Ball, 2017). La qualité de l'enrichissement dépend donc directement de l'activité contributive dans la zone d'étude. Plusieurs études ont démontré que la qualité des données OSM est généralement comparable aux données officielles dans les zones urbaines des pays développés (Girres & Touya, 2010 ; Zielstra & Zipf, 2010), mais peut présenter des lacunes significatives dans d'autres contextes géographiques.

Le principe de sélection par aire maximale suppose une homogénéité du revêtement au sein de chaque polygone source. Dans les cas de polygones hétérogènes, cette approche peut introduire un biais de simplification. Des méthodes alternatives comme l'agrégation pondérée par surface ou l'analyse multicritères, pourraient être envisagées pour améliorer la représentativité de l'attribution dans les contextes complexes (Goodchild & Li, 2012).

Les taxonomies de classification des surfaces peuvent différer entre le jeu de données source et OpenStreetMap, ce qui pourraient potentiellement nécessiter une table de correspondance pour harmoniser les nomenclatures (Jokar Arsanjani et al., 2015). L'intégration de données hétérogènes demande une attention particulière aux questions d'interopérabilité sémantique (Kuhn, 2005).

7 Pistes et recommandation

Les images satellite Pléiade Néo présentent une limitation du fait d'absences de visibilité causées par les bâtiments qui empêchent l'observation des zones masquées. Une piste serait d'utiliser les images *true ortho*. Les orthophotos standard présentent des zones cachées (occlusions) derrière les bâtiments. Les *true ortho* combleraient ces zones masquées en utilisant plusieurs clichés sous différents angles. On sélectionnerait alors, pour chaque zone cachée, le meilleur cliché oblique où le sol est visible. L'assemblage des clichés permettrait de produire une image composite sans zones masquées.

Une autre piste serait de s'inspirer du travail de l'AlphaEarth Foundations. L'AEF est une nouvelle intelligence artificielle développée pour créer des cartes détaillées de notre planète à partir d'images satellites (Brown et al., 2025). Cette nouvelle technologie a la capacité de fonctionner avec peu d'images annotées manuellement. Le modèle fonctionne en créant ce qu'on appelle un "champ d'embedding", une sorte de représentation numérique condensée qui capture l'essence de chaque endroit sur Terre en combinant des informations spatiales (où c'est situé), temporelles (quand l'image a été prise) et instrumentales (quel type de capteur a été utilisé) de sources multiples (Brown et al., 2025). Cette approche permet à AEF de surpasser les autres méthodes testées, en réduisant les erreurs d'environ 24% en moyenne, sans avoir besoin d'être réentraîné pour chaque nouvelle tâche cartographique (Google DeepMind, 2025).

Pour le canton de Genève, cette technologie pourrait fortement aider la détection des surfaces. Cela signifie qu'il n'y aurait pas besoin d'envoyer des équipes sur le terrain pour photographier et identifier manuellement des milliers d'échantillons de chaque type de revêtement à travers tout le canton. Quelques centaines d'exemples pourraient suffire pour qu'AEF apprenne à reconnaître et classifier automatiquement tous les revêtements du territoire.

Un autre moyen d'AEF serait de combiner différentes sources de données satellites. Le système peut intégrer simultanément des Pléiade Néo, des données d'altitude LiDAR même du texte géolocalisé extrait d'internet (Brown et al., 2025). Ces apports multiples permettraient de distinguer des surfaces qui se ressemblent visuellement mais qui ont des propriétés différentes. Par exemple, un parking en asphalte et une route pavée peuvent avoir des couleurs similaires sur une photo mais leurs signatures radar et leurs textures fines permettraient à AEF de les différencier.

La dimension temporelle d'AEF représente également un avantage significatif pour Genève (Brown et al., 2025). Le système peut créer des représentations continues dans le temps, même quand les satellites ne peuvent pas prendre de photos à cause des nuages ou d'interruptions techniques. Cette fonctionnalité permet de suivre l'évolution des revêtements au fil des années et aider à identifier comment le canton se transforme en identifiant les nouvelles zones bétonnées qui contribuent à l'imperméabilisation des sols par exemple.

8 Conclusion et discussion

Ce travail a exploré trois approches complémentaires pour la détection et la classification automatisée des revêtements de sol à partir d'imagerie satellitaire Pléiades Neo : la classification non supervisée ISO Cluster, la classification supervisée par Random Forest et l'enrichissement par données collaboratives OpenStreetMap. Chaque méthode présente des avantages et des limites qui méritent d'être discutés dans le contexte opérationnel de la DIT.

La classification non supervisée ISO Cluster a permis de segmenter rapidement l'espace spectral sans demander d'échantillons d'apprentissage préalables. Cette approche s'est révélée particulièrement utile en phase exploratoire pour identifier les grandes catégories de revêtements présentes sur le territoire. Le filtrage altimétrique par MNH à 40 cm s'est avéré pertinent pour isoler les surfaces au sol des objets en élévation même si ce seuil reste arbitraire et pourrait être affiné selon les typologies d'objets urbains. Plusieurs limites structurelles ont été identifiées. Premièrement, la sensibilité aux ombres car les zones ombrées ont des signatures spectrales qui perturbent la classification et ce malgré la suppression de la classe « ombre ». Deuxièmement, l'approche non supervisée ne permet pas non plus de distinguer finement les matériaux qui ont des signatures spectrales proches. L'interprétation a posteriori des classes introduit une subjectivité qui limite la reproductibilité.

La classification supervisée Random Forest présente de bonnes performances à l'échelle pixel, avec une précision globale de 98,36 % et une erreur Out-of-Bag de 1,64 % sur la zone test de Carouge. Ces résultats confirment la pertinence de l'algorithme pour discriminer des classes spectralement distinctes. L'analyse de l'importance des bandes montre l'importante du rouge et du proche infrarouge. L'apport des six bandes Pléiades Neo, dont le bleu profond, constitue un avantage important. Le passage de l'échelle pixel à l'échelle objet a tout de même des limites dans un environnement urbain très diversifié. Le seuil de consensus de 80 % n'a permis de classifier que 31,2 % des polygones de la couverture du sol, ce qui reflète la diversité spatiale du tissu urbain. Les 68,8 % de polygones non classifiés concernent principalement les zones résidentielles composites, les zones de transition et les petits polygones affectés par les effets de bord. La forte proportion de polygones arborés classifiés (76,9 %) s'explique par leur homogénéité naturelle et leur présence importante à Carouge.

L'intégration des données OpenStreetMap constitue une piste pour compléter les lacunes de la télédétection. La qualité des données OSM en Suisse est généralement élevée, mais variable selon les secteurs. L'approche fondée sur l'intersection spatiale et la sélection de la plus grande surface de chevauchement offre une solution pragmatique pour enrichir automatiquement les polygones non classifiés.

Les résultats montrent qu'une automatisation partielle de la mise à jour de la couverture du sol est réaliste. Une stratégie hybride apparaît la plus adaptée. La première composante repose sur la classification automatisée pour les surfaces homogènes de grande taille. La seconde composante consisterait en un enrichissement semi-automatique basé sur OSM pour les zones bien documentées, accompagné d'une validation ciblée.

Les données visuelles « manquante » sous les immeubles ou sous les arbres restent un problème majeur pour les images Pléiades Neo, même à 30 cm de résolution. Les conditions d'acquisition influencent les performances. Des séries temporelles amélioreraient la discrimination des classes.

L'ajout d'indices spectraux, l'intégration de descripteurs de texture ou d'informations contextuelles pourrait améliorer la performance de la classification. La fusion de données multi-sources comme le LiDAR, l'imagerie oblique ou radar ouvre des perspectives intéressantes. Les méthodes d'apprentissage profond, en particulier les modèles pré-entraînés comme AlphaEarth Foundations, pourraient accroître la performance et réduire les besoins en données d'entraînement.

9 Réflexions sur le déroulement du stage

Le stage s'est déroulé dans de très bonnes conditions. L'encadrement comprenait notamment un suivi hebdomadaire qui a permis d'échanger sur l'avancement des travaux et d'ajuster les orientations. L'équipe de la DIT comprend les compétences techniques nécessaires et s'est montrée disponible pour répondre aux questions. Une présentation du service et une mise en relation avec les collaborateurs a facilité mon intégration. Le poste de travail était bien équipé et l'espace de travail était confortable. Cependant, les protocoles de sécurité informatique de l'administration ont restreint l'accès à certains logiciels, notamment RStudio, ce qui a nécessité des adaptations soit l'utilisation du matériel disponible à la salle informatique de l'université Carl Vogt. Mes compétences limitées en FME, liées aux choix de cours effectués durant le certificat de géomatique, ne m'ont pas permis de tester certaines approches méthodologiques ce qui peut être un point négatif.

Mes compétences en ArcGIS et dans Rstudio ont répondu aux exigences du stage. La maîtrise de ces outils a permis de mener à bien les analyses requises. Le recours aux assistants d'intelligence artificielle (ChatGPT, Claude) pour le développement de scripts R a également permis d'accélérer l'apprentissage et de résoudre les problèmes techniques. Le manque de compétences en FME a constitué, pour moi, une lacune. Ce logiciel m'aurait offert des approches complémentaires pour certains traitements. Cette place de stage convient aux personnes qui maîtrisent ArcGIS et possèdent des bases en programmation R, qui souhaitent approfondir leurs compétences analytiques en géomatique et qui apprécient l'autonomie dans la réflexion. Ce stage a nécessité une démarche analytique plutôt approfondie et s'est moins situé dans de l'exécution de process.

Améliorations possibles

Une négociation avec le service informatique pourrait permettre une installation plus souple de logiciels open source comme RStudio. Une formation d'introduction à FME en début de stage élargirait la palette d'outils disponibles. Des échanges plannifiés avec d'autres services qui travailleraient sur des thématiques connexes aurait pu encore développer la recherche.

Conclusion

Ce stage m'a permis de consolider mes compétences techniques et de développer une approche méthodologique rigoureuse : réflexion sur les problématiques, recherche documentaire, maîtrise des outils d'analyse, interprétation des résultats.

Le stage a révélé le potentiel futur d'approches comme l'application du *machine learning* comme le *random forest* dans la détection des sols. Cette piste pourraient être explorée dans une recherche plus approfondie des explorations de mon stage.

Références

- Airbus Defence and Space. (2021). *Pléiades Neo technical sheet*. <https://www.intelligence-airbusds.com>
- Barrington-Leigh, C., & Millard-Ball, A. (2017). The world's user-generated road map is more than 80% complete. *PLOS ONE*, 12(8), Article e0180698. <https://doi.org/10.1371/journal.pone.0180698>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Brown, C. F., Kazmierski, M. R., Pasquarella, V. J., Pickens, A. H., Diao, C., Dhanani, S., Poortinga, A., Hu, K. T., Chishtie, F., Saah, D., Kumar, R. K., Hambrecht, K., Moore, R., Lakhchaura, N., Kumar, U., Friedl, M. A., Elmes, A., Hancher, M., & Gorelick, N. (2025). *AlphaEarth Foundations: An embedding field model for accurate and efficient global mapping from sparse label data*. arXiv. <https://arxiv.org/abs/2507.22291>
- GeeksforGeeks. (2024, 16 septembre). *Random forest approach for classification in R programming*. <https://www.geeksforgeeks.org/random-forest-approach-for-classification-in-r-programming/>
- Girres, J. F., & Touya, G. (2010). Quality assessment of the French OpenStreetMap dataset. *Transactions in GIS*, 14(4), 435–459. <https://doi.org/10.1111/j.1467-9671.2010.01203.x>
- Goodchild, M. F., & Li, L. (2012). Assuring the quality of volunteered geographic information. *Spatial Statistics*, 1, 110–120. <https://doi.org/10.1016/j.spasta.2012.03.002>
- Google DeepMind. (2025). *AlphaEarth Foundations helps map our planet in unprecedented detail*. <https://deepmind.google/blog/alphaearth-foundations-helps-map-our-planet-in-unprecedented-detail/>
- Haklay, M. (2010). How good is volunteered geographical information? A comparative study of OpenStreetMap and Ordnance Survey datasets. *Environment and Planning B: Planning and Design*, 37(4), 682–703. <https://doi.org/10.1068/b35097>
- Herold, M., Roberts, D. A., Gardner, M. E., & Dennison, P. E. (2004). Spectrometry for urban area remote sensing—Development and analysis of a spectral library from 350 to 2400 nm. *Remote Sensing of Environment*, 91(3–4), 304–319. <https://doi.org/10.1016/j.rse.2004.03.013>
- Jokar Arsanjani, J., Zipf, A., Mooney, P., & Helbich, M. (Éds.). (2015). *OpenStreetMap in GIScience: Experiences, research, and applications*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-14280-7>
- Kuhn, W. (2005). Geospatial semantics: Why, of what, and how? Dans *Journal on Data Semantics III* (p. 1–24). Springer. https://doi.org/10.1007/11496168_1
- OGC. (2011). *OpenGIS implementation standard for geographic information – Simple feature access – Part 1: Common architecture* (Version 1.2.1). Open Geospatial Consortium.

Olbricht, R. (2015). Data retrieval for small spatial regions in OpenStreetMap. Dans J. Jokar Arsanjani, A. Zipf, P. Mooney, & M. Helbich (Éds.), *OpenStreetMap in GIScience* (p. 101–122). Springer. https://doi.org/10.1007/978-3-319-14280-7_6

Ozturk, F. E. (2023, 30 décembre). *Supervised learning in R: Random forest*. Medium. <https://medium.com/@ozturkfemre/supervised-learning-in-r-random-forest-c947fe3b01ab>

Pebesma, E. (2018). Simple Features for R: Standardized support for spatial vector data. *The R Journal*, 10(1), 439–446. <https://doi.org/10.32614/RJ-2018-009>

Pebesma, E., & Bivand, R. (2023). *Spatial data science: With applications in R*. Chapman and Hall/CRC. <https://doi.org/10.1201/9780429459016>

Raifer, M., Troilo, R., Kowatsch, F., Auer, M., Loos, L., Marx, S., Przybill, K., Fendrich, S., Mocnik, F. B., & Zipf, A. (2019). OSHDB: A framework for spatio-temporal analysis of OpenStreetMap history data. *Open Geospatial Data, Software and Standards*, 4, Article 3. <https://doi.org/10.1186/s40965-019-0061-3>

Ramm, F., Topf, J., & Chilton, S. (2011). *OpenStreetMap: Using and enhancing the free map of the world*. UIT Cambridge.

Rodriguez-Galiano, V. F., Ghimire, B., Rogan, J., Chica-Olmo, M., & Rigol-Sanchez, J. P. (2012). An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67, 93–104. <https://doi.org/10.1016/j.isprsjprs.2011.11.002>

Schuster, C., Förster, M., & Kleinschmit, B. (2012). Testing the red edge channel for improving land-use classifications based on high-resolution multi-spectral satellite data. *International Journal of Remote Sensing*, 33(17), 5583–5599. <https://doi.org/10.1080/01431161.2012.666812>

Statology. (2021, 4 octobre). *How to implement random forest in R (step-by-step)*. <https://www.statology.org/random-forest-in-r/>

Weng, Q., Hu, X., & Lu, D. (2008). Extracting impervious surfaces from medium spatial resolution multispectral and hyperspectral imagery: A comparison. *International Journal of Remote Sensing*, 29(11), 3209–3232. <https://doi.org/10.1080/01431160701469024>

Wickham, H. (2014). Tidy data. *Journal of Statistical Software*, 59(10), 1–23. <https://doi.org/10.18637/jss.v059.i10>

Wickham, H. (2020). *httr: Tools for working with URLs and HTTP* (R package version 1.4.2) [Logiciel]. <https://CRAN.R-project.org/package=httr>

Wickham, H., Averick, M., Bryan, J., Chang, W., McGowan, L. D., François, R., Golem, G., Hayes, A., Henry, L., Hester, J., Kuhn, M., Pedersen, T. L., Miller, E., Bache, S. M., Müller, K., Ooms, J., Robinson, D., Seidel, D. P., Spinu, V., ... Yutani, H. (2019). Welcome to the tidyverse. *Journal of Open Source Software*, 4(43), Article 1686. <https://doi.org/10.21105/joss.01686>

Zielstra, D., & Zipf, A. (2010). A comparative study of proprietary geodata and volunteered geographic information for Germany. Dans *Proceedings of the 13th AGILE International Conference on Geographic Information Science*.

ANNEXE I – Code R expliqué

La méthodologie s'appuie sur trois jeux de données géospatiales :

1. Imagerie satellitaire multispectrale Pléiades Neo 6 bandes spectrales de la commune de Carouge

```
satellite <- rast(file.path(data_dir, "Satellite_Carouge.tif"))
names(satellite) <- c("Red", "Green", "Blue", "NIR", "RedEdge", "DeepBlue")
```

2. Couche de référence géométrique

La couverture du sol vectorielle ($n = 3720$ polygones) dont les polygones servent pour la généralisation objet-basée.

3. Échantillons d'entraînement supervisé

Un ensemble de polygones de référence ($n = 268$) produite à partir de l'image PléïadeNéo dans Arcgis Pro.

Harmonisation des systèmes de coordonnées

L'homogénéité des systèmes de référence spatiale constitue un prérequis pour l'extraction radiométrique. Une reprojection à la volée est appliquée :

```
training_sample <- st_transform(training_sample, crs = crs(satellite))
sol_carouge <- st_transform(sol_carouge, crs = crs(classified_raster))
```

Cette transformation garantit l'alignement pixel-parfait entre données vectorielles et matricielles, conformément aux standards Simple Features établis pour R (Pebesma, 2018).

Stratégie d'échantillonnage spectral

La méthodologie implémente un échantillonnage exhaustif des pixels contenus dans chaque polygone de référence. Cette fonction réalise une intersection géométrique entre les 268 polygones d'entraînement et la grille raster. Elle extrait l'intégralité des signatures spectrales à six dimensions contenues dans chaque entité vectorielle. Le paramètre ID = TRUE préserve la traçabilité polygon-pixel essentielle pour l'attribution de classe.

```
training_values <- extract(satellite, vect(training_sample), ID = TRUE)
```

Attribution des labels et structuration des données

La jointure entre valeurs spectrales et classes nominales s'effectue par correspondance d'indices :

```
training_data <- training_values %>%
  mutate(Classe = training_sample[[class_col]][ID]) %>%
  select(-ID) %>%
  mutate(Classe = as.factor(Classe))
```

Ce processus génère un tableau de données où chaque observation représente un pixel caractérisé par :

- Variables prédictives : six valeurs de réflectance spectrale (*R, G, B, NIR, RedEdge, DeepBlue*)
- Variable de réponse : classe catégorielle de revêtement

La transformation en facteur (as.factor()) est impérative pour l'algorithme de classification supervisée.

2.3 Validation de la distribution d'échantillonnage

Des contrôles statistiques préalables vérifient l'adéquation de la base d'apprentissage :

```
if (length(unique(training_data_clean$Classe)) < 2) {
  stop("ERREUR: Une seule classe présente dans les données extraites!")
}
```

Critères de validation :

- Présence d'au moins deux classes distinctes (condition nécessaire pour la discrimination)
- Absence de valeurs manquantes (na.omit())
- Effectif minimal recommandé : $n \geq 100$ pixels par classe (règle empirique pour Random Forest)

La distribution finale de l'échantillonnage est documentée via des tableaux de contingence :

```
class_distribution <- table(training_data_clean$Classe)
print(prop.table(class_distribution) * 100)
```

Modélisation Random Forest

L'algorithme Random Forest (Breiman, 2001) appartient à la famille des méthodes d'ensemble par agrégation de type *bagging*. Il construit k arbres de décision indépendants entraînés sur des sous-échantillons bootstrap des données d'apprentissage, chaque nœud de division sélectionne un sous-ensemble aléatoire de variables candidates. La prédiction finale résulte d'un vote majoritaire (classification) ou d'une moyenne (régression) des prédictions individuelles.

Avantages pour la télédétection :

- Robustesse aux données de haute dimensionnalité
- Résistance au surapprentissage (*overfitting*)

- Estimation intrinsèque de l'erreur de généralisation (Out-of-Bag)
- Quantification de l'importance des variables

Paramétrage du modèle

```
rf_model <- randomForest(
  Classe ~.,
  data = training_data_clean,
  ntree = 500,
  importance = TRUE,
  na.action = na.omit
)
```

Paramètres configurés :

- ntree = 500 : nombre d'arbres dans la forêt. Valeur standard pour assurer la stabilisation de l'erreur OOB (Rodriguez-Galiano et al., 2012)
- importance = TRUE : calcul des mesures d'importance des variables (*Mean Decrease Accuracy, Mean Decrease Gini*)
- Formule Classe ~ . : régression sur l'ensemble des prédicteurs disponibles

Les hyperparamètres non spécifiés suivent les valeurs par défaut optimisées :

- mtry = \sqrt{p} pour la classification (p = nombre de variables)
- nodesize = 1 (taille minimale des nœuds terminaux)
- maxnodes = NULL (croissance complète des arbres)

Évaluation des performances

Erreur Out-of-Bag (OOB)

Le mécanisme bootstrap génère naturellement un ensemble de validation : pour chaque arbre, environ 37% des observations ne sont pas utilisées lors de l'entraînement. Ces échantillons OOB permettent une estimation non biaisée de l'erreur de généralisation :

```
oob_error <- rf_model$err.rate[nrow(rf_model$err.rate), 1]
accuracy <- (1 - oob_error) * 100
```

L'exactitude globale (*overall accuracy*) est calculée comme le complément à 1 du taux d'erreur OOB stabilisé.

Matrice de confusion

La matrice de confusion croisée (*confusion matrix*) détaille les performances classe par classe :

```
print(rf_model$confusion)
```

Cette matrice C de dimension $k \times k$ (où k est le nombre de classes) quantifie :

- Diagonale : classifications correctes (vrais positifs pour chaque classe)
- Hors-diagonale : confusions inter-classes
- Erreur de classe : taux de mauvaise classification par classe

Des métriques dérivées peuvent être calculées :

- Précision du producteur (*producer's accuracy*) : $C_{ii} / \sum_j C_{ji}$

- Précision de l'utilisateur (*user's accuracy*) : $C_{ii} / \sum_j C_{ij}$
- Coefficient Kappa : accord inter-observateurs corrigé du hasard

Importance des variables spectrales

Deux indices quantifient la contribution de chaque bande spectrale :

```
importance_df <- as.data.frame(importance_rf_model))
importance_df <- importance_df[order(-importance_df$MeanDecreaseAccuracy), ]
```

- Mean Decrease Accuracy (MDA) : dégradation moyenne de l'exactitude OOB lorsque la variable est permutée aléatoirement. Reflète l'importance prédictive globale.
- Mean Decrease Gini (MDG) : réduction moyenne de l'impureté de Gini apportée par les divisions sur cette variable. Mesure la capacité de séparation des classes.

L'analyse de ces métriques identifie les régions spectrales discriminantes pour les revêtements urbains (typiquement : NIR pour végétation, Red/Blue pour surfaces imperméables).

Classification pixel-basée de l'image complète

Inférence spatiale exhaustive

Le modèle entraîné est appliqué à l'intégralité de l'image satellite :

```
classified_raster <- predict(satellite, rf_model, na.rm = TRUE)
```

Cette opération réalise une prédiction pixel par pixel :

1. Pour chaque pixel i de coordonnées (x, y) :
 - Extraction du vecteur de réflectance à 6 dimensions : $x_i = [R, G, B, NIR, RedEdge, DeepBlue]$
 - Propagation dans les 500 arbres de décision
 - Agrégation des votes individuels
 - Attribution de la classe majoritaire
2. Génération d'un raster catégoriel où chaque valeur de pixel encode une classe de revêtement

Le paramètre `na.rm = TRUE` exclut les pixels sans données (zones masquées, nuages) du processus de classification.

Considérations computationnelles

Pour des images de grande taille ($> 10^9$ pixels), des stratégies d'optimisation peuvent être implémentées :

- Traitement par tuiles (*tiling*) avec recomposition
- Parallélisation sur multicœurs (`predict(..., cores = n)`)
- Sous-échantillonnage spatial contrôlé

Généralisation objet-basée avec seuil de consensus

Rationale méthodologique

La classification pixel-basée génère une mosaïque spatiale granulaire souvent affectée par le "sel et poivre" radiométrique. La généralisation objet-basée (*Object-Based Image Analysis*, OBIA) agrège ces informations à l'échelle de segments prédéfinis (parcelles cadastrales, îlots bâtis), produisant une cartographie opérationnelle alignée avec les unités de gestion territoriale.

Algorithme de vote majoritaire contraint

Pour chaque polygone P de la couche de référence :

```
pixel_values <- extract(classified_raster, vect(sol_carouge[i, ]), ID = FALSE)
pixel_values <- na.omit(pixel_values[[1]])
```

Étape 1 : Extraction des valeurs de classification de tous les pixels n_p contenus dans P

```
class_counts <- table(pixel_values)
max_class <- names(class_counts)[which.max(class_counts)]
max_count <- max(class_counts)
percentage <- (max_count / total_pixels) * 100
```

Étape 2 : Calcul du tableau de fréquences des classes

Étape 3 : Identification de la classe modale C_{max} et son occurrence n_{max}

Étape 4 : Calcul du consensus relatif : $\rho = (n_{max} / n_p) \times 100$

assigned_class <- if (percentage >= 80) max_class else NA_character_

Étape 5 : Attribution conditionnelle

- Si $\rho \geq 80\%$: le polygone hérite de la classe C_{max}
- Si $\rho < 80\%$: le polygone reste non classifié (hétérogénéité intra-parcellaire excessive)

Justification du seuil de consensus

Le seuil de 80% représente un compromis entre :

1. Pureté spectrale : garantir une homogénéité minimale de la signature d'occupation du sol
2. Couverture spatiale : maintenir un taux de classification acceptable de la zone d'étude
3. Fiabilité cartographique : limiter les erreurs d'attribution en contexte hétérogène (interfaces, zones transitionnelles)

Ce seuil peut être ajusté selon le contexte applicatif :

- Applications réglementaires : seuils élevés (85-95%) pour haute fiabilité
- Études exploratoires : seuils modérés (70-75%) pour couverture maximale

Structuration des résultats

```
results_list[[i]] <- data.frame(
  OBJECTID = sol_carouge$OBJECTID[i],
  Revetement = assigned_class,
  Pourcentage = round(percentage, 2),
  Total_pixels = total_pixels,
  Classe_majoritaire = max_class,
  stringsAsFactors = FALSE)
```

)

Chaque polygone est enrichi de métadonnées analytiques :

- Revetement : classe assignée (ou NA si sous-seuil)
- Pourcentage : consensus relatif de la classe majoritaire
- Total_pixels : effectif de pixels analysés (proxy de la surface)
- Classe_majoritaire : classe modale indépendamment du seuil (information diagnostique)

Cette structure permet des analyses post-hoc de sensibilité au seuil et l'identification de zones d'incertitude spatiale.

Validation et métriques de performance

Métriques de couverture spatiale

```
n_assigned <- sum(!is.na(sol_carouge_final$Revetement))  
pct_assigned <- (n_assigned / nrow(sol_carouge_final)) * 100
```

Taux de classification (*classification rate*) : proportion de polygones satisfaisant le critère de consensus. Indicateur de l'homogénéité globale du territoire et de la robustesse de la typologie.

Distribution des classes prédites

```
stats_by_class <- results_df %>%  
  filter(!is.na(Revetement)) %>%  
  group_by(Revetement) %>%  
  summarise(  
    Nb_polygones = n(),  
    Pct_moyen = mean(Pourcentage),  
    Pct_min = min(Pourcentage),  
    Total_pixels = sum(Total_pixels)  
  )
```

Cette analyse agrégée quantifie :

- Effectif : nombre de polygones par classe (représentativité spatiale)
- Consensus moyen : homogénéité intra-classe moyenne (indicateur de qualité)
- Consensus minimal : borne inférieure de certitude ($\geq 80\%$ par construction)
- Emprise pixellique : surface totale couverte (pondération par taille des entités)

Validation indépendante (recommandation)

Bien que non implémentée dans le workflow automatisé, une validation rigoureuse nécessiterait :

1. Stratification d'un jeu de validation : réserve de 20-30% des polygones de référence avant entraînement
2. Échantillonnage aléatoire stratifié : $n \geq 50$ points par classe pour intervalles de confiance robustes
3. Calcul de métriques standards :
 - Exactitude globale (*overall accuracy*)
 - Coefficient Kappa de Cohen
 - F-scores classe par classe
 - Intervalles de confiance à 95% (bootstrapping)

4. Analyse d'erreur géographique : identification de zones systématiquement mal classifiées (biais topographiques, saisonniers, d'acquisition)

Produits cartographiques

Les sorties géospatiales incluent :

- Raster pixel-basé : classification exhaustive (format GeoTIFF)
- Vecteur objet-basé : polygones enrichis (format Shapefile ESRI)

Ces formats standardisés assurent l'interopérabilité avec les SIG (QGIS, ArcGIS) et bases de données spatiales (PostGIS).

7.2 Traçabilité scientifique

```
sink(file.path(output_dir, "Resume_modele.txt"))
cat("Données d'entraînement:", nrow(training_data_clean), "pixels\n")
print(rf_model)
print(importance(rf_model))
print(rf_model$confusion)
sink()
```

Un rapport textuel automatisé documente :

- Paramétrisation complète du modèle
- Performances d'entraînement (erreur OOB, matrice de confusion)
- Importance relative des bandes spectrales
- Statistiques d'application (couverture, distribution des classes)

Cette traçabilité est essentielle pour la reproductibilité (*reproducible research*) et l'audit scientifique.

Limites méthodologiques

Échantillonnage d'entraînement :

- Dépendance à la qualité de la photo-interprétation initiale
- Représentativité spatiale limitée (268 polygones pour 3720 cibles)
- Absence de stratification géographique ou temporelle

Généralisation :

- Hypothèse d'homogénéité intra-parcellaire (seuil 80% arbitraire)
- Sensibilité aux effets de bordure (pixels mixtes)
- Pas de modélisation de l'incertitude spatiale continue

Validation :

- Estimation OOB comme proxy de l'exactitude finale (potentiellement optimiste)
- Absence de validation externe indépendante
- Pas d'évaluation de la transférabilité spatiale ou temporelle

Cette méthodologie hybride combinant classification supervisée par Random Forest et généralisation objet-basée contrainte offre un pipeline reproductible pour la cartographie semi-

automatique de revêtements urbains à partir d'imagerie THRS. L'approche garantit un niveau de fiabilité contrôlé (consensus $\geq 80\%$) tout en préservant la traçabilité analytique complète, répondant aux exigences de rigueur scientifique pour publication académique.

Intégration de données OpenStreetMap

Cette méthodologie a souhaité explorer une approche basée sur l'analyse d'intersection spatiale et le principe du maximum de vraisemblance. Elle a testé une solution automatisée pour compléter des attributs manquants dans la couche vectorielle Sol_Carouge_Teledetecte en utilisant des données de surfaces géoréférencées disponibles dans la base OSM.

Données primaires

Les données primaires consistent en la couche Sol_Carouge_Teledetecte vectorielle de type polygone qui contient les informations sur les revêtements de sol détectés par télédétection. Cette couche présente des lacunes dans l'attribut Revtmnt, avec des valeurs nulles ou vides pour certains polygones. L'utilisation de la fonction `st_read()` du package `sf` (Pebesma, 2018) permet l'importation des données vectorielles dans l'environnement R tout en préservant les attributs géométriques et les métadonnées du système de coordonnées de référence (CRS). Ce package implémente la spécification Simple Features définie par l'Open Geospatial Consortium (OGC, 2011).

```
sol_carouge <- st_read(file.path(chemin_data, paste0(nom_shapefile, ".shp")),
quiet = TRUE)
```

Identification des entités à compléter

Une analyse préliminaire permet d'identifier les polygones auxquels il manque un revêtement suite à la télédétection avec seuil de 80%

```
polygones_a_completer <- sol_carouge %>%
  mutate(id_original = row_number()) %>%
  filter(is.na(Revtmnt) | Revtmnt == "")
```

Cette opération de filtrage, implémentée via le paradigme tidyverse (Wickham et al., 2019), crée un identifiant unique pour chaque entité afin de maintenir la traçabilité lors des opérations ultérieures de mise à jour. L'approche fonctionnelle du tidyverse permet une manipulation des données transparente et reproductible, critères essentiels en recherche scientifique (Wickham, 2014).

Définition de l'emprise spatiale

L'emprise géographique de la requête est déterminée par le calcul de la boîte englobante (bounding box) minimale contenant l'ensemble des polygones de la couche source :

```
bbox <- st_bbox(st_transform(sol_carouge, 4326))
```

Une transformation vers le système WGS 84 (EPSG:4326) est nécessaire, ce système étant le standard utilisé par l'API Overpass d'OpenStreetMap pour les requêtes spatiales (Ramm et al., 2011). La transformation de systèmes de coordonnées s'appuie sur la bibliothèque PROJ, garantissant une précision géodésique conforme aux standards internationaux (Evenden, 2005).

Requête Overpass API

L'acquisition des données OSM s'effectue via l'API Overpass, un service de requête optimisé pour extraire des sous-ensembles de données de la base OpenStreetMap (Raifer et al., 2019). La requête est structurée dans le langage de requête Overpass QL :

```
overpass_query <- paste0(
  '[out:json][timeout:90];',
  '(',
  ' way["surface"]("bbox_str");
  ' relation["surface"]("bbox_str");
  ')';
  'out geom;
  )
```

Cette requête extrait l'ensemble des entités linéaires (way) et relationnelles (relation) qui ont un attribut surface, dans la bbox spécifiée. Le paramètre timeout:90 définit une limite temporelle de 90 secondes pour l'exécution de la requête pour éviter les blocages en cas de volume de données important. L'architecture distribuée d'Overpass API permet le traitement efficace de requêtes complexes sur l'ensemble de la base de données planétaire OSM (Olbricht, 2015).

Transmission et réception des données

La communication avec l'API s'effectue via le protocole HTTP POST :

```
response <- POST(url, body = list(data = overpass_query), encode = "form")

if (status_code(response) == 200) {
  return(content(response, "parsed"))
}
```

Le code de statut HTTP 200 confirme la réussite de la transaction. Les données sont retournées au format JSON et automatiquement *parsed* en structures de données R natives par la fonction content() du package httr (Wickham, 2020).

Construction des géométries polygonales

Les données OSM brutes nécessitent une conversion en objets géométriques compatibles avec le format Simple Features (SF). Pour chaque entité OSM :

```
coords <- do.call(rbind, lapply(element$geometry, function(node) {
```

```

c(node$lon, node$lat)
  }))

# Fermer le polygone
if (nrow(coords) > 2 && !all(coords[1,] == coords[nrow(coords),])) {
  coords <- rbind(coords, coords[1,])
}

```

Cette étape extrait les coordonnées géographiques des nœuds constitutifs de chaque entité et assure la fermeture topologique du polygone en vérifiant que le premier et le dernier point sont identiques, condition nécessaire à la validité géométrique selon la spécification Simple Features (OGC, 2011).

Validation et filtrage géométrique

Seuls les polygones valides, c'est-à-dire composés d'au moins quatre sommets (trois points distincts plus le point de fermeture), sont conservés :

```

if (nrow(coords) >= 4) {
  poly <- st_polygon(list(coords))

  polygones_list[[length(polygones_list) + 1]] <- list(
    osm_id = as.character(element$id),
    surface = element$tags$surface,
    geometry = poly
  )
}

```

Cette validation prévient les erreurs topologiques qui pourraient compromettre les analyses spatiales ultérieures.

Construction de l'objet spatial

Les géométries individuelles sont agrégées dans un objet sf unique :

```

osm_sf <- st_sf(
  osm_id = sapply(polygones_list, function(x) x$osm_id),
  surface = sapply(polygones_list, function(x) x$surface),
  geometry = st_sfc(lapply(polygones_list, function(x) x$geometry), crs = 4326)
)

osm_sf <- st_transform(osm_sf, crs_cible)

```

Une transformation de coordonnées est appliquée pour aligner le système de référence des données OSM sur celui de la couche source, garantissant ainsi la cohérence spatiale des opérations d'intersection ultérieures.

Analyse d'intersection et attribution

Pour chaque polygone de la couche source présentant un attribut Revtmnt manquant, une analyse d'intersection spatiale est réalisée avec l'ensemble des polygones OSM :

```
intersections <- st_intersection(osm_polygones, poly_actuel)
```

La fonction `st_intersection()` calcule l'intersection géométrique entre deux couches vectorielles, produisant de nouvelles entités représentant les zones de chevauchement (Pebesma & Bivand, 2023).

Calcul des surfaces d'intersection

Pour chaque intersection détectée, la surface de chevauchement est quantifiée :

```
intersections$aire <- as.numeric(st_area(intersections))
```

La fonction `st_area()` calcule l'aire des polygones dans l'unité du système de coordonnées projeté. La conversion en valeur numérique via `as.numeric()` facilite les opérations de comparaison ultérieures.

Sélection de la correspondance optimale

Le principe du maximum de vraisemblance spatiale est appliqué pour sélectionner l'attribut OSM le plus représentatif :

```
meilleure <- intersections %>%
  filter(aire == max(aire)) %>%
  slice(1)
```

```
sol_carouge_copie$Revmtnt[idx_original] <- meilleure$surface
```

L'attribut surface du polygone OSM qui présente la plus grande surface d'intersection est attribué au polygone source. En cas d'égalité parfaite, la fonction `slice(1)` assure une sélection déterministe et ne retient que la première occurrence.

Création de l'attribut consolidé

Un nouvel attribut revetement est créé qui renseigne les informations originales et les données OSM complémentaires :

```
sol_carouge_complete <- sol_carouge_copie %>%
  mutate(revetement = Revmtnt)
```

Export de la couche enrichie

La couche complétée est exportée au format Shapefile qui garantit l'interopérabilité avec la majorité des systèmes d'information géographique (SIG).:

```
st_write(sol_carouge_complete,  
        chemin_sortie,
```

Évaluation de la qualité

L'efficacité du processus d'enrichissement est quantifiée par le calcul du taux de complétude qui permet d'évaluer la couverture spatiale des données OpenStreetMap pour la zone d'étude et d'identifier les secteurs nécessitant des levés complémentaires.:

```
nb_original <- sum(!is.na(sol_carouge$Revtmnt) & sol_carouge$Revtmnt != "")  
nb_final <- sum(!is.na(sol_carouge_complete$revetement) &  
                 sol_carouge_complete$revetement != "")  
taux_completion <- (nb_final - nb_original) /  
                  nrow(polygones_a_completer) * 100
```

