



WP3

Classification de l'occupation du sol (LC) par méthode orientée  
objet

# **Guide pour l'opérationnalisation de la procédure sur l'ensemble du territoire wallon (D3.2)**

20/11/18

Subvention financée par le Service Public de Wallonie, DGO3 et le Département de la Géomatique  
du Secrétariat Général.

**TABLE DES MATIERES**

<b>1.</b>	<b><u>INTRODUCTION .....</u></b>	<b><u>3</u></b>
<b>2.</b>	<b><u>APPROCHE MÉTHODOLOGIQUE .....</u></b>	<b><u>3</u></b>
<b>3.</b>	<b><u>TUilage .....</u></b>	<b><u>5</u></b>
<b>4.</b>	<b><u>SEGMENTATION .....</u></b>	<b><u>5</u></b>
<b>5.</b>	<b><u>CARACTÉRISATION DES SEGMENTS, STRATIFICATION ET SÉLECTION DES SEGMENTS D'ENTRAÎNEMENT</u></b>	<b><u>5</u></b>
<b>6.</b>	<b><u>CLASSIFICATION.....</u></b>	<b><u>6</u></b>
<b>7.</b>	<b><u>IMPLÉMENTATION TECHNIQUE CONCRÈTE DE L'APPROCHE .....</u></b>	<b><u>7</u></b>
<b>8.</b>	<b><u>EVALUATION DES RÉSULTATS SUR LES ZONES TEST.....</u></b>	<b><u>7</u></b>
<b>9.</b>	<b><u>OPÉRATIONNALISATION POUR L'ENSEMBLE DU TERRITOIRE.....</u></b>	<b><u>8</u></b>
<b>10.</b>	<b><u>ANNEXES .....</u></b>	<b><u>9</u></b>
<b>ANNEXE 1 : SCHÉMAS DÉTAILLÉS.....</b>		<b>9</b>
<b>ANNEXE 2 : RÈGLES POUR LA SÉLECTION DES SEGMENTS D'ENTRAÎNEMENT .....</b>		<b>11</b>

## 1. Introduction

Le projet prévoit deux processus parallèles de classification automatique : une classification par objet et une par pixel. La première semble plus adéquate pour les environnements bâtis tandis que la deuxième plus pour les environnements naturels, surtout grâce à l'utilisation de séries temporelles d'images Sentinel 2 et d'images radar de Sentinel 1. Ce WP3 traite de la classification par objet tandis que le WP 4 aborde la classification par pixel. Les deux seront fusionnées dans une étape ultérieure.

L'objectif de ce livable est de proposer des orientations pour l'opérationnalisation de la méthode sur l'ensemble du territoire wallon. Ces orientations sont basées sur l'expérience acquise dans le travail sur 4 zones test.

Ce document commence par une description de l'approche méthodologique choisie pour la chaîne de traitement orientée objet, avec une discussion des enjeux de chaque étape. Ensuite, l'implémentation technique concrète sera expliquée, avant de présenter les résultats des expériences sur les 4 zones pour finalement énumérer une série de recommandations pour le passage à un traitement sur toute la Région wallonne.

## 2. Approche méthodologique

La classification par objet dans le cadre de Walous suit la lignée déjà entamée avec le projet SmartPop (ainsi que des projets BELSPO comme MAUPP et REACT), focalisé particulièrement sur la cartographie de l'occupation du sol en milieu bâti. La démarche reflète les principes de base suivants :

- une attention à une parallélisation importante des calculs à travers un traitement par tuiles, tout en évitant le plus possible les effets de bord ;
- une prise en compte des conditions de prise de vue différentes des images en traitant séparément des groupes d'images homogènes.
- une volonté d'automatisation complète

Le schéma suivant (Figure 1) montre l'ensemble des processus mis en œuvre. Dans les annexes, deux schémas montrent plus en détail les chaînes respectives pour la segmentation et pour la classification.

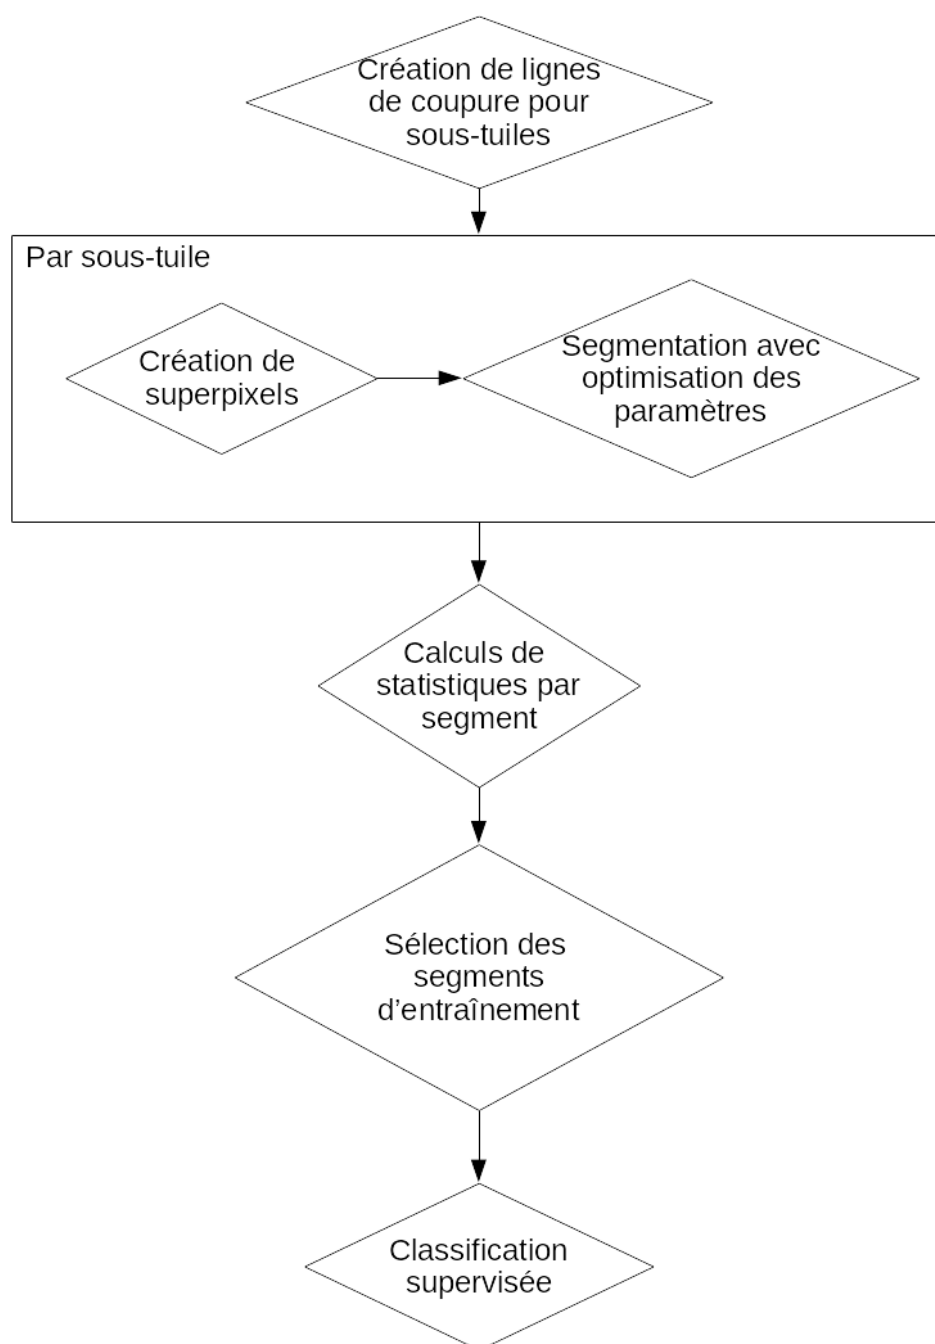


Figure 1: Vue globale des processus constituant la chaîne OBIA

### 3. Tuilage

Une première étape dans la classification par objet est la création des objets par segmentation. Comme l'expérience des autres projets l'a montré, l'hétérogénéité dans les images traitées exige une approche spatialement différenciée de choix des paramètres de cette segmentation. Pour pouvoir assurer une telle différenciation, l'image doit être découpée en plus petites tuiles, de préférence sans que les limites de ces tuiles passent à travers des objets qui nous intéressent. Les orthophotos de la Région sont déjà constituées de tuiles représentant différentes prises de vue. Ces tuiles sont néanmoins trop grandes pour les utiliser comme plus petite unité spatiale de différenciation. La première partie du travail a donc consisté en la mise en place d'une chaîne de traitement assurant un découpage traversant le moins possible les objets que l'on souhaite identifier.

### 4. Segmentation

La segmentation se fait par une optimisation différenciée par sous-tuile. L'algorithme teste différentes valeurs pour le seuil de segmentation (threshold). Les gammes des valeurs testées et la taille minimale des segments varient selon le type d'environnement : dans les zones forestières et agricoles les segments recherchés seront plus grands, et une moindre attention est portée à l'homogénéité interne des segments, puisque les variations à l'intérieur d'une forêt ou un champ donné ne sont généralement pas pertinentes pour la classification de l'occupation du sol. Le contraire est vrai pour les autres types d'occupation du sol, notamment le bâti, pour lesquels de plus petits segments sont nécessaire et une attention plus grande à l'homogénéité interne des segments en vue du passage rapide d'une occupation à une autre.

### 5. Caractérisation des segments, stratification et sélection des segments d'entraînement

Tous les segments résultant de la segmentation doivent être caractérisés avec des statistiques décrivant leur forme, leur caractéristiques spectrales, leur texture, etc. Il est également possible d'y inclure pour chaque segment des informations concernant les voisins.

Ensuite, pour pouvoir procéder à la classification supervisée, un set de données d'entraînement est indispensable. En vue d'un côté de la nécessité de s'adapter à des conditions locales et de prise de vue différente, et de l'autre côté à la grande taille du territoire couverte par rapport à la résolution très fine des images, la classification devra être stratifiée (comme cela a déjà été expérimenté dans le projet Orthowatch). Cette stratification exige dès lors des sets d'entraînement pour chacune des strates. Une automatisation totale du processus de sélection des segments d'entraînement s'impose donc comme seule option viable.

Cette sélection se base sur les bases de données vectorielles existantes en Région wallonne (PICC, SIGEC, Lifewatch, etc) ou ailleurs (IGN – nécessaire pour les forêts puisque dans le Brabant et le Hainaut la part de forêts gérés par le DNF est très faible). A cause du chevauchement dans le temps, il n'était pas encore possible de profiter du travail du WP 2 pour la sélection de ces données, mais ce sera le cas dans l'extension des analyses sur l'ensemble de la Région.

Pour chaque tuile, les segments sont sélectionnés selon leur superposition avec des données de différentes classes et ensuite soumis à un filtrage supplémentaire (essentiellement sur base de valeurs NDVI et de hauteur – voir annexe pour le détail) pour éliminer de faux positifs (segments identifiés comme appartenant à une classe, mais n'y appartenant visiblement pas (éventuellement puisqu'ils sont recouverts par une autre classe sur l'image) et des valeurs extrêmes. Les algorithmes de sélection doivent aussi tenir compte du décalage spatial entre photos et bases de données vectorielles, par exemple en acceptant comme bâtiment un segment dont la surface recouvre à 95 % la surface d'un bâtiment du PICC.

Les données d'entraînement de plusieurs tuiles avec des conditions de prise de vue similaires (ligne de vol le même jour à presque la même heure et en même direction) sont ensuite regroupées. Ce regroupement se fait en traduisant le moment de la prise de vue en secondes d'époque (secondes depuis un moment arbitraire dans le passé) et ensuite divisé par 10.000 et arrondi à l'entier le plus proche, résultant en des groupes des mêmes 1-2h de prises de vue.

Puisque la sélection des paramètres optimaux pour un classifieur comme le Random Forest peut s'avérer longue en temps si trop de données sont utilisées, mais aussi puisque le nombre de segments d'entraînement par classe est très inégal après la première sélection, ce qui peut engendrer des biais, un algorithme d'active learning est ensuite utilisé pour choisir un nombre plus limité de segments d'entraînement (entre 100 et 200). Pour encore diminuer le temps nécessaire, l'active learning est appliqué sur un échantillon tiré au hasard dans l'ensemble des segments d'entraînement potentiels identifiés.

## 6. Classification

A l'aide des zones d'entraînement, chaque strate est ensuite classée en utilisant un classifieur Random Forest qui montre de très bonnes performances. Une approche combinant plusieurs classifieur par un système de vote est envisageable, mais rallongerait significativement le temps de calcul sans apporter d'améliorations significatives dans nos essais. Pour chaque segment l'information sur la probabilité d'appartenance à la classe choisie (ainsi que les probabilités d'appartenance aux autres classes) est également enregistrée.

Il est important de noter que pour la classification supervisée les variables liées à la hauteur relative (MNH) ne sont pas utilisées à cause du décalage spatial existant entre ce MNH et les orthophotos. Ceci permet d'éviter des classifications erronées de zones aux abords de bâtiment en bâtiment, mais diminue en même temps la précision globale du résultat. Les post-traitements deviennent dès lors plus importants.

Pour améliorer les résultats de classification supervisée, certaines étapes de post-traitement sont appliquées, cette fois-ci en incluant les informations de hauteur relative :

- Transformer les objets classés en sols imperméabilisés, sol nu ou eau ayant une hauteur relative de plus de 2,5m en bâtiment
- Transformer les pixels classés en résineux ou feuillus de moins de 1,5m en végétation basse
- Réaffecter chaque zone d'une classe donnée avec une taille plus petite que 15m<sup>2</sup> et entourée de zones d'autres classes vers la classe voisine avec laquelle la zone en question partage la plus longue limite commune. Cette dernière étape est à revoir,

néanmoins, puisqu'elle élimine entre autres de petites zones aux abords des bâtiments, diminuant ainsi la qualité de la délimitation de ces derniers.

## 7. Implémentation technique concrète de l'approche

L'ensemble de la chaîne de traitement a été implémenté en GRASS GIS, utilisant l'API Python de ce dernier. Le code est donc sous forme de scripts liant différents modules de GRASS GIS par du code Python. Trois scripts sont disponibles :

- Script pour la division en sous-tuiles et pour la segmentation
- Script pour la caractérisation des segments et la partition au hasard en segments initiaux d'entraînement, segments de test (pour l'active learning) et segments disponibles pour l'active learning.
- Script pour le regroupement des statistiques par strate, l'active learning et la classification (pour l'instant sous forme de script shell Linux)

Ces scripts sont accessibles à l'adresse : <https://github.com/mlennert/WALOUS>.

Le travail de mise en place de cette chaîne de traitement a mené à une série d'améliorations et d'extensions de modules de GRASS GIS. L'ensemble de ces améliorations a directement été reversé dans le dépôt central de code du projet et est donc disponible publiquement.

Exemples d'améliorations :

- `i.cutlines` : possibilité d'inclure des données servant de limites pré-existantes entre sous-tuiles
- `i.segment.uspo` : amélioration de la performance
- `i.segment.stats` : possibilité de calculer les statistiques des voisins, amélioration de la performance
- `v.class.mlR` : possibilité de sauvegarder l'information sur les probabilités d'appartenance aux classes + de sauvegarder un modèle entraîné pour utilisation ultérieure, amélioration de la performance
- `r.texture.tiled` : nouveau module simple pour calculer les textures en parallèle

## 8. Evaluation des résultats sur les zones test

En termes de qualité de la classification, les résultats sont globalement satisfaisants avec une précision globale (overall accuracy) estimée par le classifieur (par validation croisée) à  $> 0,80$ . Ceci est la classification sans le MNH. Après quelques étapes de post-classification, cette précision passe rapidement à autour de  $0,90$ .

En termes d'efficacité de l'approche pour permettre une analyse dans des temps raisonnables, on arrive au traitement complet d'une zone test de  $\pm 100$  tuiles orthos en 4-5 jours maximum sur un nœud avec 10-12 cœurs. Cela représente une moyenne de  $\pm 1$  par tuile. Pour l'ensemble des  $\pm 2750$  tuiles, cela signifie donc un temps de calcul de  $\pm 3000$  heures ou 125 jours. En répartissant ce calcul sur de multiples nœuds, ce temps peut être réduit quasi

proportionnellement, donc avec, par exemple, une vingtaine de nœuds équivalent, on devrait pouvoir ramener ce temps de calcul à une durée de l'ordre d'une à deux semaines. Ce temps variera évidemment en fonction du type et du nombre de nœuds disponibles et ne tient pas compte des interruptions éventuelles, ni des files d'attente pour ces nœuds dans les superordinateurs universitaires.

## 9. Opérationnalisation pour l'ensemble du territoire

La chaîne semble opérationnelle en tant que telle, mais contient évidemment encore des options d'amélioration et d'augmentation de la vitesse. Dans ce contexte, il faut toujours trouver l'équilibre entre la simplicité du processus (et du code), la rapidité de l'exécution et la précision des résultats. En même temps, des questions pragmatiques se posent concernant les quantités de mémoire RAM, d'espace disque et de nombre de cœurs à utiliser. Certains choix dans la chaîne actuelle reflètent ces questions, comme le calcul d'indicateurs de texture pour chaque tuile séparément, au lieu de les calculer une fois pour toute pour tout le territoire, pour ne pas créer de grandes quantités de données à stocker sur le disque.

De premiers essais de fusion entre les résultats par pixel et les résultats par objet devraient permettre de rapidement déterminer si cette fusion suffit pour combler les imprécisions dans les deux résultats respectifs, ou s'il faut encore améliorer les chaînes individuelles avant fusion.

En vue des résultats et expériences relatés ci-dessus, nous pouvons faire les recommandations suivantes pour l'opérationnalisation de la chaîne sur l'ensemble du territoire.

- Pistes d'augmentation de la vitesse :
  - Travailler plus par échantillonnage au hasard pour réduire le nombre de segments traités lors de la sélection des segments d'entraînement
  - Réduire la gamme des hyper-paramètres pour le calibrage du modèle de classification
  - Utiliser une autre implémentation du classifieur random forest (différents modules existent dans R avec des performances variables)
- Options de niveau de parallélisation

La parallélisation permet d'augmenter significativement la vitesse d'exécution totale des scripts. L'ensemble est déjà conçu pour une parallélisation par tuile, avec une exécution des scripts pour chaque tuile en parallèle. Mais il existe encore des parties de scripts avec un potentiel de parallélisation interne, comme dans la sélection des zones d'entraînement qui se fait actuellement classe par classe en séquentiel. Travailler plus sur cette parallélisation interne des scripts a un sens si on travaille sur des nœuds avec plusieurs cœurs, et permettra alors l'accélération du traitement de chaque tuile.



## 10. Annexes

### Annexe 1 : Schémas détaillés

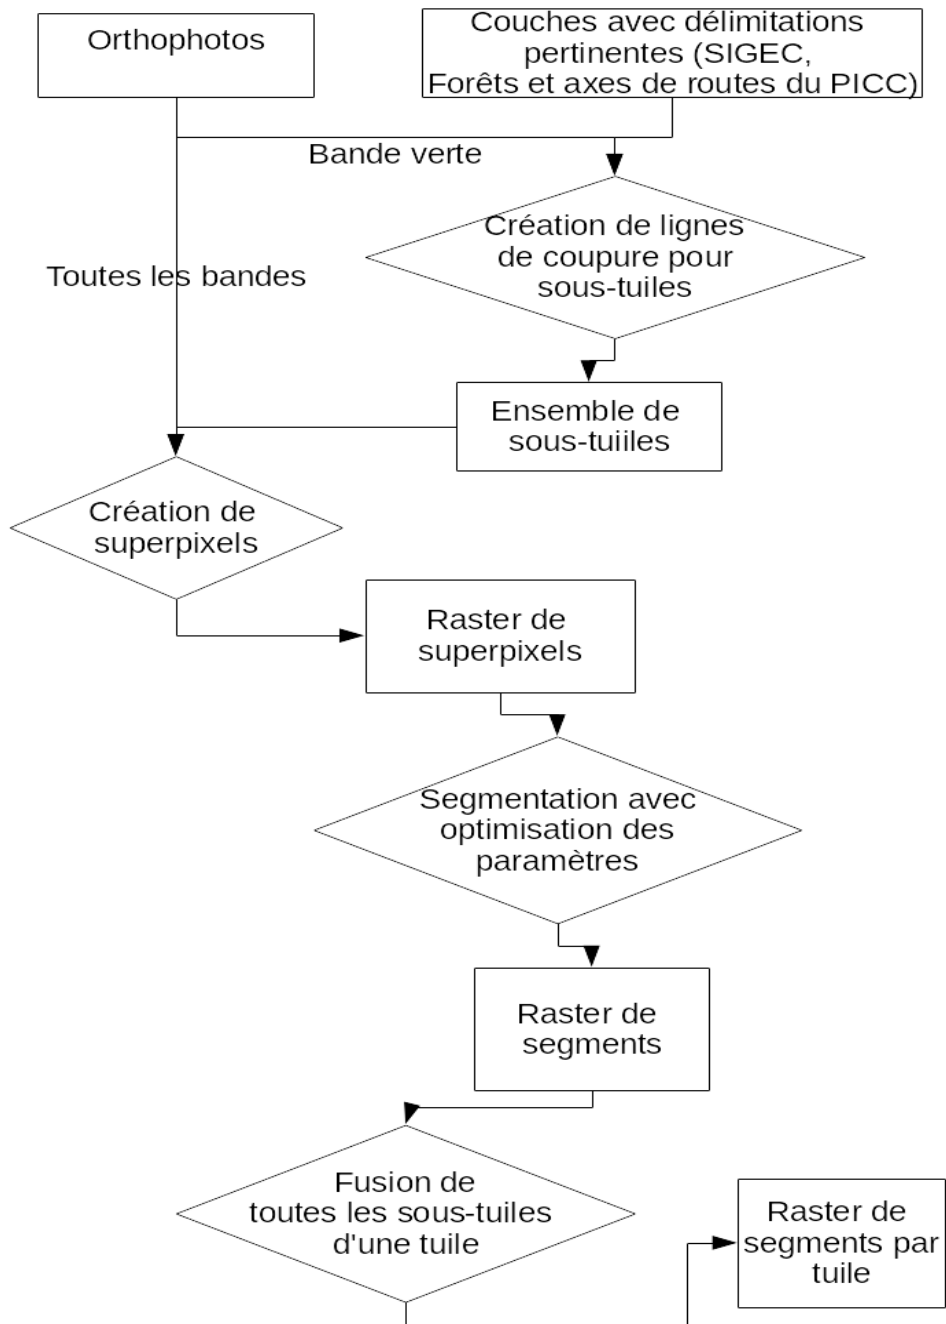


Figure 2: Schéma détaillé de la segmentation

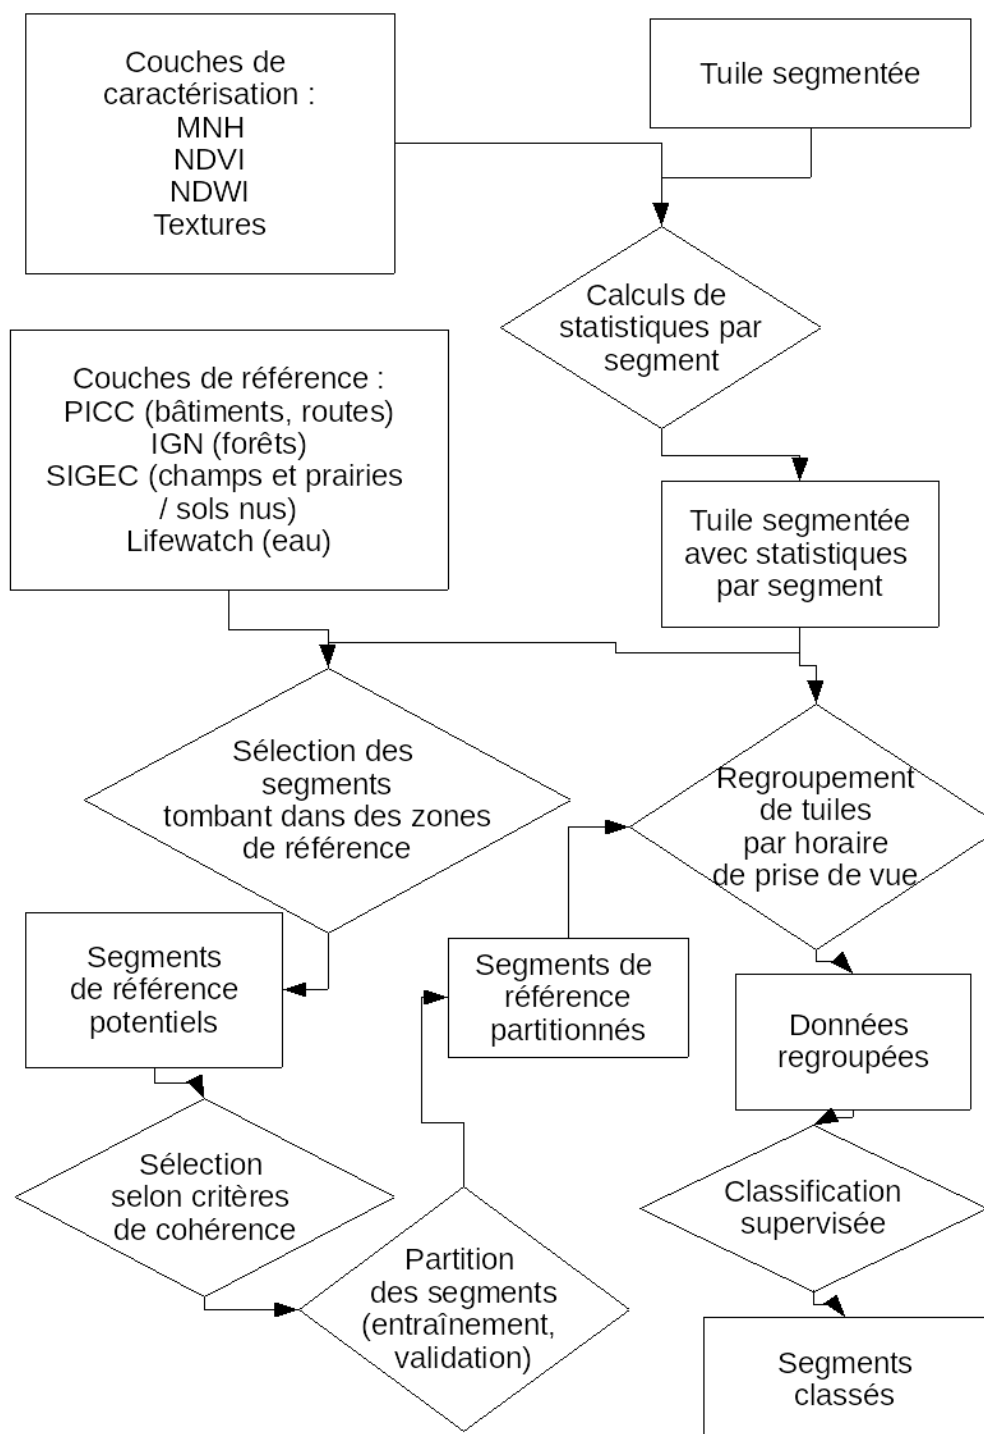


Figure 3: Schéma détaillé de la classification

## Annexe 2 : Règles pour la sélection des segments d'entraînement

- Bâti :
  - au moins 95 % du segment doit se trouver dans un polygone bâtiment du PICC (pour tenir compte du décalage spatial entre les deux couches)
  - le NDVI du segment doit être à moins d'un écart-type du NDVI moyen de tous les segments se superposant avec des polygones de bâti du PICC
  - l'écart-type du NDVI dans le segment doit être inférieur à l'écart-type moyen de tous les segments se superposant avec des polygones de bâti du PICC
- Routes / sols imperméabilisés:
  - le NDVI du segment doit être inférieur au NDVI moyen de tous les segments croisés par un axe de route du PICC
  - l'écart-type du NDVI dans le segment doit être inférieur à l'écart-type moyen de tous les segments croisés par un axe de route du PICC
  - la moyenne de hauteur dans le segment doit être inférieure à 200cm
- Végétation basse :
  - le NDVI du segment doit être supérieur 0,2
  - l'écart-type du NDVI dans le segment doit être inférieur à l'écart-type moyen de tous les segments à l'intérieur d'une parcelle identifiée comme 'Prairie et fourrage' dans le SIGEC
  - la moyenne de hauteur dans le segment doit être inférieure à la hauteur moyenne de tous les segments à l'intérieur d'une parcelle identifiée comme 'Prairie et fourrage' dans le SIGEC plus un écart-type
- Sol nu (sélection à revoir car était basée sur segments tombant dans catégorie 'Prairie et fourrage' dans le SIGEC)
  - le NDVI du segment doit être inférieur à 0
  - la moyenne de hauteur dans le segment doit être inférieure à la hauteur moyenne plus un écart-type de tous les segments à l'intérieur d'une parcelle identifiée comme 'Prairie et fourrage' dans le SIGEC
- Conifères
  - la moyenne de hauteur dans le segment doit être supérieur à la hauteur moyenne moins 2 écarts-type de tous les segments à l'intérieur d'une zone de résineux de la base de données TOPOV10 de l'IGN
  - le NDVI doit être supérieur à 0,2

- Feuillus
  - la moyenne de hauteur dans le segment doit être supérieur à la hauteur moyenne moins 2 écarts-type de tous les segments à l'intérieur d'une zone de feuillus de la base de données TOPOV10 de l'IGN
  - le NDVI doit être supérieur à 0,2
- Eau
  - au moins 90 % du segment doit se trouver dans un polygone eau de Lifewatch
  - une de deux conditions doit être remplie :
    - le NDWI moyen du segment est plus grand que 0,35 OU
    - le NDWI moyen du segment est plus grand que 0,25 ET le NDVI moyen du segment est inférieur à 0 ET la valeur moyenne du segment dans le proche infrarouge est inférieure à 150
- Ombres
  - la valeur moyenne du segment dans chacune des 4 bandes est inférieure à 65