

# WalousMàJ

## Solution

Version	1
Révision	2
Projet	WalousMàJ
Date	28/09/2022

	Nom	Société	Signature
Auteur	Damien Draime	Aerospacelab	
Relecteur / Approbateur	Jonathan Denies	Aerospacelab	
Approbateur	Benoît Deper	Aerospacelab	<i>Benoît Deper</i>

# Table des matières

<b>Table des matières</b>	<b>2</b>
<b>Abréviations et acronymes</b>	<b>3</b>
<b>1. Objet du rapport</b>	<b>4</b>
<b>2. Solution</b>	<b>4</b>
2.1. Pipeline	4
2.2. Modèle	7
2.3. Interactions	9
<b>3. Résultats</b>	<b>10</b>
<b>4. Comparaison avec WAL_OCS_2018</b>	<b>22</b>
<b>5. Détection des changements et correction d'erreurs</b>	<b>26</b>
<b>6. Limites</b>	<b>29</b>
6.1. Limites exogènes	29
6.2. Limites endogènes	33
6.3. Limites liées aux données non-représentatives	42
<b>7. Perspectives</b>	<b>43</b>
7.1. Affinement du jeu de données d'entraînement	43
7.2. Utilisation de true orthophotos	43
7.3. Utilisation de plusieurs orthophotos acquises à des périodes différentes de l'année	43
7.4. Création d'un nouveau jeu de données d'entraînement autour des orthophotos de 2020	44
7.5. Combiner plusieurs modèles dans Ensemble	44
7.6. Utilisation de données synthétiques	44
<b>8. Références</b>	<b>45</b>
<b>9. Annexes</b>	<b>45</b>
9.1. Configuration du modèle	45

# Abréviations et acronymes

<b>CA</b>	Comité d'Accompagnement
<b>ETP</b>	Equivalent Temps Plein
<b>LIDAR</b>	Light Detection and Ranging
<b>LPIS</b>	Land Parcel Identification System (Parcelle agricole anonyme)
<b>LSTM</b>	Long Short Term Memory
<b>MMU</b>	Minimum Mapping Unit (Unité de cartographie minimum)
<b>MNH</b>	Modèle Numérique de Hauteur
<b>MNS</b>	Modèle Numérique de Surface
<b>MNT</b>	Modèle Numérique de Terrain
<b>OA</b>	Précision globale (Overall Accuracy)
<b>PA</b>	Précision producteur (Producer Accuracy)
<b>PICC</b>	Projet Informatique de Cartographie Continue
<b>SOL_2018</b>	Solution développée dans le cadre du projet WALOUS afin de générer la carte d'occupation du sol de la Wallonie pour 2018
<b>SOL_2019/20</b>	Solution proposée par AEROSPACELAB à l'issue de ce marché
<b>SPW</b>	Service Public de Wallonie
<b>TEST_Set</b>	Jeu de données servant à évaluer la solution finale durant la phase III
<b>TRAIN_Set</b>	Jeu de données servant à entraîner les modèles d'une solution intermédiaire
<b>UA</b>	Précision utilisateur (User Accuracy)
<b>VAL_Set</b>	Jeu de données servant à valider une solution intermédiaire durant la phase de prototypage. Inclut VAL_Set_2018 et, potentiellement, VAL_Set_2019/20
<b>VAL_Set_2018</b>	Jeu de données de validation se basant sur les données de 2018
<b>VAL_Set_2019/20</b>	Jeu de données de validation se basant sur les données de 2019 (ou 2020)
<b>WAL_OCS_2018</b>	Carte d'occupation du sol de la Wallonie pour 2018 générée par le projet WALOUS
<b>WAL_OCS_IA_2019/20</b>	Carte d'occupation du sol de la Wallonie pour 2019 (ou 2020) générée pour ce marché
<b>WAL_OCS_CHA_IA_2018_2019/20</b>	Produit vectoriel regroupant les changements survenus entre 2018 et 2019 (ou 2020) et labélisés

# 1. Objet du rapport

Ce rapport a pour but de détailler la solution retenue et implémentée dans le cadre du marché de mise à jour de la carte d'occupation du sol de Wallonie.

La première section décrit la solution dans son ensemble : les données d'entrée et de sortie, l'architecture du modèle, et son entraînement. Ensuite les résultats obtenus avec cette solution/modèle sont présentés et interprétés. La troisième et quatrième section listent, respectivement, les améliorations, en termes de prédictions, apportées par cette nouvelle solution par rapport à WAL\_OCS\_2018, et les limites observées de la solution implémentée. Finalement, une section est consacrée aux perspectives qui peuvent être envisagées afin d'améliorer les performances de la solution retenue.

## 2. Solution

La solution, SOL\_2019/20, présentée ci-dessous, est celle qui a été retenue à la suite de la Phase II de prototypage, à savoir celle qui découle de l'Implementation II de l'itération 02. Elle est donc le résultat de plusieurs itérations à la suite desquelles le CA a retenu la solution répondant le plus à ses attentes.

Pour rappel, ce marché a pour objectif l'implémentation d'une solution capable de mettre à jour la carte d'occupation des sols de Wallonie et de détecter les changements survenus entre la nouvelle et l'ancienne version de cette carte. Trois critères principaux furent utilisés par le CA pour évaluer les solutions intermédiaires de la Phase II :

- Automatisation : afin d'éviter une solution où des interventions manuelles seraient trop fréquentes et déterminantes pour les résultats finaux ;
- Appropriation : le SPW veut pouvoir comprendre la solution, l'exécuter, et la maintenir ;
- Performance : les performances de SOL\_2019/20 doivent être comparables à celles de SOL\_2018 avec une marge de tolérance de 5% afin de promouvoir l'automatisation.

Cette solution s'axe autour d'un modèle d'apprentissage profond responsable de la prédiction des 11 classes principales. Le reste de la solution se compose de plusieurs blocs visant à manipuler les données d'entrée et de sortie afin de délivrer en bout de chaîne les deux livrables suivants<sup>1</sup> :

- WAL\_OCS\_IA\_2019/20
- WAL\_OCS\_CHA\_IA\_\_2018\_2019/20

La première partie, Pipeline, de cette section présente la solution dans son ensemble. Les différents blocs du pipeline y sont ainsi détaillés. Ensuite, la seconde partie, 2.2, se concentre davantage sur le bloc « Inférence », i.e. : le modèle d'apprentissage profond. Finalement, la dernière partie de cette section s'attarde sur les méthodes d'interactions qu'AEROSPACELAB a mises en place pour faciliter l'appropriation de SOL\_2019/20.

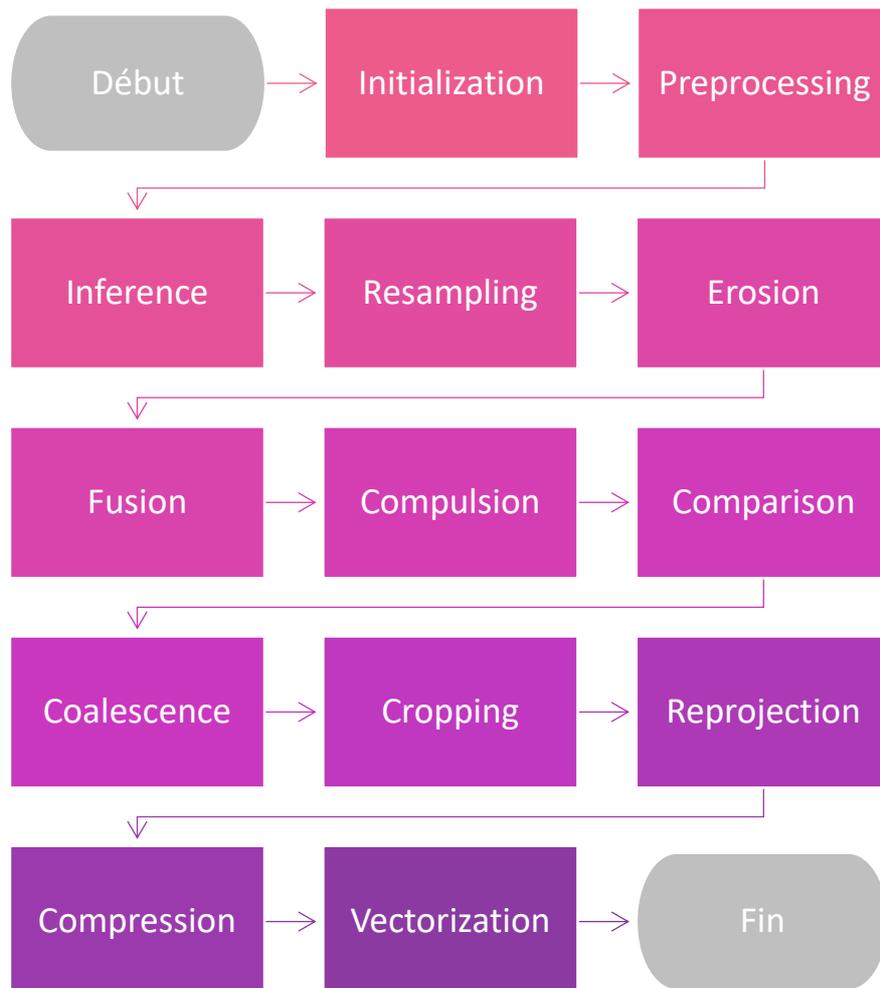
### 2.1. Pipeline

La solution regroupe plusieurs blocs chaînés successivement les uns aux autres. Cette chaîne est appelée pipeline et reçoit des données d'entrée qui sont traitées successivement par chacun des blocs afin de produire des données de sortie en fin de chaîne. Les données de sortie comprennent notamment les deux livrables mentionnés ci-dessus. D'autres données annexes peuvent également émaner de ce pipeline, comme les logs et paramètres de l'exécution par exemple.

La solution est composée de 13 blocs. Leur agencement est illustré à la Figure 1.

---

<sup>1</sup> Sous format vectoriel et sous forme de raster.



**Figure 1 - Pipeline de la solution. Les 13 blocs du pipeline de la solution**

Cette solution accepte donc en entrée les données brutes et la configuration des différents blocs et propose en sortie la nouvelle version des cartes d'occupation du sol et de changements.

Ci-dessous sont détaillés chacun de ces blocs dans leur ordre de positionnement dans le pipeline :

#### A. Initialization

Cette phase d'initialisation a pour but de vérifier les données fournies en entrée de pipeline et de préparer l'exécution de la solution selon les paramètres fournis. C'est notamment durant cette phase que les différentes bases de données sont réinitialisées, que la configuration de l'exécution est déterminée, et que la distinction entre une nouvelle exécution et la reprise de l'exécution précédente est faite.

En effet, la solution est adaptable grâce à un fichier de configuration fourni par l'utilisateur lors de chaque exécution. Ces paramètres de configuration permettent, entre autres, d'exécuter la solution sur une région prédéfinie, de changer la résolution de sortie, ou même de sauter certaines étapes facultatives.

#### B. Preprocessing

Le bloc Preprocessing applique un pré-traitement aux données d'entrée afin de préparer celles-ci pour le prochain bloc appliquant le modèle d'apprentissage profond. Il s'agit principalement de calculer, pour chaque maille, le MNH et de le concaténer à l'orthophoto.

#### C. Inference

Le bloc Inference est probablement le plus important de la solution puisque c'est celui qui génère la nouvelle version de la carte d'occupation des sols pour les classes principales. C'est donc ce bloc qui contient le modèle d'apprentissage profond.

A la sortie de ce bloc, on retrouve donc, pour chaque maille, la prédiction du modèle à une résolution spatiale identique aux données d'entrée, à savoir 0.25m/pixel.

Le modèle, ainsi que la manière dont il a été entraîné, sont présentés dans la prochaine partie : Modèle.

#### D. Resampling

Le bloc Resampling se charge du rééchantillonnage des prédictions faites par le modèle à une résolution spatiale de 1m/pixel. Ce bloc a été dissocié du précédent afin de faciliter une éventuelle transition future vers une plus haute résolution.

Cette étape est optionnelle.

#### E. Erosion

Ce bloc Erosion permet, une fois la résolution spatiale de la donnée de sortie établie grâce au bloc précédent, d'appliquer un MMU en remplaçant la classe assignée aux zones regroupant moins de pixels contigus appartenant à la même classe que le seuil requis, par la classe de la zone voisine la plus grande. Ainsi les petites zones entraînant un bruit sont masquées. Tel est le cas par exemple pour les trouées en forêts, ou encore certains abris de jardin, qui sont homogénéisés avec leur environnement immédiat.

Cette étape est optionnelle.

#### F. Fusion

Le bloc Fusion propose de fusionner des données vectorielles avec la donnée raster afin d'en dériver des doubles labels. Ce bloc n'altère pas les prédictions du modèle pour la classe « vue du ciel ». Un étalement de labels en résulte.

Cette étape est optionnelle.

#### G. Compulsion

Ce bloc Compulsion permet de forcer des données vectorielles sur la donnée raster obtenue à la suite de tous les blocs précédents. Ceci remplace donc irrémédiablement les données originales. Ce bloc est utile afin de corriger des zones spécifiques où le modèle se serait trompé dans ses prédictions.

Cette étape est optionnelle.

#### H. Comparison

Le bloc Comparison compare les données prédites par le modèle avec la version précédente de la carte d'occupation des sols. Cette comparaison est faite maille par maille et plusieurs paramètres de configuration y sont associés pour permettre notamment de faire cette comparaison uniquement sur les classes « vues du ciel ».

Cette étape est optionnelle.

#### I. Coalescence

Dans ce bloc Coalescence, les résultats obtenus pour chaque maille (i.e. résultats du bloc Compulsion et, optionnellement, du bloc Comparison) sont agglomérés et fusionnés dans leurs rasters respectifs.

#### J. Cropping

Ce bloc Cropping a la charge de rogner le raster sur base d'une zone d'intérêt prédéfinie. Par défaut, le rognage se fait sur le territoire wallon.

Cette étape est optionnelle.

#### K. Reprojection

Le bloc Reprojection permet d'aligner la donnée raster à une grille prédéfinie ainsi que de projeter les données dans un nouveau référentiel de coordonnées spatiales. Ainsi si les données d'entrée sont en Lambert Belge 72, il est possible avec ce bloc de projeter les données de sortie en Lambert Belge 2008 au lieu de les obtenir en Lambert Belge 72.

Cette étape est optionnelle.

#### L. Compression

Ce bloc de post-traitement a pour but de compresser la/les donnée(s) raster afin d'en réduire la taille du fichier.

Cette étape est optionnelle.

#### M. Vectorization

Le dernier bloc se charge de la vectorisation (sans simplification) du/des raster(s) :

- WAL\_OCS\_IA\_2019/20
- WAL\_OCS\_CHA\_IA\_\_2018\_2019/20

Cette étape est optionnelle.

## 2.2. Modèle

Le modèle d'apprentissage profond implémenté dans le bloc 3 est le fruit de nombreuses itérations réalisées durant la deuxième Phase.

### 2.2.1. Architecture

Ce modèle de segmentation est basé sur l'architecture DEEPLABV3+, proposée par GOOGLE en 2017 (Chen, et al. 2017), et implémenté avec les bibliothèques DETECTRON 2<sup>2</sup> et PYTORCH<sup>3</sup>, toutes deux développées par FACEBOOK AI RESEARCH. Cette architecture a été sélectionnée pour ses performances prouvées à de nombreuses reprises sur diverses applications, sa maturité, et la disponibilité de modèles pré-entraînés. Les bibliothèques ont, quant à elles, été choisies pour leur aspect open-source, leur implémentation permettant un rapide prototypage, et la taille de leurs communautés.

L'architecture DEEPLABV3+ d'origine, comprenant un squelette RESNET de profondeur 101, a été adaptée pour pouvoir accueillir en entrée des données avec plus de 3 bandes et proposer en sortie une prédiction pour chacune des 11 classes principales.

Cette architecture doit en partie ses performances à l'utilisation de convolutions « Atrous » permettant d'exponentiellement inclure davantage d'information dans les champs de perception (Chen, et al. 2017).

La configuration du modèle dans DETECTRON 2 est proposée en Annexes 9.1.

### 2.2.2. Données d'entrée

Afin de faire ses prédictions (i.e. données de sortie), le modèle reçoit des données d'entrée. Celles-ci sont composées des orthophotos et du MNH.

---

<sup>2</sup> Pour plus d'information sur cette bibliothèque : <https://ai.facebook.com/blog/-detectron2-a-pytorch-based-modular-object-detection-library/>, et <https://github.com/facebookresearch/detectron2>

<sup>3</sup> Pour plus d'information sur cette bibliothèque : <https://pytorch.org/> et <https://github.com/pytorch/pytorch>

Les données d'entrée du modèle ont les dimensions suivantes :

$$B \times Ch \times H \times L$$

#### Equation 1 - Dimensions des données d'entrée du modèle

Où  $B$  est la taille du batch (i.e. : le nombre de vignettes dans un batch),  $Ch$  le nombre de « channels » / bandes,  $H$  la hauteur d'une vignette (i.e. : première dimension spatiale),  $L$  la largeur d'une vignette (i.e. : deuxième dimension spatiale).

Les deux dimensions spatiales,  $H$  et  $L$ , ayant été fixées à 512, en utilisant la résolution spatiale native des orthophotos de 0.25m/pixels, chaque vignette couvre une zone maximale de 128x128m<sup>2</sup>. Le nombre de bandes,  $Ch$ , est de 5 puisque les 4 bandes de l'orthophoto sont utilisées et à celles-ci la bande du MNH est rajoutée. La taille du batch,  $B$ , est, quant à elle, flexible car celle-ci dépend en grande partie de la mémoire interne de la carte graphique sur laquelle le modèle est entraîné ou utilisé pour de l'inférence. Au plus cette mémoire est élevée, au plus le nombre de vignettes dans un batch peut augmenter et le temps d'exécution diminuer et, vice versa, si cette même mémoire est limitée.

Concernant les orthophotos, la version 16 bits est utilisée afin de bénéficier des nuances qu'elle contient par rapport à la version 8 bits. Les bandes spectrales correspondantes au domaine du visible pour les longueurs d'onde associées au rouge (R), vert (G), et bleu (B), ainsi qu'une bande spectrale liée à l'infrarouge (IR). Les orthophotos sont donc directement coupées en vignettes de 512x512 pixels. La résolution spatiale native est conservée pour donner au modèle le plus de détails possibles.

Le MNH est lui dérivé de la soustraction du MNT au MNS. Le MNT découle des acquisitions LIDAR faites entre 2013 et 2014, alors que le MNS est spécifique à chaque année et est obtenu par photogrammétrie. La résolution spatiale (au sol par pixel) du MNT étant de 1m et celles des MNS variant entre 0.5 et 1m, ces données furent rééchantillonnées dans la même résolution spatiale que les orthophotos pour pouvoir dériver le MNH. Les éventuelles données négatives du MNT furent bornées à 0 avant le calcul du MNH. Ensuite, les valeurs du MNH furent également bornées arbitrairement entre -5 et 25m afin de conserver les valeurs négatives pouvant indiquer la présence de carrières à ciel ouvert, et les valeurs positives pour la distinction des classes dont la discrimination se fait sur base de la hauteur. Le seuil maximal de 25m a été choisi pour garder les informations sur la canopée des arbres qui peuvent s'avérer utiles pour distinguer les feuillus des résineux.

En concaténant et recadrant les données de l'orthophoto et du MNH, des vignettes sont obtenues regroupant, dans l'ordre, les bandes suivantes : R, G, B, IR, MNH. Avant d'être soumises au modèle, ces données sont normalisées<sup>4</sup> sur base de la variance et moyenne observées sur un échantillon aléatoire du jeu de données d'entraînement. Cette normalisation permet de faciliter la convergence du modèle en ramenant sur la même échelle/intervalle de valeurs les différentes bandes.

### 2.2.3. Données de sortie

En sortie, le modèle propose une donnée aux dimensions suivantes :

$$Cl \times H \times L$$

#### Equation 2 - Dimensions des données de sortie du modèle

Où  $Cl$  est le nombre de classes / labels,  $H$  la hauteur d'une vignette (i.e. : première dimension spatiale),  $L$  la largeur d'une vignette (i.e. : deuxième dimension spatiale).

Les deux dimensions spatiales,  $H$  et  $L$ , sont les mêmes que celles de la donnée d'entrée. Et le nombre de classes,  $Cl$ , est de 11 puisqu'il y a autant de classes principales.

Ainsi à chaque classe principale est associée une matrice  $H \times L$  assignant pour chaque pixel une valeur prédite par le modèle directement proportionnelle avec sa probabilité d'appartenance à cette classe. On obtient donc la classe à associer à chaque pixel en regardant la classe liée au score le plus élevé sur la première dimension (i.e. : *argmax*).

Les prédictions faites par le modèle représentent la situation vue du ciel.

<sup>4</sup> Variance unitaire et moyenne nulle.

#### 2.2.4. Entraînement

Puisque le modèle choisi fait partie des « eager learners », celui-ci doit être entraîné afin d'apprendre une représentation des données afin de les généraliser globalement. Ainsi cet entraînement a pour but de modéliser les données d'entrées tout en évitant l'overfitting. Cela se fait en ajustant les poids (et biais<sup>5</sup>) du modèle. Une fois ces poids ajustés, le jeu de données d'entraînement ne sera plus nécessaire.

Comme mentionné plus haut, le modèle a été entraîné de manière supervisée. Cela signifie que pour son apprentissage, le modèle bénéficiait de données labélisées : réalité-terrain. Ces données sont utilisées, à chaque itération<sup>6</sup>, pour comparer les prédictions du modèle à la réalité-terrain et en dériver un score découlant de la fonction objectif. Ce score est ensuite utilisé pour ajuster les poids internes du modèle via un mécanisme, appelé backpropagation, qui en dérive le gradient pour chacun des poids.

Ainsi l'entraînement du modèle se fait en deux phases. Dans un premier temps, il est demandé au modèle de faire ses prédictions pour un set de vignettes (regroupée dans un batch). Pour se faire, les poids du modèle sont fixés et l'information passe de l'entrée à la sortie du modèle. Pour chacune des prédictions sur une vignette, la fonction objectif est utilisée pour évaluer la pertinence de ces prédictions en comparaison avec la réalité-terrain associée à la vignette. Les scores obtenus sont sommés et la résultante est utilisée dans la deuxième phase de l'entraînement. Dans cette deuxième partie, les poids du modèle vont être ajustés grâce à la backpropagation en commençant par les poids les plus proches de la sortie du modèle pour ensuite remonter vers ceux proches de l'entrée.

Comme mentionné ci-dessus, la solution présentée est le fruit de nombreuses itérations, ainsi l'entraînement du modèle s'est fait graduellement et par étape. Le lecteur est redirigé vers la documentation sur les itérations (Rapport\_Itérations) pour obtenir plus de détails sur l'entraînement de ce modèle. Néanmoins, cet entraînement peut se résumer avec les étapes principales suivantes :

- Initialisation du modèle avec les poids pré-entraînés sur IMAGENET<sup>7</sup> ;
- Entraînement succinct du modèle sur base des orthophotos de 2018, et WAL\_OCS\_2018
- Poursuite de l'entraînement sur base des orthophotos et du MNH de 2018 et 2020, et WAL\_OCS\_2018

#### 2.2.5. Réalité-terrain

La réalité-terrain utilisée pour calculer le score de la fonction objectif est dérivée de la carte d'occupation du sol de Wallonie de 2018. En effet, seuls les labels représentant les classes « vues du ciel » ont été gardées ainsi les doubles labels n'ont pas été considérées puisque l'objectif du modèle est de prédire les classes visibles sur les données d'entrée (i.e. les classes « vues du ciel »). La donnée réalité-terrain est donc constituée des 11 classes principales. Chaque pixel se voit assigner une de ces 11 classes et la donnée d'origine, WAL\_OCS\_2018, a été rééchantillonnée pour obtenir une résolution spatiale de 0.25m afin que celle-ci corresponde à celle de la donnée de sortie du modèle.

De plus, les points inclus dans les VAL\_Set et Test\_Set ont été masqués de la réalité-terrain afin de ne pas montrer ceux-ci au modèle lors de son entraînement et de les réserver pour sa validation et son évaluation. Ainsi, pour chaque point du VAL\_Set et TEST\_Set, tous les pixels contenus dans le carré de 100m<sup>2</sup> centré sur le point ont été masqués.

### 2.3. Interactions

---

<sup>5</sup> Par simplicité, la suite du rapport inclura implicitement l'ajustement des biais lorsqu'il sera fait mention de l'ajustement des poids du modèle.

<sup>6</sup> Le terme « itération » n'est pas à confondre avec les itérations de la Phase II. Dans ce contexte, une itération correspond aux prédictions du modèle pour l'ensemble des vignettes d'un batch.

<sup>7</sup> IMAGENET est un jeu de données labélisé de référence pour le pré-entraînement des modèles et le benchmarking. Pour plus d'information : <https://www.image-net.org/>

Il y a deux manières prévues pour interagir avec la solution. Soit directement par ligne de commande, soit indirectement via le RESTAPI. Alors que la première approche s'adresse plus à une audience familière avec PYTHON, la deuxième est accessible à un plus grand nombre.

Pour plus d'information sur les interactions possibles avec la solution, le lecteur est invité à se référer à la documentation accompagnant les ateliers techniques.

## 3. Résultats

Le modèle a été évalué sur le TEST\_Set et les résultats ont été compilés dans des matrices de confusion similaires à celle utilisée pour évaluer SOL\_2018, c'est-à-dire en regroupant et pondérant les résultats par strate. Ce TEST\_Set est composé de 1710 points photo-interprétés et contre-validés pour chacune des deux années, 2019 et 2020. Les résultats de ces évaluations sont présentés dans les Figures suivantes :

## TEST\_Set\_2019

Classes réelles	Classes prédites									PA
	Revet. art. au sol	Const. art. hors sol	Eau	Couv. herb. permanent	Couv. herb. rotation	Sols nus	Feuillus	Résineux	PA	
Revet. art. au sol	789			5		1	8			804 98.11%
Const. art. hors sol	32	233		2						268 86.96%
Eau			141	11						153 92.28%
Couv. herb. permanent	8			2813	97	1	9	5		2936 95.81%
Couv. herb. rotation					2283		49			2421 94.30%
Sols nus	14		6	86		54	6			168 32.32%
Feuillus				87			2185	48		2321 94.15%
Résineux				117	10		224	574		927 62.01%
UA	844 93.39%	233 100%	149 94.74%	3211 87.60%	2390 95.50%	57 95.03%	2483 88.01%	629 91.35%	9999 90.75%	

n = 1710

UA: User Accuracy, PA: Producer Accuracy

Figure 3 - Evaluation du modèle sur le TEST\_Set\_2019

## TEST\_Set\_2020

Classes réelles	Classes prédites									PA
	Revet. art. au sol	Const. art. hors sol	Eau	Couv. herb. permanent	Couv. herb. rotation	Sols nus	Feuillus	Résineux	PA	
Revet. art. au sol	792			11	2	3				810 97.75%
Const. art. hors sol	31	197		2						231 85.52%
Eau			111	1						112 98.93%
Couv. herb. permanent	11			2775	78	5		5		2879 96.38%
Couv. herb. rotation					2332		27	17		2448 95.24%
Sols nus	5		1	146	5	68				228 29.94%
Feuillus				863			1430	71		2388 59.92%
Résineux				146			82	671		900 74.56%
UA	866 91.43%	199 98.99%	113 98.34%	4015 69.12%	2419 96.40%	77 88.40%	1541 92.83%	765 87.61%	9999 83.80%	

n = 1710

UA: User Accuracy, PA: Producer Accuracy

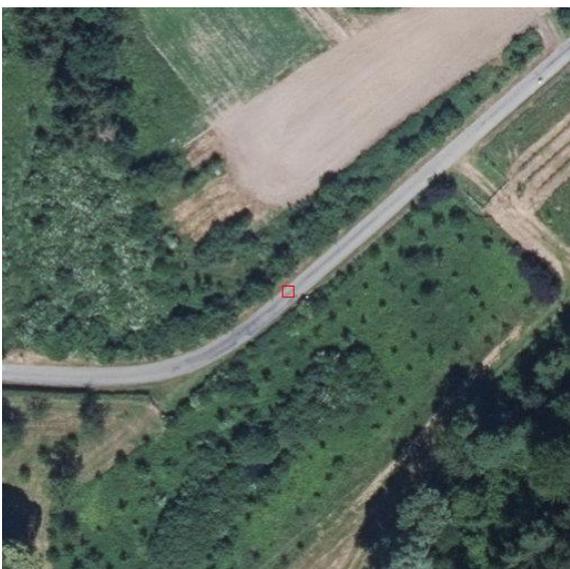
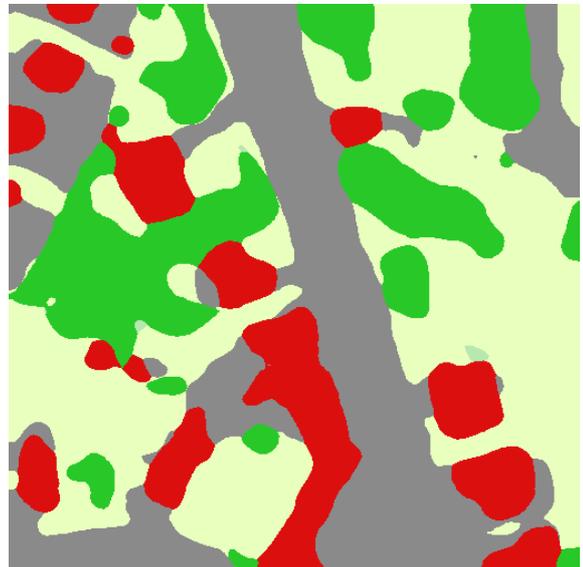
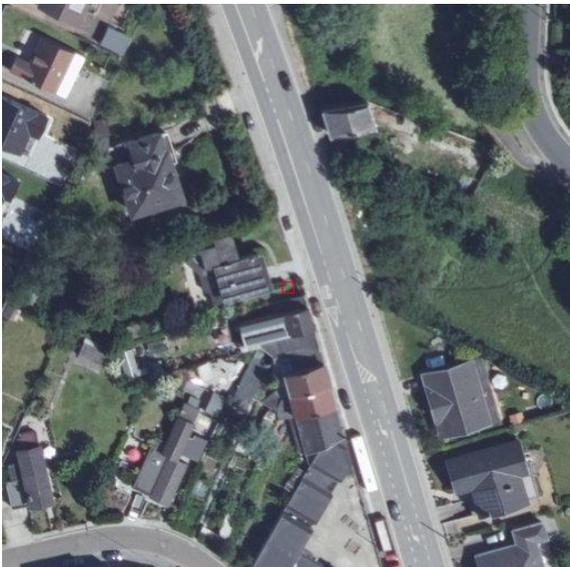
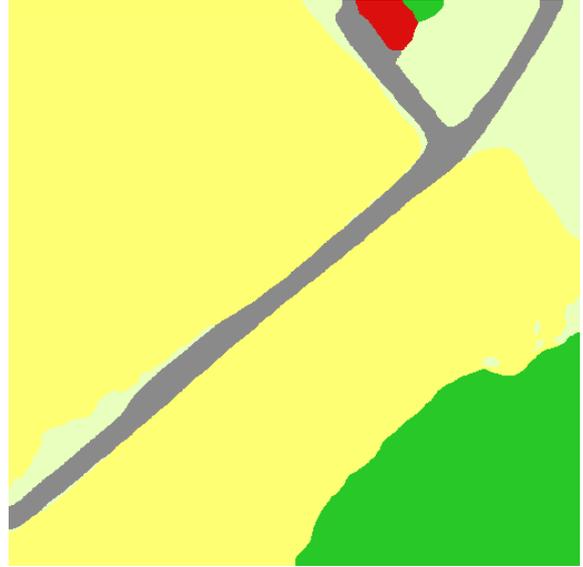
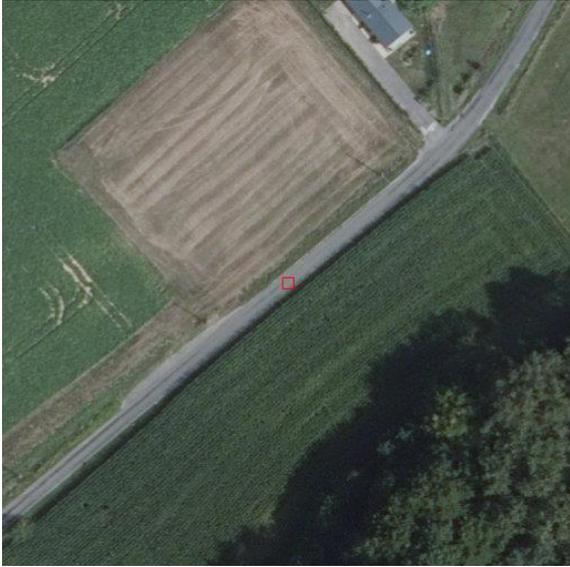
Figure 2 - Evaluation du modèle sur le TEST\_Set\_2020

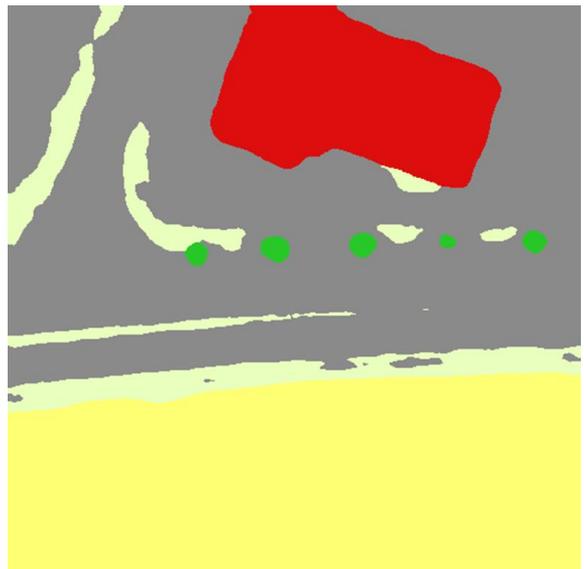
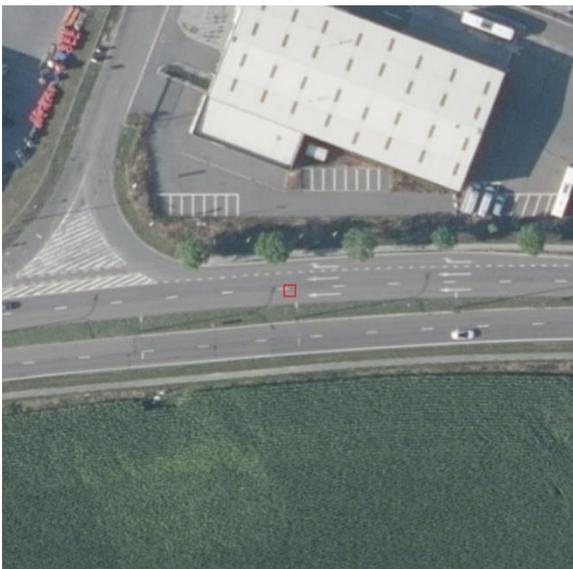
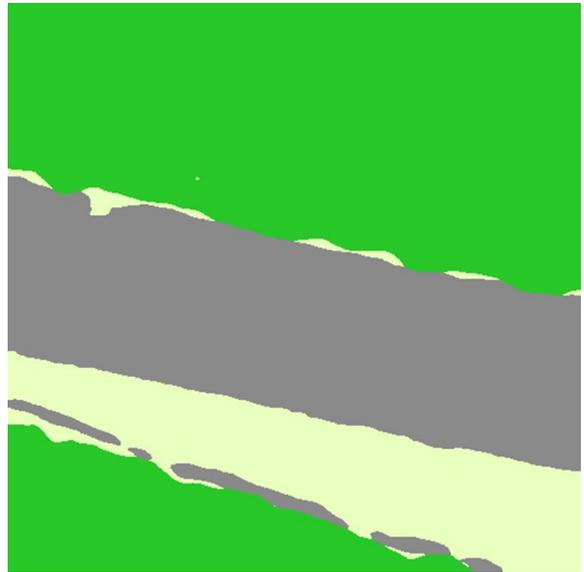
Les résultats obtenus sur le TEST\_Set sont similaires à ceux obtenus sur le VAL\_Set, ce qui conforte l'idée qu'il n'y a pas eu d'overfitting.

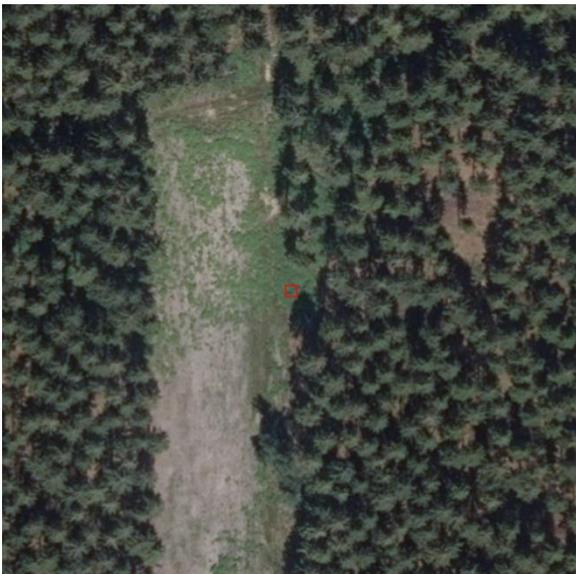
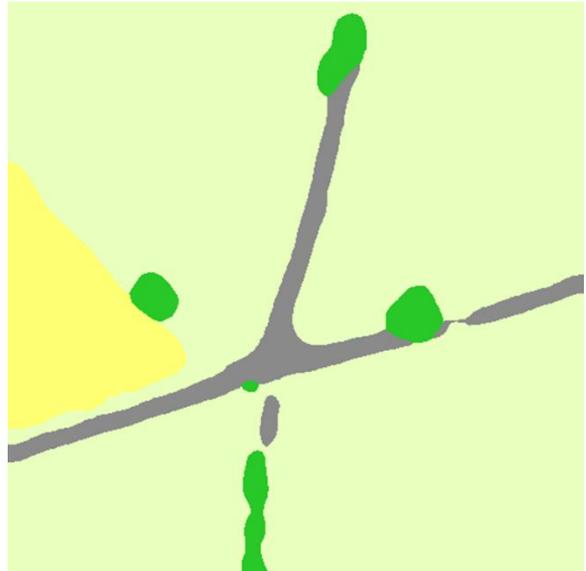
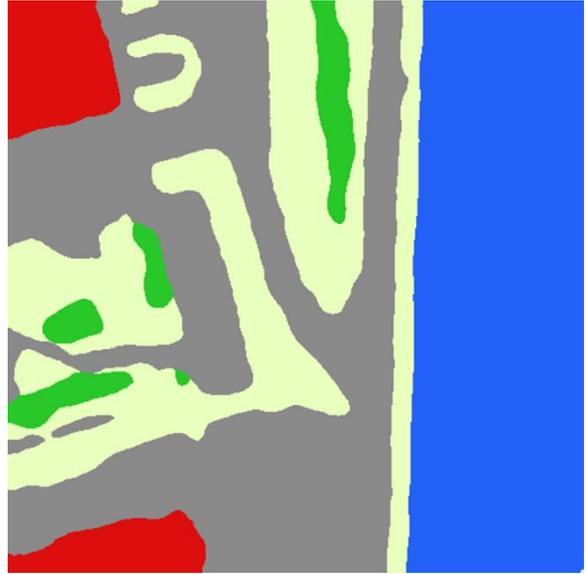
Plusieurs constats peuvent être tirés de ces résultats :

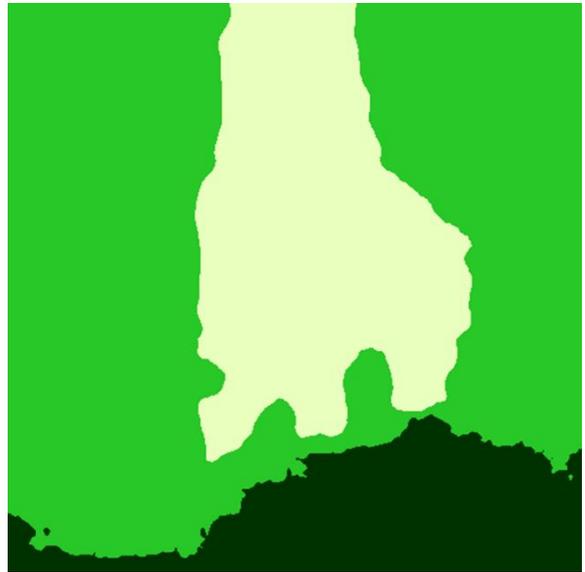
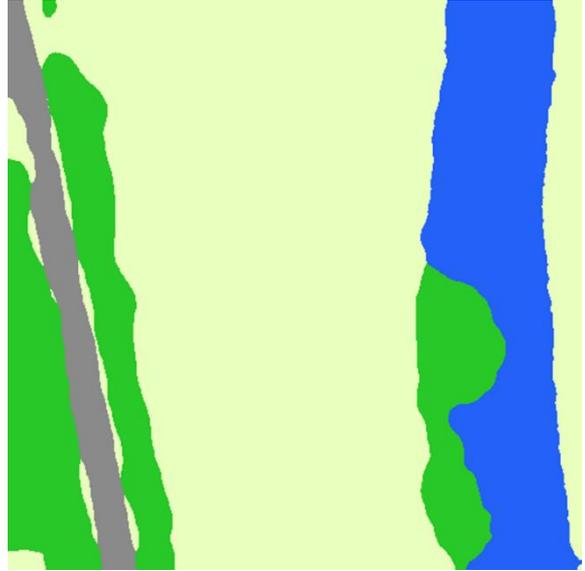
- La précision (UA) du modèle est bonne, autour des 90%, sur l'ensemble des strates, particulièrement pour 2019. Le corolaire implique que les erreurs de commissions sont limitées.
- Le rappel (PA) du modèle est bonne sur la majorité des strates à l'exception des « Sols nus » et des « Résineux » en 2019, et des « Feuillus » en 2020. Le faible rappel de la classe « Sols nus » s'explique par le fait que cette classe est la moins représentée dans WAL\_OCS\_2018. Ainsi, durant son entraînement, la classe des « Sols nus » est celle qui a le moins été vue par le modèle. De plus, le faible rappel de cette strate (36,8%) dans WAL\_OCS\_2018 implique que les données d'entraînement sont loin d'être fiables pour cette classe. Concernant le faible rappel de la strate « Feuillus » en 2020, ceci est dû à la période d'acquisition plus précoce des orthophotos qui implique un manque de végétation générale et plus particulièrement une absence de feuilles sur les feuillus. Ceci présente une difficulté pour le modèle puisque les signatures spectrales sont très similaires en cas d'absence de végétation. De même, l'absence de feuilles sur les arbres impacte le MNH.
- Les performances du modèle sont généralement moins bonnes en 2020, en comparaison avec 2019. Cette baisse de performance observée sur le TEST\_Set\_2020 est majoritairement liée au fait que les données de 2020 sont trop différentes de celles utilisées pour entraîner le modèle. En effet, il est important que les données d'entraînement soient représentatives des données sur lesquelles le modèle devra se prononcer par la suite. Or ces données d'entraînement sont constituées en majeure partie de données de 2018. Puisque les données d'entrée de 2019 qui ont été acquises dans la même période de l'année que celles de 2018, les résultats sur le TEST\_Set\_2019 sont comparables à ceux obtenus sur le VAL\_Set\_2018. Cependant, les données d'entrée de 2020 ont été acquises plus tôt dans l'année impliquant des différences notoires notamment pour les classes naturelles à cause d'une baisse de végétation en cette période plus précoce. Ainsi des zones où l'herbe n'a pas encore poussée peuvent être confondues avec un sol nu. De même, les cultures des parcelles agricoles ne sont pas encore visibles. Ceci est illustré à la Figure 5.

Ci-dessous sont regroupés plusieurs exemples illustrant les performances du modèle pour l'année 2019 :









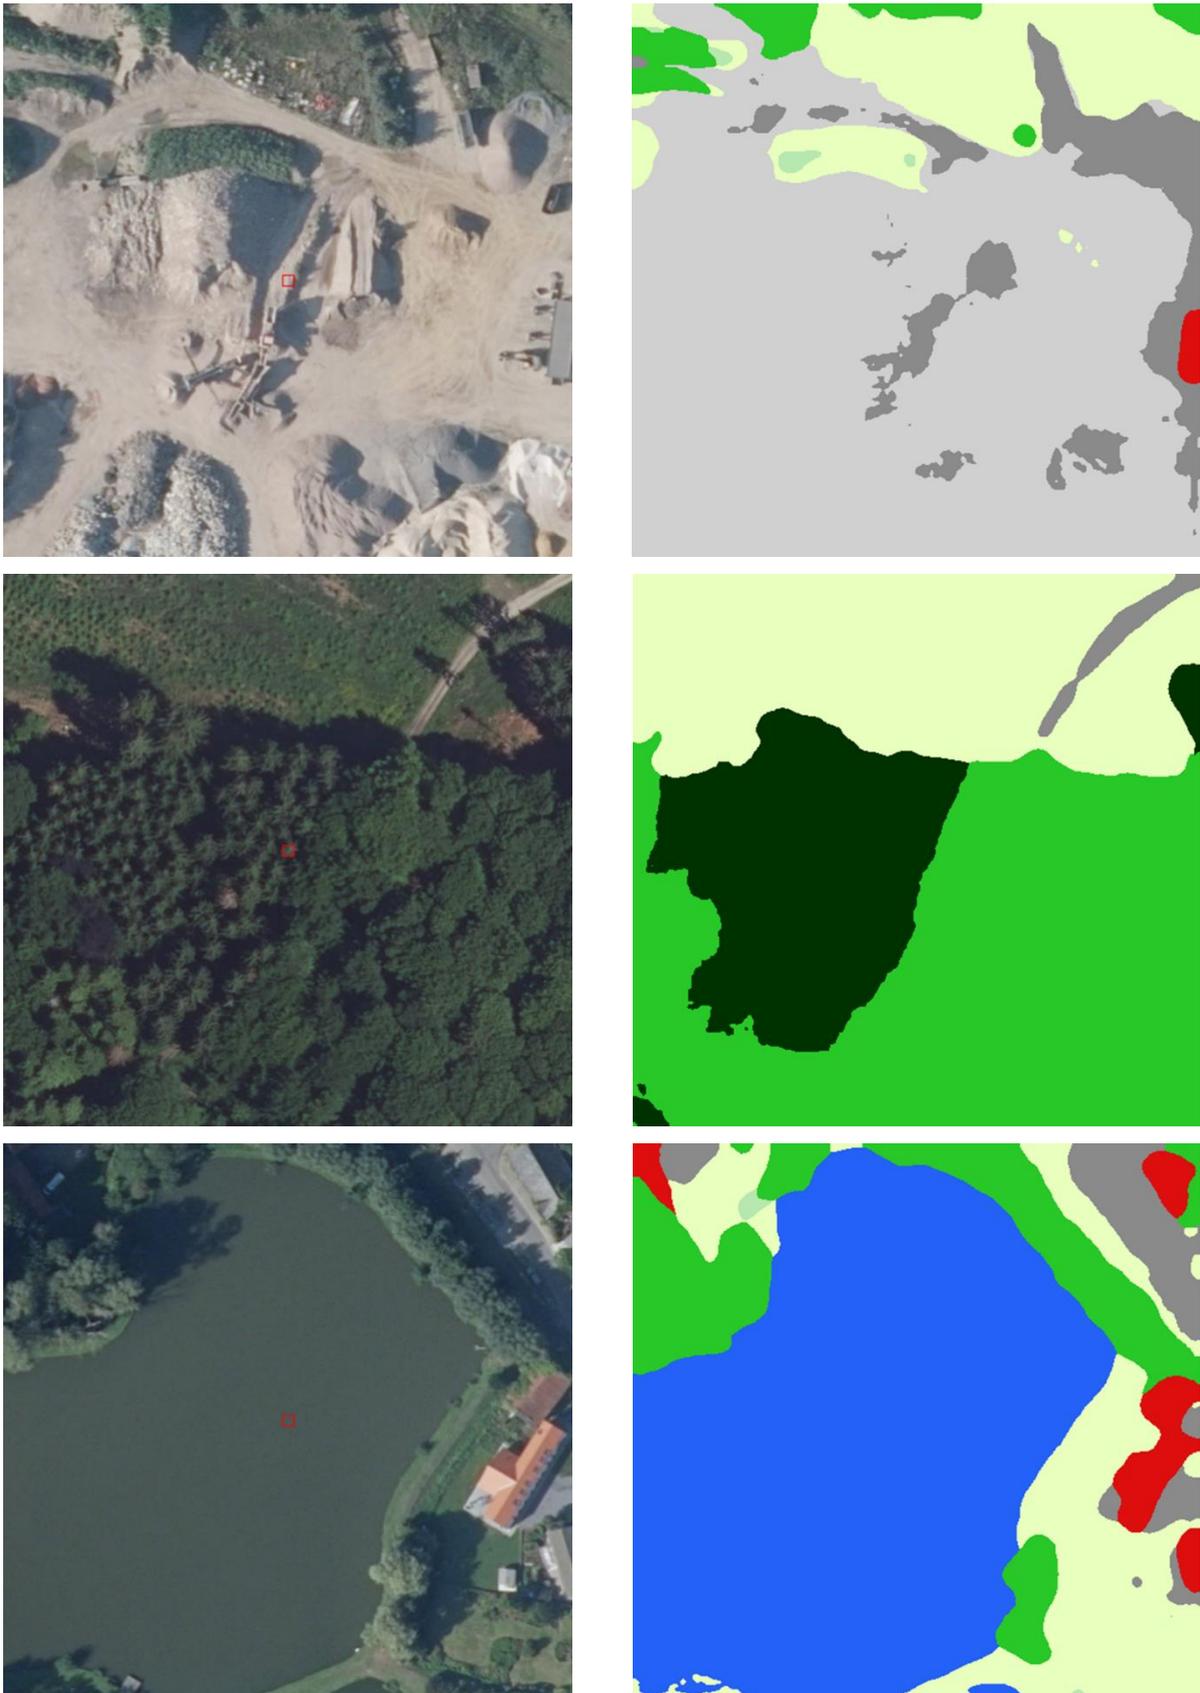
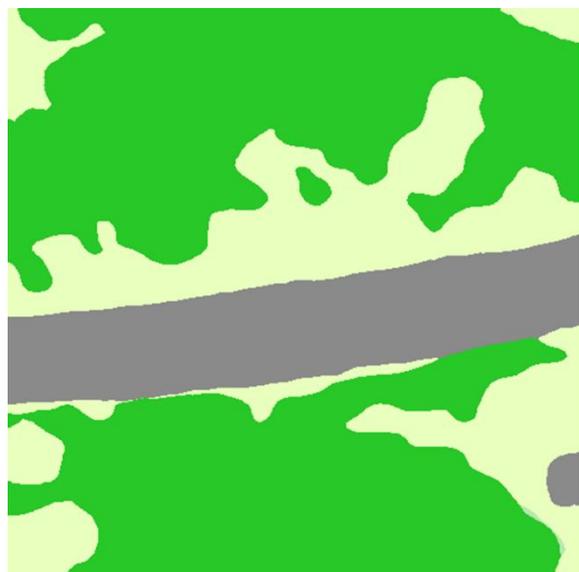
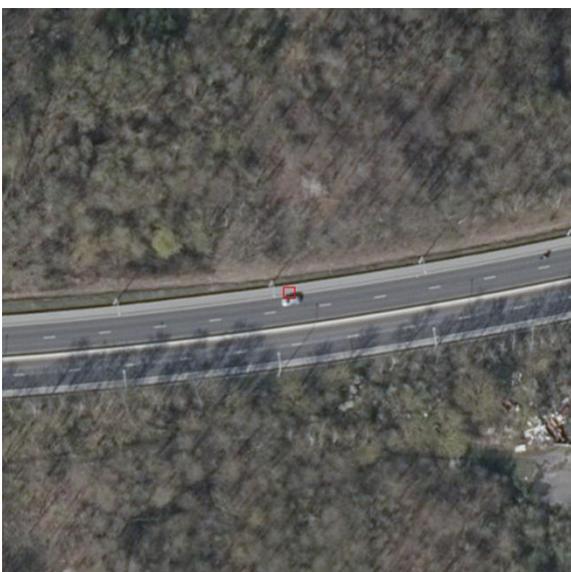
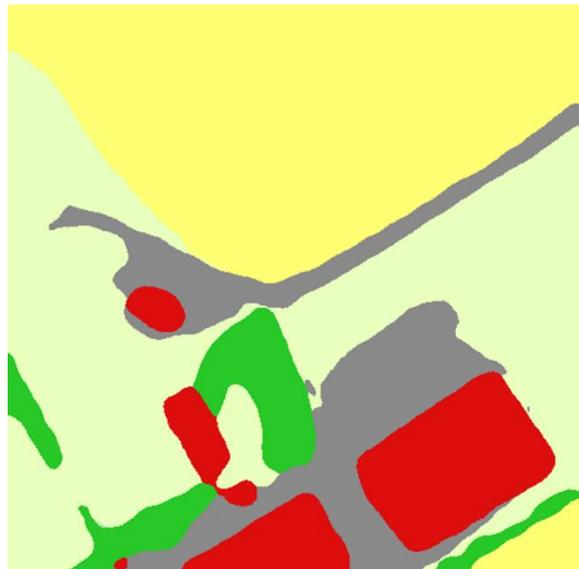
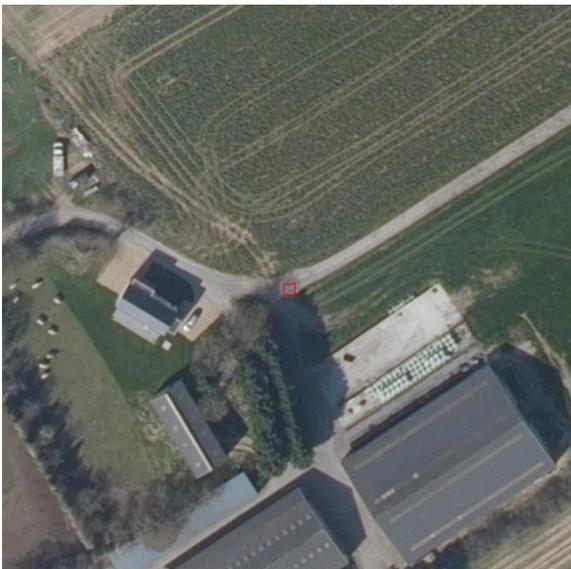
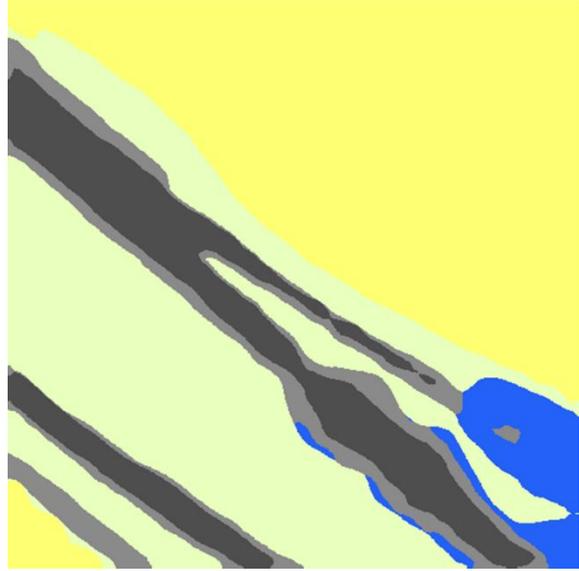
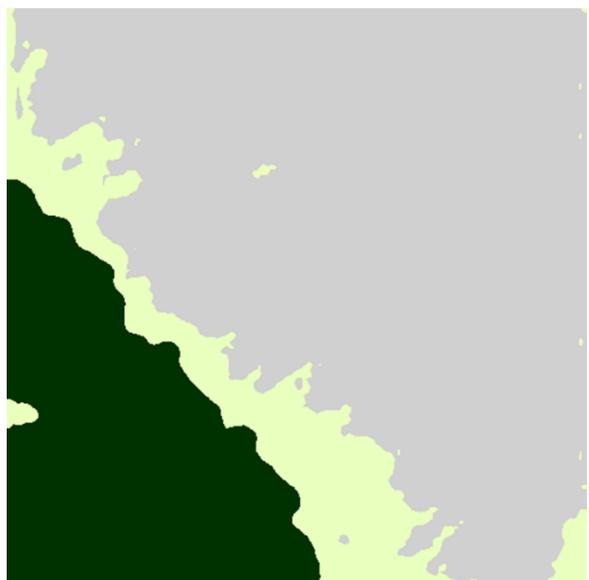
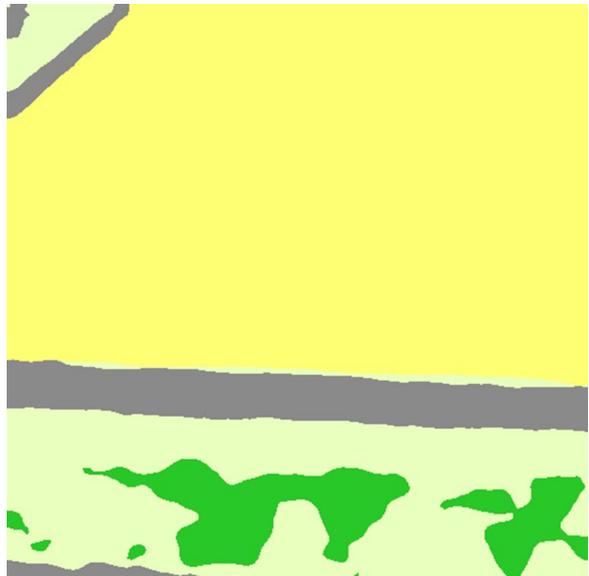
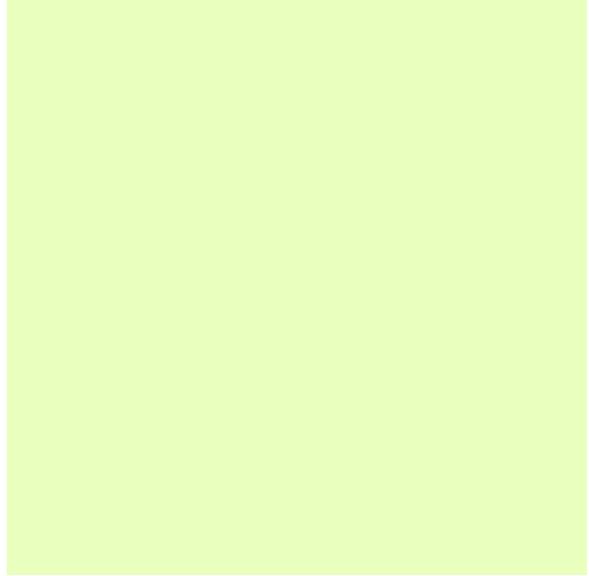
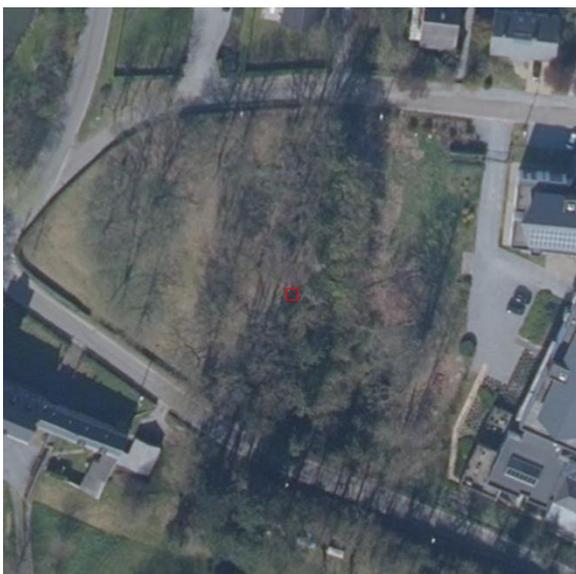
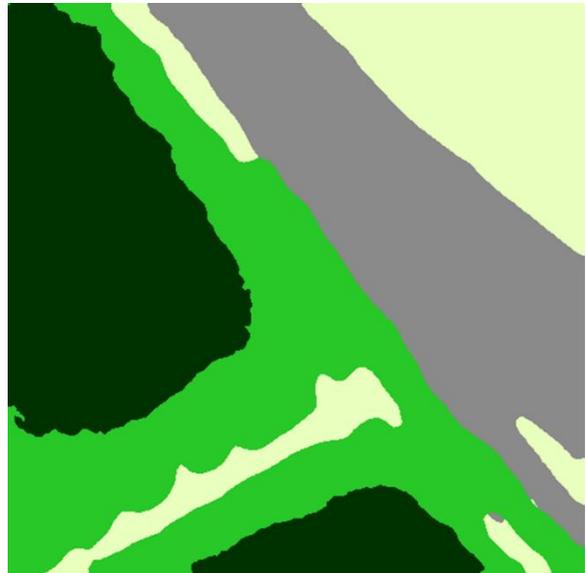
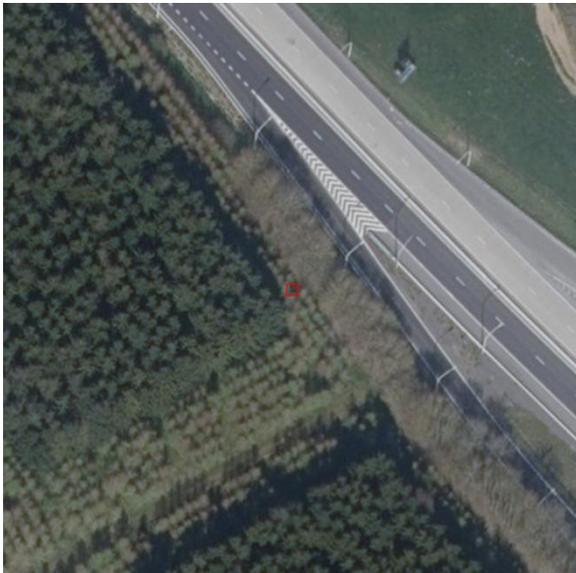


Figure 4 - Prédications du modèle sur les données de 2019.  
Prédications (à droite) sur base des orthophotos (à gauche) et MNH de 2019. Résolution spatiale des prédictions : 0.25m.

Ci-dessous sont regroupés plusieurs exemples illustrant les performances du modèle pour l'année 2020 :







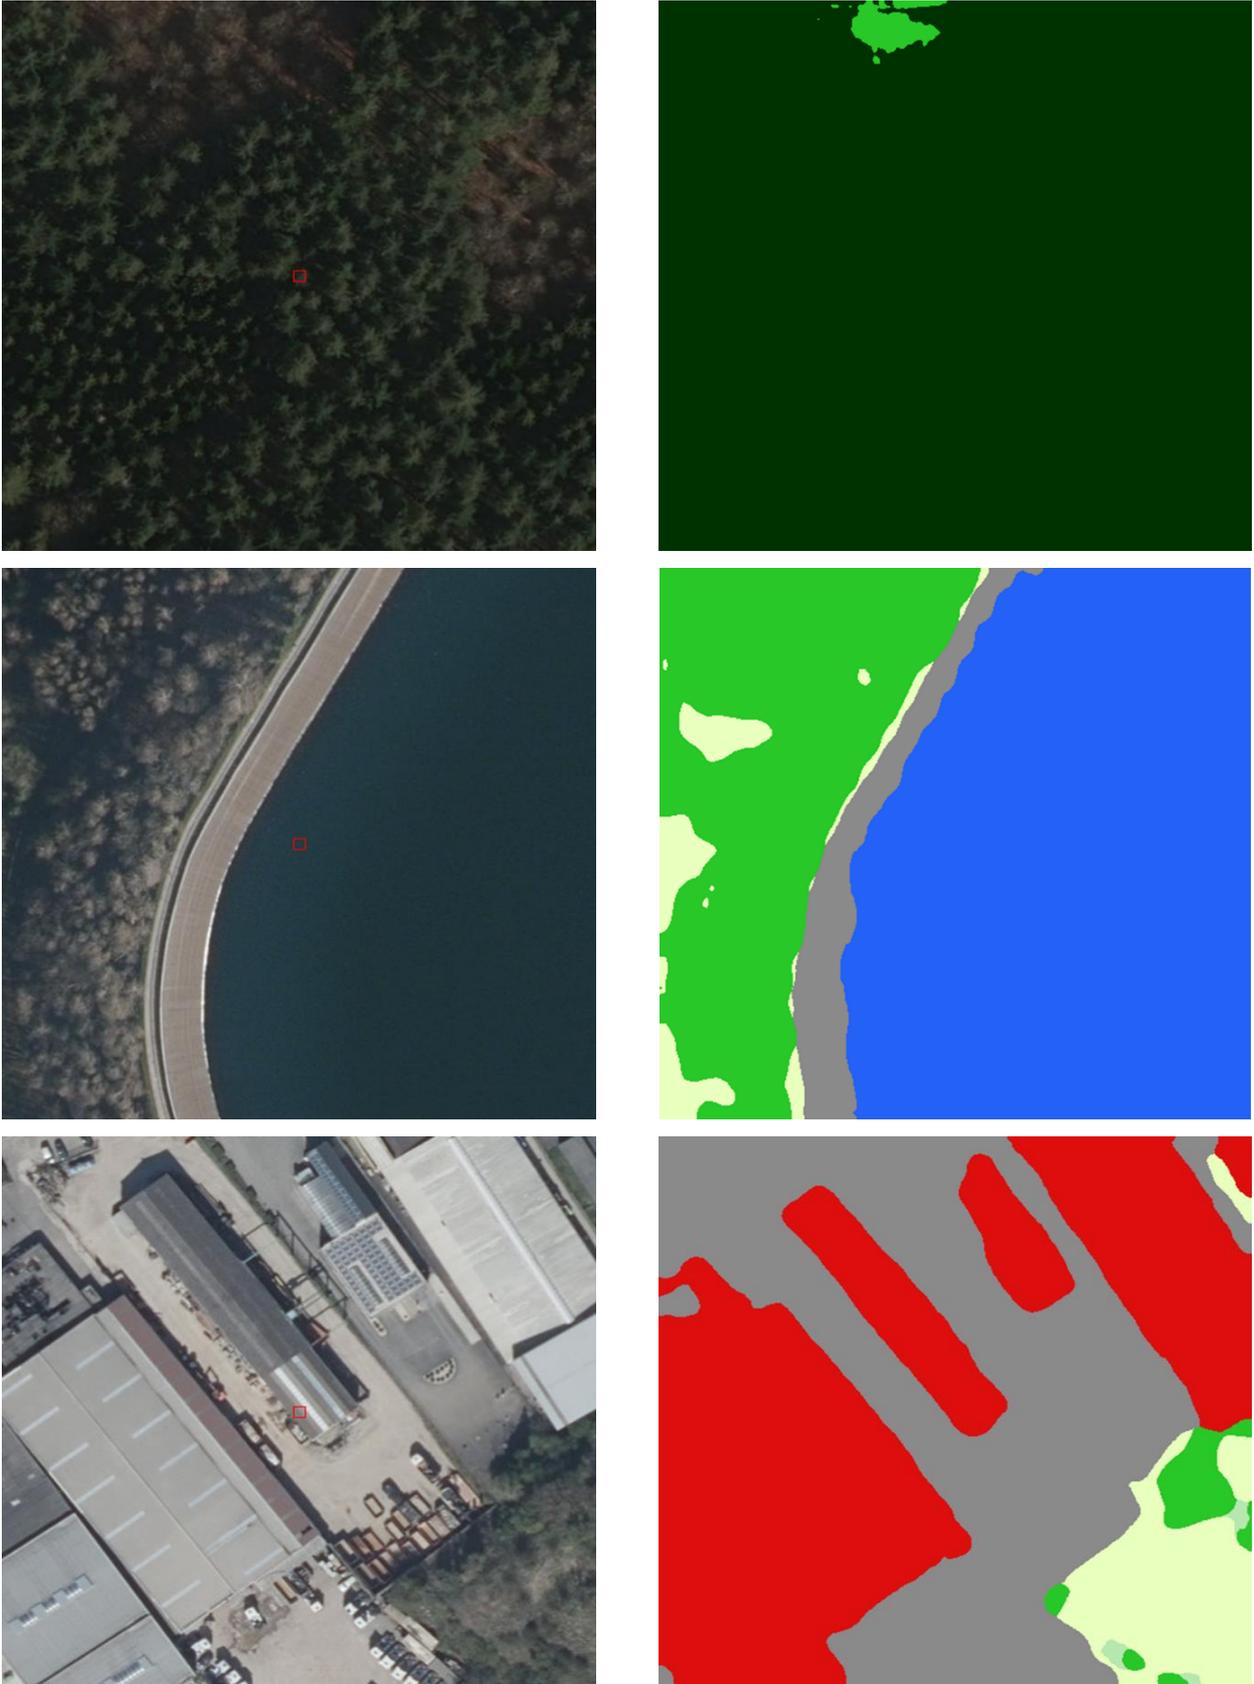


Figure 5 - Prédications du modèle sur les données 2020.  
Prédications (à droite) sur base des orthophotos (à gauche) et MNH de 2020. Résolution spatiale des prédictions : 0.25m.

## 4. Comparaison avec WAL\_OCS\_2018

Comme discuté dans la documentation « Rapport\_Itérations », plusieurs facteurs ont influencé le choix de cette solution. Parmi les plus importants sont son haut degré d'automatisation, sa généralisation et robustesse, et sa faible dépendance sur les sources de données.

### a) Haut degré d'automatisation

Aussi bien la phase d'entraînement que celle d'inférence présentent un haut degré d'automatisation. En effet, une fois le jeu de données labélisé et les hyperparamètres d'optimisation sélectionnée, le modèle s'entraîne de manière autonome et choisit librement les caractéristiques à extraire des données d'entrée afin d'optimiser ses performances à la tâche donnée. Outre le choix des hyperparamètres, et la labélisation du jeu de données dans le cas d'un entraînement supervisé, aucune autre intervention manuelle n'est nécessaire pour entraîner le type de modèle choisi. De plus, une fois que celui-ci a été entraîné et que ses poids sont figés, le modèle est disposé à faire de l'inférence sur de nouvelles données. Dans la solution implémentée, aucune étape manuelle n'est prévue pour consolider les prédictions du modèle.

Cet avantage permet au SPW de s'approprier plus aisément la solution finale car les connaissances techniques requises pour son exécution sont limitées.

### b) Généralisation/robustesse

Les modèles d'apprentissage profond peuvent facilement « overfitter » si aucun mécanisme de prévention n'est implémenté. En effet, suivant leur profondeur, leur nombre de paramètres, et la dimension des données d'entrée, il est possible que ces modèles mémorisent les données d'entrée et les données de sortie à leur associer. L'apprentissage du modèle est alors inutile puisqu'il ne sera pas capable de faire des prédictions cohérentes sur de nouvelles données non vues à l'entraînement. Il est donc souhaitable d'avoir un modèle capable de généraliser les notions apprises lors de l'entraînement pour pouvoir ultérieurement les appliquer sur des nouvelles données. Un tel modèle est alors considéré comme robuste et restera performant sur de nouvelles données pour autant que les données d'entraînement soient représentatives des données sur lesquelles le modèle devra se prononcer. Compte tenu des performances du modèle qui sont similaires sur le VAL\_Set et TEST\_Set, il peut être conclu que le modèle est robuste.

De plus, aucune règle prédéfinie n'a été explicitement implémentée pour ajuster les prédictions du modèle. Ces règles définies manuellement peuvent en effet être très difficiles à généraliser pour prendre en compte toutes les exceptions.

Cet aspect du modèle permet au SPW d'appliquer le modèle sur les futures orthophotos pour autant que celles-ci soient comparables à celles contenues dans le jeu de données d'entraînement.

### c) Faible dépendance

En mode inférence, le modèle n'a besoin que des orthophotos, du MNT qui peut en être dérivé via photogrammétrie, et du MNS comme données d'entrée. Puisque le MNS ne nécessite pas d'être mis à jour régulièrement, uniquement de nouvelles orthophotos sont indispensables pour mettre à jour la carte d'occupation du sol. Il n'est donc pas nécessaire d'attendre que d'autres bases de données externes soient mises à jour avant de pouvoir considérer la génération d'une nouvelle édition de la carte d'occupation du sol.

Cette dépendance unique permet au SPW de mettre à jour la carte d'occupation du sol dès l'acquisition de nouvelles orthophotos.

Puisque la nouvelle solution se base uniquement sur les orthophotos et le MNH, elle ne force pas de données provenant d'autres sources. Cela implique plusieurs différences notoires avec WAL\_OCS\_2018, parmi celles-ci ;

- Absence de double labels

Dans les situations d'étalement de classes (e.g. : une route masquée par le feuillage d'un arbre), puisque les orthophotos ne contiennent pas d'information sur la classe masquée/du dessous, le modèle ne peut pas prédire de manière fiable cette classe. Uniquement la classe « vue du ciel » est prédite.

Le marché prévoyait l'insertion des double labels après la mise à jour de ceux-ci par le SPW via l'utilisation de données externes. Cependant, cela n'a pas été rendue possible à cause du manque de documentation sur le sujet.

De plus, l'ajout des double labels via des sources de données externes irait à l'encontre du principe visant à limiter autant que possible les dépendances. Il faudrait dans ce cas attendre que toutes ces sources soient mises à jour afin de dériver les double labels.

- Empreinte des « Constructions artificielles hors sol »

Puisque les données du PICC furent utilisées pour forcer l'empreinte des bâtiments de la classe « Constructions artificielles hors sol » dans WAL\_OCS\_2018, l'empreinte de ces bâtiments sur la carte d'occupation du sol correspond au cadastre ce qui n'est pas toujours équivalent à l'empreinte du bâtiment sur l'orthophoto. En effet, toute capture d'orthophotos avec un angle de prise de vue « off-nadir » déforme le bâtiment engendrant des zones d'occlusion. De la même manière que pour les double labels, le modèle est incapable sur base d'une seule image de déterminer les classes qui sont masquées par d'autres. Ainsi le modèle segmente le bâtiment tel qu'il apparaît sur les orthophotos et le MNH. Un exemple de ces décalages entre empreinte du bâtiment sur l'orthophoto et sur la carte d'occupation du sol est donnée à la Figure 6.

De plus, le modèle, ne se basant que sur les données d'une seule orthophoto, ne dispose pas de suffisamment d'information pour pouvoir prédire la présence de « Couverts herbacés en rotation » comme ils ont été définis dans WAL\_OCS\_2018, à savoir : « Cette classe reprend les parcelles combinant un couvert herbacé une partie de l'année et un sol nu temporairement mis à nu. On y retrouve toutes les cultures annuelles, ainsi que les prairies temporaires succédant à une culture annuelle ». En effet, aucune donnée temporelle n'a été utilisée afin de déterminer l'évolution d'une parcelle agricole, dès lors, et ce même si les résultats obtenus sur les deux classes de couverts herbacés sont similaires à ceux de SOL\_2018, la définition de la classe des « Couverts herbacés en rotation » a été remplacée par la suivante : « Cette classe reprend les parcelles contenant une culture annuelle ou un sol labouré au moment de l'acquisition des orthophotos. »

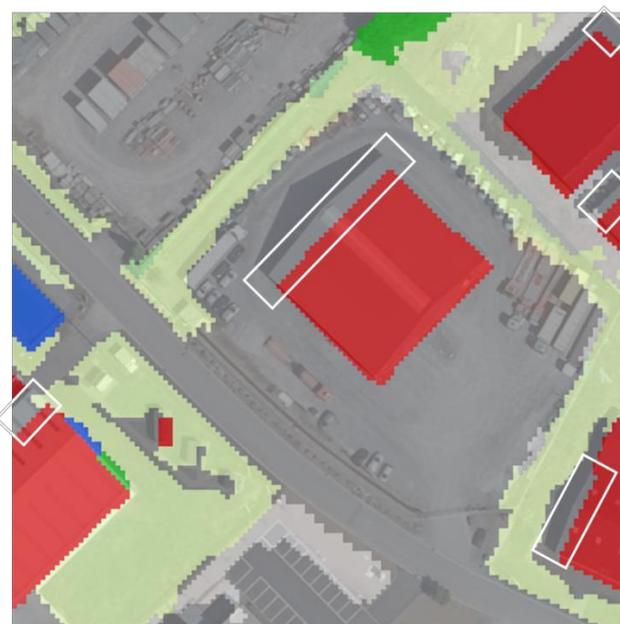
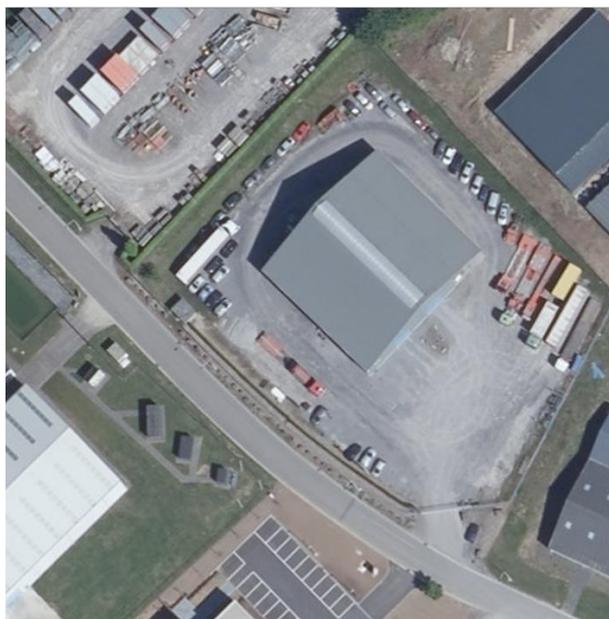




Figure 6 - Décalage des bâtiments.

A gauche : Orthophoto 2018. Au centre : WAL\_OCS\_2018 (avec une résolution spatiale de 1m). A droite : Prédictions de SOL\_2019/20 (avec une résolution spatiale de 0.25m). Les rectangles aux bords blancs mettent en évidence les différences entre WAL\_OCS\_2018 et les prédictions du nouveau modèle.

## 5. Détection des changements et correction d'erreurs

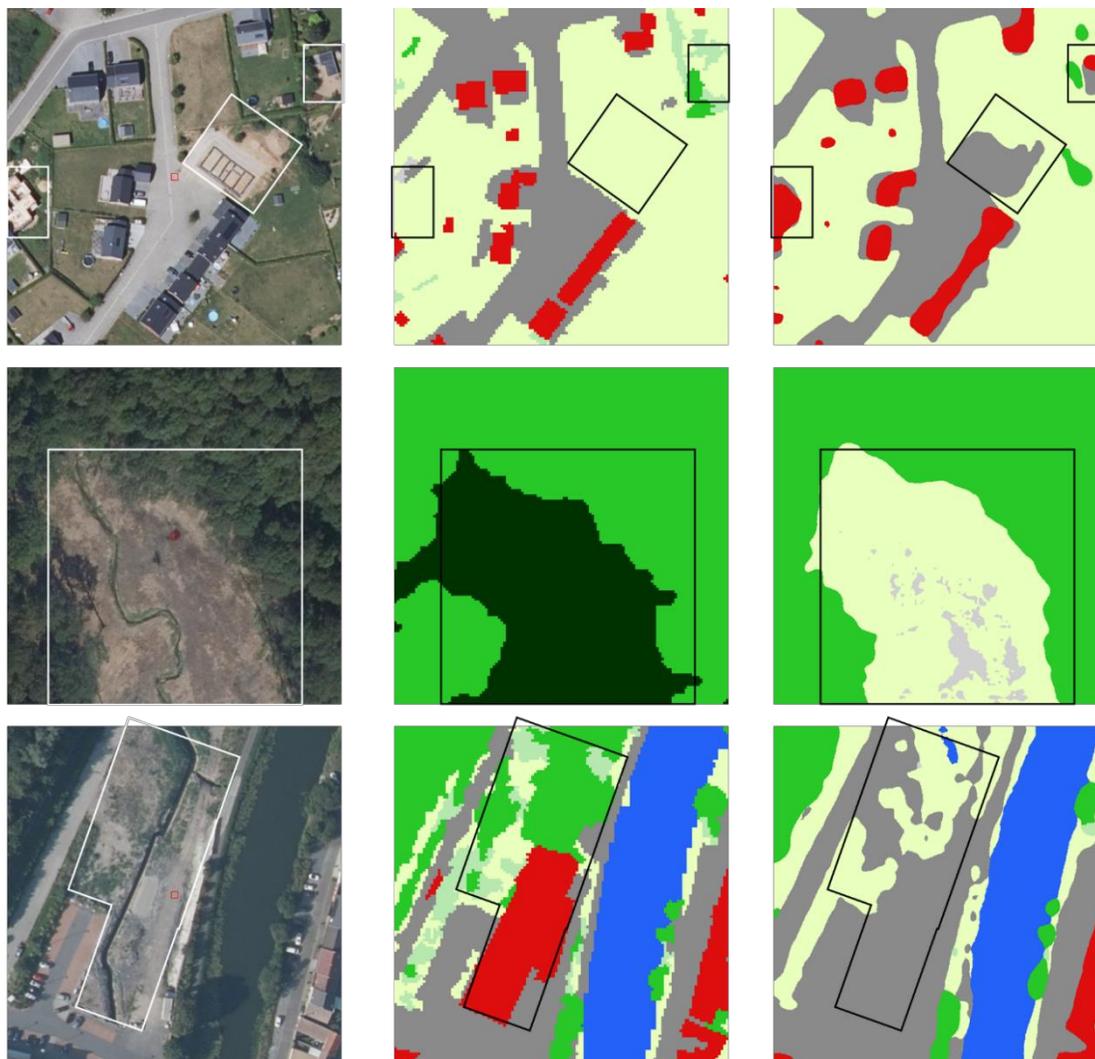
La solution implémentée permet de mettre à jour la carte d'occupation du sol, cela implique la détection et segmentation des changements survenus mais également la correction d'erreurs déjà présentes dans l'édition précédente. Les Figure 7 et Figure 8 présentent des exemples de détections de changements et des corrections d'erreurs, respectivement.

Une carte des changements, WAL\_OCS\_CHA\_IA\_2018\_2019/20 regroupant les différences entre les cartes d'occupation du sol de deux années a également été générée pour 2019 et 2020. Cette carte est constituée d'une unique bande indiquant 0 pour les pixels n'ayant pas connu de changement de classe entre les deux années et un nombre pour les pixels ayant changé de classe. Ce nombre encapsule les classes des deux années comparées en suivant une convention spécifique. Ainsi un pixel peut tomber dans 3 catégories :

$$valeur\ pixel = \begin{cases} 255 & \textit{nodata} \\ 0 & \textit{pas de changement} \\ (label^{2018} \times 1000) + label^{2019/2020} & \textit{changement} \end{cases}$$

Cette carte contient donc non seulement les changements survenus entre les deux années, les corrections d'erreurs de l'édition précédente, mais aussi des erreurs de prédictions de la nouvelle édition. Il est important de souligner que, compte tenu de l'approche sélectionnée, la carte des changements contient également des changements dus aux effets de bords.

Outre l'inclusion de 124 points liés à un changement dans chacun des VAL\_Sets et Test\_Sets de 2019 et 2020, une analyse diachronique des changements a également été réalisée afin de caractériser la fiabilité du modèle sur ses prédictions concernant des changements. Cette analyse s'est concentrée sur les changements liés à la classe « Constructions artificielles hors sol ». Ce sont 602 points qui ont été échantillonnés, labélisés par deux experts en photo-interprétations du SPW, et finalement comparés aux prédictions faites par les deux modèles (i.e. : SOL\_2018 et SOL\_2019). Il ressort de cette analyse que lorsque les experts identifient un changement lié à la classe « Constructions artificielles hors sol », ceux-ci confirment les prédictions des modèles dans plus de 70% des cas. Cependant, pour la majorité des points échantillonnés (dans 75.09% et 73.76% des cas pour l'Expert A et B, respectivement), les experts considèrent qu'il n'y a pas de changements liés à la classe « Constructions artificielles hors sol ». La majorité de ces désaccords entre photo-interprétations d'experts et prédictions des modèles peut être expliqué par les effets de bords puisque, selon les experts, entre 68.8% et 86.9% des points échantillonnés se retrouvent à moins de 1 mètre d'une frontière avec une autre classe. Le lecteur est redirigé vers le « Rapport\_Analyse\_Changements » pour obtenir plus de détails.



**Figure 7 - Détection des changements**  
 A gauche : Orthophoto 2019. Au centre : WAL\_OCS\_2018 (avec une résolution spatiale de 1m). A droite :  
 Prédictions de SOL\_2019/20 (avec une résolution spatiale de 0.25m). Les rectangles mettent en évidence  
 les changements survenus entre 2018 et 2019. Construction de nouvelles habitations, mise à  
 blanc/déforestation, et démolition d'un bâtiment.



Figure 8 - Correction des erreurs

A gauche : Orthophoto 2019. Au centre : WAL\_OCS\_2018 (avec une résolution spatiale de 1m). A droite : Prédications de SOL\_2019/20 (avec une résolution spatiale de 0.25m). Les rectangles mettent en évidence les erreurs de WAL\_OCS\_2019 corrigées par SOL\_2019/20.

## 6. Limites

Ce chapitre a pour objectif de lister les limites de la solution implémentée et plus spécifiquement ceux ayant un impact sur les prédictions faites par le modèle.

Dans un premier temps, les limites imposées par les données d'entrée sont investiguées. Ces limites exogènes ne sont pas le fruit de la solution choisie.

Dans un second temps, ce sont les limites directement liées à la solution choisie qui seront détaillées. Ces limites seront détaillées pour chacune des 11 classes principales. Uniquement les limites observées sur les données similaires à celles utilisées pour l'entraînement seront détaillées dans cette section (i.e. les données de 2018 et 2019).

Finalement, une section spéciale est dédiée aux limites du modèle lorsqu'il est appliqué sur des données présentant des différences notoires par rapport aux données d'entraînement (i.e. les données de 2020).

### 6.1. Limites exogènes

#### 6.1.1. Résolution spatiale des données d'entrée

Le modèle implémenté a été entraîné en utilisant comme données d'entrée les orthophotos ainsi que le MNH. La résolution native du MNT de 2013-2014 est de 1m et celle des MNS varie entre 0.5m et 1m, suivant les années. Puisque le modèle requiert des données de même dimension spatiale, le MNH a été rééchantillonné avec une approche bilinéaire pour obtenir une résolution spatiale artificielle de 0.25m qui correspond à celle retrouvée nativement dans les orthophotos. Ceci dicte la première limite physique de notre modèle puisque ce dernier ne pourra pas détecter et donc segmenter des objets ayant moins de 0.25m de côté. De plus, puisque la résolution spatiale dérivée du MNH est de 1m et que cette donnée d'entrée est particulièrement importante pour le modèle, ce dernier présentera des difficultés à segmenter des objets ayant moins de 1m de côté.

Dans le même sens, puisque, pour la plus grande partie de l'entraînement, WAL\_OCS\_2018 a été utilisé comme réalité-terrain et que sa résolution spatiale native est de 1m, le modèle a été entraîné à ignorer les objets de moins de 1m de côté. Cela coïncide avec les exigences du marché puisque celles-ci imposent une unité cartographique minimale de 15m<sup>2</sup> et une précision de 1m.

#### 6.1.2. Angle de prise de vue

L'angle de capture des orthophotos a un impact sur l'empreinte des objets hors sol sur l'orthophoto. Et puisque le modèle se base sur ces orthophotos pour faire ses prédictions des classes « vues du ciel », il se peut que le modèle surestime dans certains cas la proportion des classes « Constructions artificielles hors sol », « Feuillus », « Résineux », et sous-estime la proportion des autres classes.

#### 6.1.3. Ombre

Les ombres proposent toujours un défi supplémentaire lors de la segmentation du sol en fonction de son occupation. En effet, celles-ci altèrent la signature spectrale des objets qu'elles voilent et donc perturbent les prédictions du modèle. Il est à noter que des points de cette strate ont été échantillonnés pour faire partie des VAL\_Sets et TEST\_Sets.

#### 6.1.4. Disponibilités des données d'entrée

Le modèle requiert toutes les données d'entrée pour pouvoir faire ses prédictions. Dès lors l'absence de données sur une des sources suffit pour empêcher l'interférence du modèle pour les pixels affectés. Ceci est par exemple le cas sur la carte d'occupation du sol de 2019 et 2020 pour des sections de la piste cyclable (Ravel) Montjoie pour lesquelles le MNT n'est pas renseigné.

### 6.1.5. Qualité des données réalité-terrain

Comme mentionné ci-dessus, WAL\_OCS\_2018 a été utilisé, dans sa forme d'origine, comme réalité-terrain pour la plus grande partie de l'entraînement du modèle. Or cette donnée présente certaines erreurs récurrentes qui ont perturbés l'apprentissage du modèle. Parmi ces erreurs récurrentes, les plus impactantes sont :

- Décalages, dans certaines régions, des empreintes des « Constructions artificielles hors sol » sur WAL\_OCS\_2018 par rapport à leurs empreintes sur les orthophotos suite à l'utilisation des données du PICC (illustrées à la Figure 9) ;
- Inconsistances dans la segmentation des certaines classes telles que les « Sols nus » (illustrées à la Figure 10), « Arbustes résineux », et « Arbustes feuillus ».

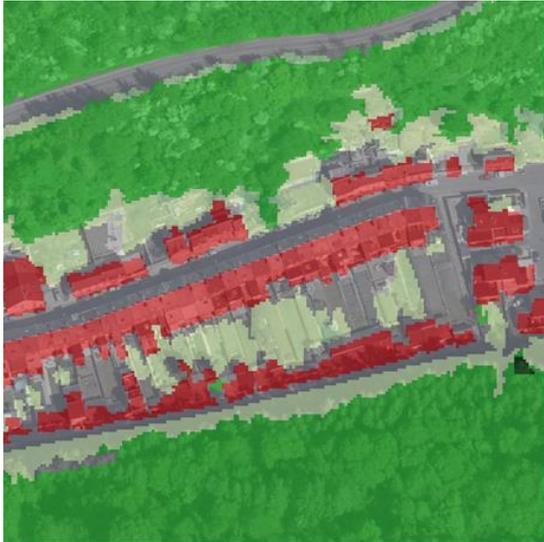


Figure 9 - Décalage des "Constructions artificielles hors sol".  
A gauche : WAL\_OCS\_2018 en transparence sur orthophoto de 2018. A droite : orthophoto de 2018 associée. Pour les trois exemples, un décalage vers le bas est constaté pour les bâtiments (couleur rouge dans la symbologie WALOUS).

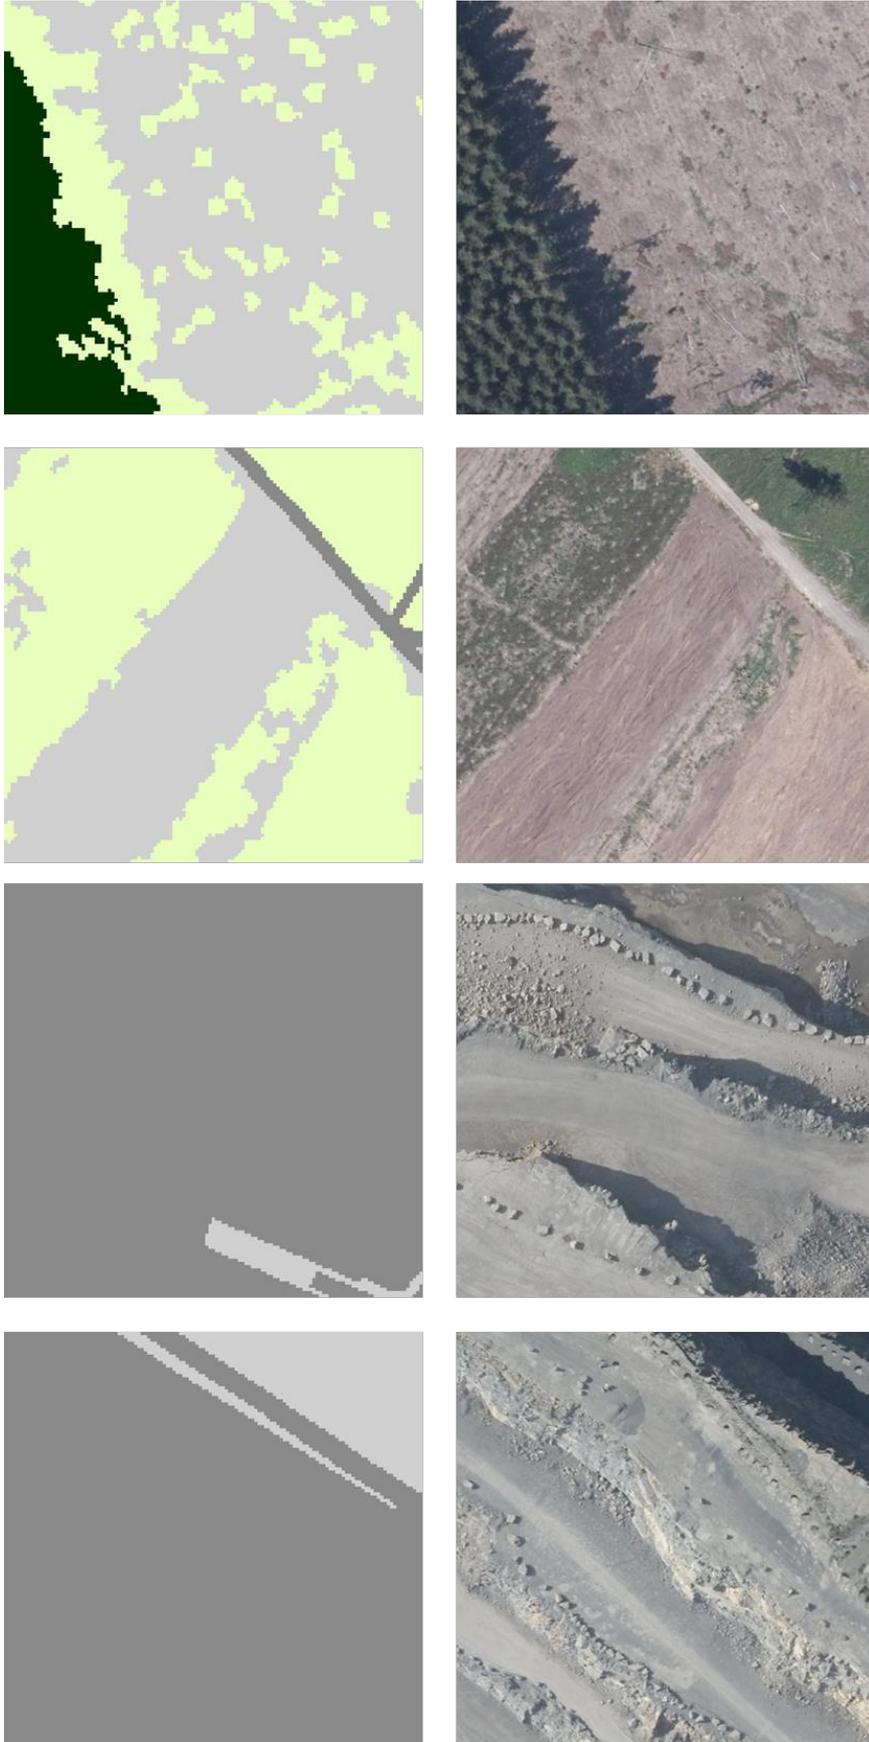


Figure 10 - Incohérences pour les "Sols nus" dans WAL\_OCS\_18.  
A gauche : WAL\_OCS\_2018 (avec une résolution spatiale de 1m). A droite : Orthophoto 2018. On observe certaines inconsistances dans les prédictions faites par SOL\_2018.

## 6.2. Limites endogènes

### 6.2.1. Précision dans les délimitations d'objets

Les réseaux de neurones convolutifs appliqués à la tâche de segmentation sont connus pour souffrir d'une plus faible précision au niveau des contours d'objets. Ceci ne représente pas un problème majeur pour la segmentation des classes naturelles où le passage d'une classe à l'autre s'apparente plus à une transition graduelle qu'une délimitation nette et précise. Ceci est moins vrai pour les classes artificielles où une délimitation plus précise peut souvent être observée.

Cependant, puisque la précision attendue pour les prédictions est de 1m, cette faiblesse du modèle n'a que peu d'impact sur le résultat final. En effet, une fois les données rééchantillonnées à 1m/pixel, la notion de précision aux contours d'objets devient plus relative.

### 6.2.2. Revêtement artificiel au sol

#### 6.2.2.1. Continuité

La continuité des routes n'est pas toujours garantie. En effet, plusieurs facteurs peuvent venir perturber la continuité d'une route, fractionnant celle-ci en plusieurs sections indépendantes.

De manière générale, cette discontinuité intervient pour les routes de relative faible largeur. Ainsi les chemins de campagne entre deux champs et les petits sentiers sont généralement les plus impactés. Un exemple est donné à la Figure 11.



**Figure 11 - Discontinuité des routes (routes de faible largeur).**  
**A gauche : Prédiction de SOL\_2019/20 (avec une résolution spatiale de 0.25m). A droite : Orthophoto 2018.**  
**On observe certaines discontinuités dans le tracé des routes suite à leur étroitesse.**

Une zone ombragée peut également perturber les prédictions du modèle et donc causer ces discontinuités.

De plus, certaines sections de route peuvent être caractérisées par le modèle comme « Sols nus » alors que le reste sera classifié en tant que « Revêtement artificiel au sol ». La Figure 12 illustre ce point.



Figure 12 - Discontinuité des routes (sols nus).  
A gauche : Prédictions de SOL\_2019/20 (avec une résolution spatiale de 0.25m). A droite : Orthophoto 2018.  
On observe certaines discontinuités dans le tracé des routes suite aux alternances de prédictions entre « Sols nus » et « Revêtement artificiel au sol ».

Finalement des discontinuités peuvent survenir suite aux occlusions causées par des arbres, par exemple. Dans ce cas, l'information contenue dans les doubles labels devra être utilisée.



Figure 13 - Discontinuité des routes (occlusions).  
A gauche : Prédictions de SOL\_2019/20 (avec une résolution spatiale de 0.25m). A droite : Orthophoto 2018.  
On observe certaines discontinuités dans le tracé des routes suite aux occlusions des arbres.

#### 6.2.2.2. Ponts

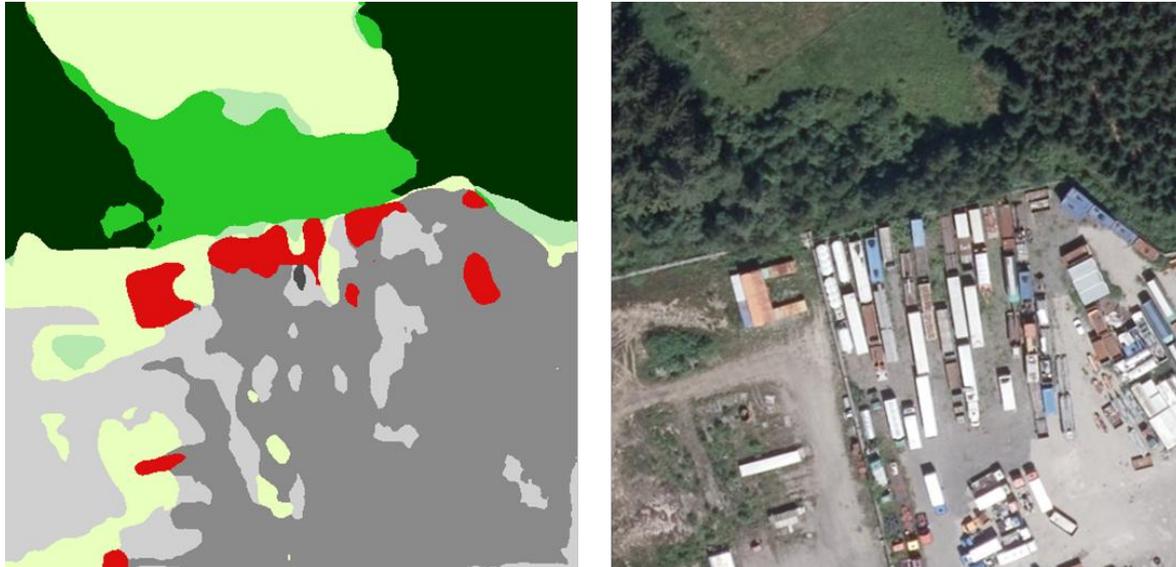
Bien que rares, dans certains cas, les ponts peuvent être parfois interprétés comme des « Constructions artificielles hors sol » à cause de leur signature sur le MNH.

#### 6.2.2.3. Confusion avec les sols nus

Des confusions avec la classe « Sols nus » sont parfois observées dues à la frontière étant parfois floue entre les classes. En effet, discriminer les deux classes n'est pas une chose aisée tant leurs définitions se chevauchent et l'information contenue dans les orthophotos et le MNH est imparfaite pour cette tâche.

De plus, il est important de noter que SOL\_2018 a consolidé des données de différentes sources afin de différencier ces deux classes. Par exemple, un sol compacté près d'une entreprise est considéré par SOL\_2018 comme un « Revêtement artificiel au sol » et non un « Sol nu » car celui-ci a perdu sa perméabilité. Ce type de règle n'a volontairement pas été implémenté dans SOL\_2019/20 pour les raisons évoquées plus haut.

Ces confusions sont présentes généralement dans les cimetières, les terrains vagues servant d'entrepôt, les carrières, .... Un exemple est donné à la Figure 14.



**Figure 14 - Confusion entre "Sols nus" et "Revêtement artificiel au sol".**  
**A gauche : Prédications de SOL\_2019/20 (avec une résolution spatiale de 0.25m). A droite : Orthophoto 2018.**

### 6.2.3. Constructions artificielles au sol

#### 6.2.3.1. Petites extensions

Comme mentionné précédemment, au plus l'objet à segmenter est petit, en largeur et/ou en longueur, au plus le modèle rencontrera des difficultés à le détecter et le segmenter. Ainsi les extensions de maison, les abris de jardin, ou des bâtiments étroits, comme illustré aux Figure 11 et Figure 15, ne seront pas toujours correctement segmentés. Il faut cependant garder en tête que l'unité minimale de cartographie est de 15m<sup>2</sup>.



**Figure 15 - Petites extensions.**  
A gauche : Prédications de SOL\_2019/20 (avec une résolution spatiale de 0.25m). A droite : Orthophoto 2018. SOL\_2019/20 a parfois des difficultés à détecter les petits objets. Les rectangles aux bords blancs mettent en évidence les difficultés de SOL\_2019/20.

### 6.2.3.2. Empreinte du bâtiment

Le modèle délimite les constructions artificielles sur base de leurs empreintes sur l'orthophoto et sur le MNH. Le modèle ne tenant pas compte de l'angle de prise de vue liée à l'acquisition des orthophotos, l'empreinte de bâtiments observés « off-nadir » sera artificiellement déformée par rapport à leur empreinte réelle au sol. Cet impact sera d'autant plus important que l'angle de vue dévie du nadir et que le bâtiment est haut.

Même si les informations sur l'angle de prise de vue étaient utilisées en données d'entrée, le modèle ne pourrait pas, de manière fiable, prédire ce qui se trouve caché derrière le bâtiment.

### 6.2.3.3. Bâtiments industriels

Les bâtiments industriels constituent un défi important pour le modèle à cause de la densité d'objets présents et la singularité de ceux-ci. En effet, les tuyaux et conduits aériens dans certaines usines chimiques, tel qu'illustré à la Figure 16, sont souvent interprétés comme « Constructions artificielles

hors sol ». Les ombres portées par les hauts bâtiments, souvent présents dans ces sites industriels, accentuent également le problème auquel fait face le modèle.

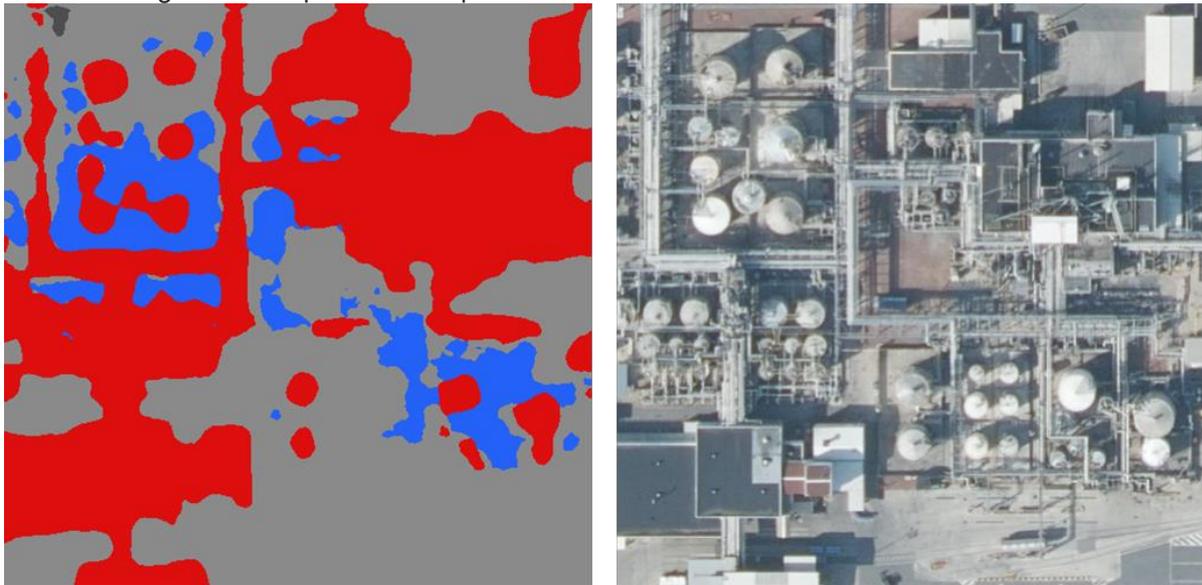


Figure 16 - Bâtiments industriels.  
A gauche : Prédiction de SOL\_2019/20 (avec une résolution spatiale de 0.25m). A droite : Orthophoto 2019. SOL\_2019/20 a des difficultés à segmenter correctement les sites industriels.

#### 6.2.3.4. Objets élevés attenants à un bâtiment

Dans certains cas, des objets élevés attenants à un bâtiment peuvent pousser le modèle à considérer ceux-ci comme faisant partie de la construction artificielle. Ainsi des camions stationnés près d'un entrepôt et l'ensilage stocké sous des bâches à proximité d'une ferme sont deux exemples qui peuvent mener à ce type de confusion. Ces exemples sont illustrés à la Figure 17.

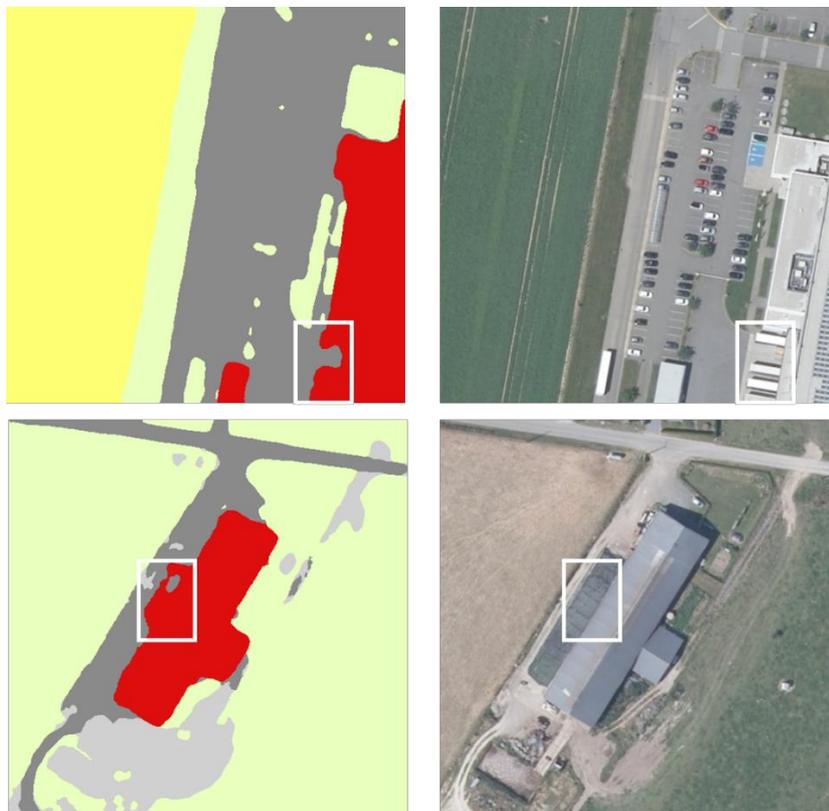


Figure 17 - Objets élevés attenants à un bâtiment.

A gauche : Prédictions de SOL\_2019/20 (avec une résolution spatiale de 0.25m). A droite : Orthophoto 2018. Les rectangles aux bords blancs mettent en évidence les difficultés de SOL\_2019/20.

#### 6.2.3.5. Objets élevés mobiles

Le modèle peut également avoir tendance à considérer les objets élevés et mobiles, tels que les remorques de camions, les péniches, ou des conteneurs, comme des constructions artificielles hors sol. Ceci est illustré à la Figure 18 et à la Figure 14.



Figure 18 - Objets élevés mobiles (péniche).  
 A gauche : Prédictions de SOL\_2019/20 (avec une résolution spatiale de 0.25m). A droite : Orthophoto 2018.

#### 6.2.3.6. Ombres

Différentes observations tendent à montrer que les zones ombragées peuvent parfois être erronément segmentées comme « Eaux de surface ». Cela s'illustre par exemple avec la Figure 16.

#### 6.2.4. Réseau ferroviaire

##### 6.2.4.1. Continuité

Tout comme les réseaux routiers, les réseaux ferroviaires peuvent également être impactés par des discontinuités. Les mêmes raisons que celles évoquées précédemment peuvent en être la cause. La Figure 12 illustre ce point.

#### 6.2.5. Sols nus

##### 6.2.5.1. Confusion avec les couverts herbacés continus

Les classes « Sols nus » et « Couvert herbacé continu » sont parfois difficile à distinguer et les transitions entre elles deux peuvent être difficile à positionner précisément. Ces confusions sont particulièrement présentes dans la région des Hautes-Fagnes.

Un exemple de transition parfois délicate entre ces deux classes est illustré avec la **Error! Reference source not found.**



Figure 19 - Confusion entre "Sols nus" et "Couvert herbacé continu".  
A gauche : Prédications de SOL\_2019/20 (avec une résolution spatiale de 0.25m). A droite : Orthophoto 2018.

## 6.2.6. Eaux de surface

### 6.2.6.1. Petites surfaces d'eau

Comme mentionné à plusieurs reprises jusqu'à présent, le modèle a plus de difficulté à détecter et segmenter les objets de petite taille. Par conséquent, les petits cours d'eau, étangs, ou piscines sont parfois ignorés par le modèle. La Figure 20 illustre ce constat.

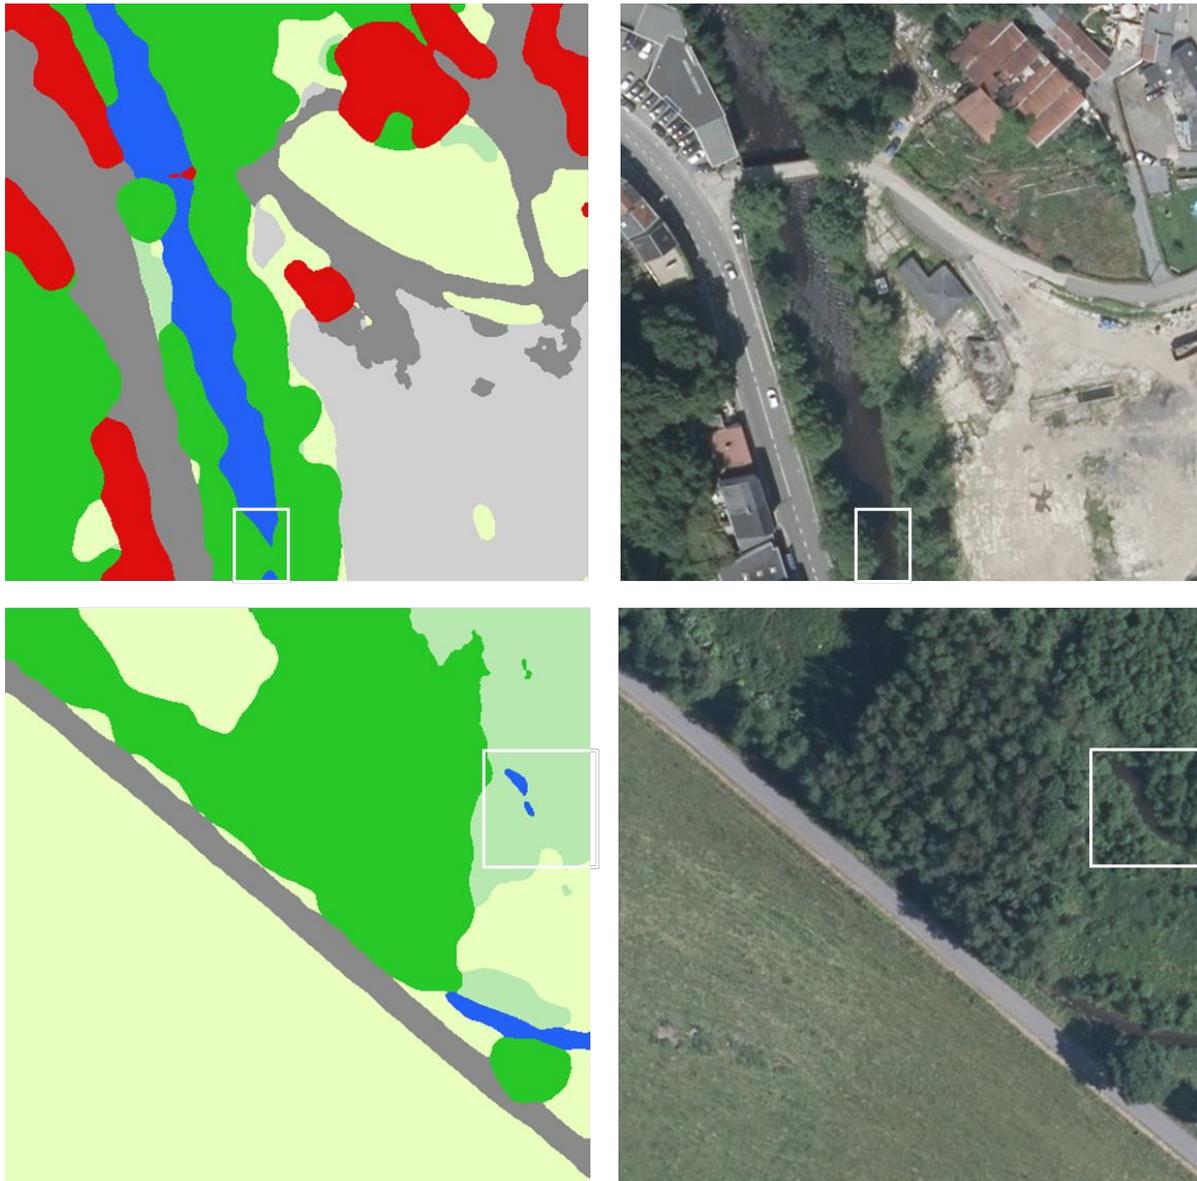


Figure 20 - Petites surfaces d'eau.  
A gauche : Prédications de SOL\_2019/20 (avec une résolution spatiale de 0.25m). A droite : Orthophoto 2018. Les rectangles aux bords blancs mettent en évidence les difficultés de SOL\_2019/20.

#### 6.2.6.2. Grandes étendues d'eau

Face à une grande étendue d'eau, le modèle peut également rencontrer des difficultés. En effet, ce dernier reçoit en entrée une vignette avec un contexte de 128x128m<sup>2</sup> ce qui peut impliquer pour des grandes étendues homogènes que l'entièreté de la vignette est couverte par une même classe uniforme apportant, au final, peu de contexte. Le modèle, n'ayant dans ces cas pas d'autres surfaces de comparaison, peut confondre ces étendues d'eau avec d'autres classes, typiquement « Revêtement artificielle au sol » et « Sols nus ».

#### 6.2.7. Couvert herbacé en rotation

##### 6.2.7.1. Capture à une date précise

Puisque le modèle n'a accès qu'aux données du terrain à une date précise, celui-ci ne peut pas s'assurer que tous les impératifs de la définition utilisée dans WAL\_OCS\_2018 soient remplis. En effet, la définition stipule que cette classe reprend les parcelles combinant un couvert herbacé une partie de l'année et un sol nu temporairement mis à nu. On y retrouve toutes les cultures annuelles, ainsi que les prairies temporaires succédant à une culture annuelle. Puisque le modèle n'a pas suffisamment

d'information pour savoir si une prairie herbacée a ou va succéder à une culture annuelle, la définition de cette classe a été revue.

### 6.2.7.2. Horticulture

Les vignobles et les vergers, sensés appartenir à la classe « Couvert herbacé en rotation », sont parfois classifiés comme « Arbustes résineux » ou « Arbustes feuillus » par le modèle.

### 6.2.8. Couvert herbacé continu

Étant la classe la plus représentée sur le territoire wallon, celle-ci est devenue la classe de prédiction par défaut du modèle en cas de doute.

### 6.2.9. Arbres résineux

#### 6.2.9.1. Petites étendues de résineux

Les petites étendues de résineux composées de quelques arbres sont souvent classifiées à tort par le modèle comme « Feuillus ». Ceci s'observe plus particulièrement en zone urbaine.

#### 6.2.9.2. Confusion avec « Arbres feuillus »

Les confusions avec la classe « Arbres feuillus » sont les plus fréquentes. Les observations sembleraient montrer que le modèle a tendance à préférer prédire la présence de feuillus plutôt que de résineux en cas de confusion ou lorsque les forêts sont mixtes. La Figure 21 illustre ce dernier point en montrant que la détection des résineux sur la gauche a pu être faite par le modèle, mais la segmentation n'est pas parfaite puisque celui-ci favorise la prédiction d' « Arbres feuillus ».



**Figure 21 - Confusion avec "Arbres feuillus".**  
 A gauche : Prédications de SOL\_2019/20 (avec une résolution spatiale de 0.25m). A droite : Orthophoto 2018. SOL\_2019/20 a détecté la présence de résineux dans la zone encadrée en blanche mais reste réservé dans la segmentation de ceux-ci. Les rectangles aux bords blancs mettent en évidence les difficultés de SOL\_2019/20.

### 6.2.10. Arbres feuillus

#### 6.2.10.1. Petites étendues de feuillus

Les petites étendues de feuillus composées de moins de 3 arbres peuvent être ignorés par le modèle. Celles-ci sont alors souvent segmentées comme « Couvert herbacé continu ».

### 6.2.11. Arbustes résineux/feuillus

### 6.2.11.1. Rappel

Le modèle se montre réticent à prédire les étendues d'« Arbustes résineux/feuillus ». Ceci est illustré à la Figure 22 où les haies séparant les jardins ne sont pas segmentées. Ceci était déjà le cas dans WAL\_OCS\_2018 cependant.

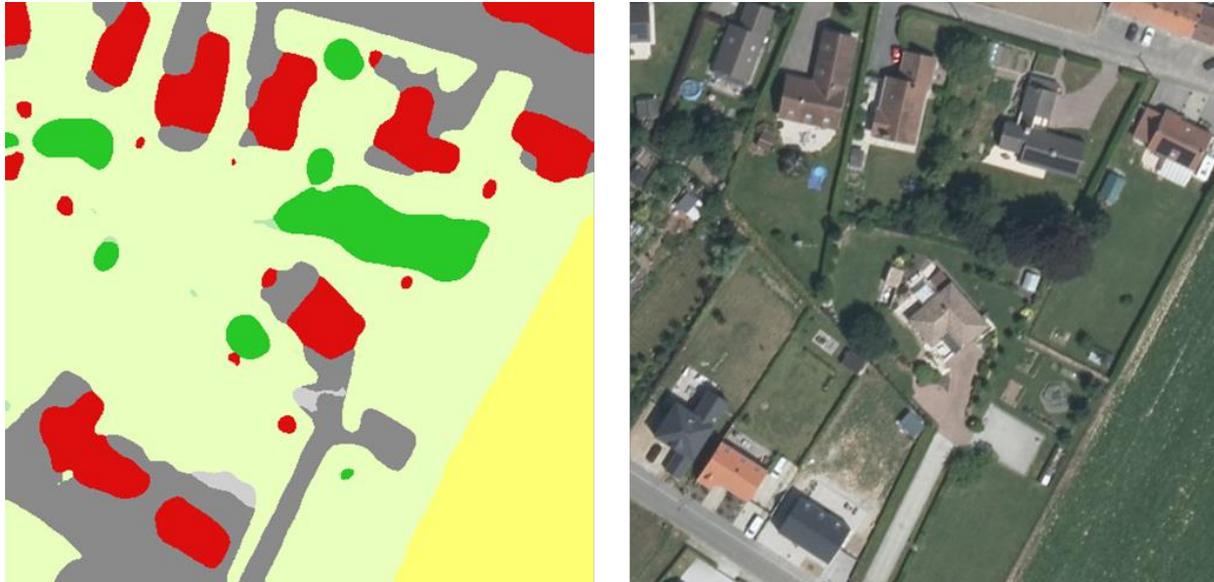


Figure 22 - Haies séparant les jardins résidentiels.  
A gauche : Prédications de SOL\_2019/20 (avec une résolution spatiale de 0.25m). A droite : Orthophoto 2018. SOL\_2019/20 ne segmente de manière fiable les arbustes.

### 6.2.11.2. Confusion entre « Arbustes »

Les confusions entre arbustes sont fréquentes et difficiles à trancher pour le modèle. En effet, le modèle éprouve des difficultés à différencier ces deux types d'arbres lorsqu'ils ont moins de 3m.

## 6.3. Limites liées aux données non-représentatives

Comme pour tout modèle de Machine Learning, il est important que les données d'entraînement soient représentatives des données sur lesquelles le modèle doit être appliqué. Puisque le modèle a principalement été entraîné sur des données de 2018, dont les orthophotos ont été prises entre les mois de mai et août, on ne peut s'attendre à des performances similaires que pour des données comparables. En effet, si le modèle n'a jamais vu durant son entraînement des orthophotos prises en hiver ou en automne alors il n'y a aucune garantie quant aux résultats qu'on obtiendra si on applique le modèle sur ce type de données.

### 6.3.1. Données de 2020

Alors que ces données de 2018 sont représentatives de celles de 2019, elles ne le sont pas pour celles de 2020. En effet, les orthophotos de 2020 ont été prises durant le mois d'avril, période durant laquelle la végétation est moins luxuriante : les feuillus n'ont parfois pas encore leurs feuilles, les régions herbacées paraissent plus ternes, .... Cela occasionne plusieurs confusions pour notre modèle lorsqu'il est appliqué aux données de 2020. Parmi ces confusions, les plus notoires sont les suivantes :

- Confusion entre « Sols nus » et « Couvert herbacé continu »
- Confusion entre « Arbres/arbustes feuillus » et « Sols nus » / « Couvert herbacé continu »

## 7. Perspectives

Dans ce chapitre, plusieurs perspectives sont avancées pour améliorer davantage les performances de la solution.

### 7.1. Affinement du jeu de données d'entraînement

Certaines des limites détaillées ci-dessus peuvent être adressées directement en continuant l'affinement du jeu de données d'entraînement (i.e. : WAL\_OCS\_18). En effet, les résultats obtenus à l'itération 05 sont très prometteurs sur de nombreux points, cependant, les mailles affinées utilisées pour finaliser l'entraînement du modèle ne furent pas assez diversifiées entraînant des lacunes importantes au niveau du rappel des classes « Eau » et « Couverts herbacés en rotation ». En poursuivant l'affinement de mailles et en veillant à diversifier le nouveau jeu de données d'entraînement, les problèmes de rappels peuvent être adressés tout en gardant les avantages de l'itération 05 à savoir une amélioration du rappel pour les classes « Sols nus », « Arbustes feuillus », « Arbustes résineux », et « Résineux ».

Ce travail d'affinement, bien qu'exigeant sur le plan des ressources requises pour le mener à bien, permet de corriger les inconsistances dans la réalité-terrain WAL\_OCS\_18 qui compromettent l'apprentissage du modèle pour les classes affectées par ces inconsistances.

Ainsi l'affinement de la réalité-terrain pourrait :

- Améliorer le rappel de la classe « Sols nus »
- Améliorer les rappels des classes « Arbustes résineux » et « Arbustes feuillus »
- Améliorer la distinction entre feuillus et résineux

De plus, cet affinement pourrait permettre de proposer des prédictions à une meilleure résolution spatiale.

### 7.2. Utilisation de true orthophotos

L'utilisation des true orthophotos permettrait d'adresser l'impact des angles de vue « off-nadir » lors de l'acquisition des orthophotos. En effet, les true orthophotos représentent, en tout point, la situation telle qu'elle est lorsqu'on l'observe en « nadir ». Ceci éviterait la présence de zones d'occlusion autrement générées par la déformation des objets hors sol observés depuis un angle « off-nadir ».

### 7.3. Utilisation de plusieurs orthophotos acquises à des périodes différentes de l'année

L'acquisition de plusieurs orthophotos durant l'année pourrait permettre d'améliorer :

- La discrimination entre les « Arbres résineux » et les « Arbres feuillus », puisque les différences peuvent s'accroître au fil des saisons
- La distinction entre « Couvert herbacé continu » et « Couvert herbacé en rotation », puisqu'il y a une notion de temporalité pour ces deux classes
- Les performances générales du modèle, puisque les perturbations (e.g. : ombres, variations dues aux saisons, ...) seront atténuées par la capture d'une même zone à des moments différents et sous des conditions différentes.

Un modèle suivant l'architecture d'un LSTM est parfaitement disposé pour cette tâche, comme le montrent Rußwurm et Korner (Rußwurm and Korner 2018).

Cependant, utiliser une série temporelle d'orthophotos comme données d'entrée présente également certains désavantages :

- L'acquisition d'orthophoto a un coût non négligeable ;
- La mise à jour de la carte d'occupation des sols ne serait possible que lorsque la dernière capture d'orthophotos a été réalisée ;

- La segmentation des classes « hors sols »<sup>8</sup> peut s'avérer moins précise puisque l'empreinte des objets de ces classes va varier entre chaque orthophoto suivant l'angle de vue ;
- La complexité du modèle ainsi que ces contraintes techniques seraient accrues.

#### **7.4. Création d'un nouveau jeu de données d'entraînement autour des orthophotos de 2020**

Si la volonté du SPW est d'acquérir les orthophotos plus tôt dans l'année, à l'instar de celles de 2020, alors la création d'un nouveau jeu de données d'entraînement centré autour des particularités saisonnières de cette période serait judicieuse. En effet, les performances de la solution actuelle sur les données de 2020 sont en dessous de celles escomptées. Utiliser WAL\_OCS\_2018 comme réalité-terrain pour entraîner un modèle sur les données d'entrée de 2020 n'est pas optimal à cause des changements d'occupation du sol survenus entre 2018 et 2020. Ainsi, la création ou la mise à jour de la réalité-terrain est préférable pour faciliter l'apprentissage du modèle.

Néanmoins, il reste que les prédictions du modèle sur base des orthophotos prises en hiver, automne, ou début printemps resteront plus difficiles car les spécificités de chaque classe s'estompent durant ces périodes. En effet, une couche de neige uniformise le terrain, le peu de végétation complique la distinction entre « Sols nus » et « Couverts herbacés continus », entre « Couverts herbacés en rotation » et Couverts herbacés continu », l'absence de feuilles aux « Arbres feuillus » peut entraîner leur confusion avec leur sol, ...

#### **7.5. Combiner plusieurs modèles dans Ensemble**

Le regroupement de plusieurs modèles dans un Ensemble a également fait ses preuves ces dernières années. A la condition que les erreurs de chacun des modèles faisant partie de l'Ensemble soient indépendantes, alors la diversité des modèles constituant l'Ensemble engendrera des meilleures performances que chacun des modèles pris isolément (Mudasir, et al. 2021).

Ces différents modèles peuvent se distinguer les uns des autres sur base de leur architecture et/ou sur base de la source des données d'entrées.

Cependant, le désavantage de cette approche, c'est qu'elle complexifie la solution puisqu'elle implique la gestion de plusieurs modèles indépendants. De plus, le temps d'inférence peut lui aussi considérablement augmenter avec le nombre de modèles inclus dans l'Ensemble. De la même manière, si les sources de données sont diversifiées, le nombre de dépendances de la solution augmentera, ce qui pourrait occasionner des retards dans la mise à jour de la carte d'occupation des sols si une source de données d'entrée doit d'abord être rendu disponible.

#### **7.6. Utilisation de données synthétiques**

L'utilisation des données synthétiques générées peut permettre la génération d'instances pour lesquelles le modèle éprouve des difficultés, e.g. : arbustes. Soumis plus fréquemment à ces instances, le modèle peut plus facilement les modéliser. De plus la diversité de situations que ces données synthétiques apportent permettra au modèle de plus facilement généraliser les concepts appris.

Cependant, la conception et l'implémentation d'un modèle permettant de générer ces données synthétiques est loin d'être trivial. De plus, des données réelles resteront indispensables pour contrebalancer les éventuels biais engendrés lors de la génération des données synthétiques.

D'autre part, dépendamment des performances du modèle générant ces données synthétiques, cette approche pourrait permettre de proposer des prédictions à une meilleure résolution spatiale.

---

<sup>8</sup> i.e.: "Constructions artificielles hors sol", "Arbes résineux", et "Arbres feuillus"

## 8. Références

- Card, Don H. 1982. «Using known map category marginal frequencies to improve estimates of thematic map accuracy.» *Photogrammetric Engineering and Remote Sensing* (NASA Ames Research Center) 48: 431-439. [https://www.asprs.org/wp-content/uploads/pers/1982journal/mar/1982\\_mar\\_431-439.pdf](https://www.asprs.org/wp-content/uploads/pers/1982journal/mar/1982_mar_431-439.pdf).
- Chen, Liang-Chieh, George Papandreou, Florian Schroff, et Hartwig Adam. 2017. «Rethinking Atrous Convolution for Semantic Image Segmentation.» *Cornell Univeristy / Computer Vision and Pattern Recognition*, 5 December. doi:1706.05587.
- Mudasir, A. Ganaie, Hu Minghui, Tanveer Mohammad, et N. Suganthan Ponnuthurai. 2021. «Ensemble deep learning: A review.» *Cornell Univeristy / Computer Science and Machine Learning*. doi:2104.02395.
- Rußwurm, Marc, et Marco Korner. 2018. «Multi-Temporal Land Cover Classification with Sequential Recurrent Encoders.» *International Journal of Geo-Information*, 21 March. doi:10.3390/ijgi7040129.
- Service Public de Wallonie (SPW) - Walous. 2019. «Guide méthodologique finalisé et recommandations d'usages pour la fusion des données de la carte d'occupation du sol de Wallonie 2018.» 29. [https://geoportail.wallonie.be/files/PDF/annexes\\_walous/WALOUS\\_WP5\\_D5.1\\_Fusion.pdf](https://geoportail.wallonie.be/files/PDF/annexes_walous/WALOUS_WP5_D5.1_Fusion.pdf).
- Service Public de Wallonie (SPW) - Walous. 2020. «Consolidation et enrichissement de la carte d'occupation du sol de Wallonie 2018.» 15. [https://geoportail.wallonie.be/files/PDF/annexes\\_walous/WALOUS\\_WP6\\_Consolidation.pdf](https://geoportail.wallonie.be/files/PDF/annexes_walous/WALOUS_WP6_Consolidation.pdf).
- Service Public de Wallonie (SPW) - Walous. 2018. «Guide méthodologique de production du squelette vectoriel.» 30. [https://geoportail.wallonie.be/files/PDF/annexes\\_walous/WALOUS\\_WP2\\_squelettevectoriel.pdf](https://geoportail.wallonie.be/files/PDF/annexes_walous/WALOUS_WP2_squelettevectoriel.pdf).
- Service Public de Wallonie (SPW) - Walous. 2020. «Validation de la carte d'occupation du sol de Wallonie 2018.» 7. [https://geoportail.wallonie.be/files/PDF/annexes\\_walous/WALOUS\\_WP6\\_validation.pdf](https://geoportail.wallonie.be/files/PDF/annexes_walous/WALOUS_WP6_validation.pdf).

## 9. Annexes

### 9.1. Configuration du modèle

```

CUDNN_BENCHMARK: false
DATALOADER:
  ASPECT_RATIO_GROUPING: true
  FILTER_EMPTY_ANNOTATIONS: true
  NUM_WORKERS: 10
  REPEAT_THRESHOLD: 0.0
  SAMPLER_TRAIN: TrainingSampler
DATASETS:
  PRECOMPUTED_PROPOSAL_TOPK_TEST: 1000
  PRECOMPUTED_PROPOSAL_TOPK_TRAIN: 2000
  PROPOSAL_FILES_TEST: []
  PROPOSAL_FILES_TRAIN: []
TEST:
  - walous_sem_seg_val
TRAIN:
  - walous_sem_seg_train
GLOBAL:
  HACK: 1.0
  
```

```

INPUT:
  CROP:
    ENABLED: false
    SINGLE_CATEGORY_MAX_AREA: 1.0
    SIZE:
      - 512
      - 1024
    TYPE: absolute
  FORMAT: RGB
  MASK_FORMAT: polygon
  MAX_SIZE_TEST: 512
  MAX_SIZE_TRAIN: 512
  MIN_SIZE_TEST: 512
  MIN_SIZE_TRAIN:
    - 512
  MIN_SIZE_TRAIN_SAMPLING: choice
  RANDOM_FLIP: horizontal
MODEL:
  ANCHOR_GENERATOR:
    ANGLES:
      - -90
      - 0
      - 90
    ASPECT RATIOS:
      - 0.5
      - 1.0
      - 2.0
    NAME: DefaultAnchorGenerator
    OFFSET: 0.0
    SIZES:
      - 32
      - 64
      - 128
      - 256
      - 512
  BACKBONE:
    FREEZE_AT: 0
    NAME: build_resnet_deeplab_backbone
  DEVICE: cuda
  FPN:
    FUSE_TYPE: sum
    IN_FEATURES: []
    NORM: ''
    OUT_CHANNELS: 256
  KEYPOINT_ON: false
  LOAD_PROPOSALS: false
  MASK_ON: false
  META_ARCHITECTURE: SemanticSegmentor
  PANOPTIC_FPN:

```

```
COMBINE :
  ENABLED: true
  INSTANCES_CONFIDENCE_THRESH: 0.5
  OVERLAP_THRESH: 0.5
  STUFF_AREA_LIMIT: 4096
  INSTANCE_LOSS_WEIGHT: 1.0
PIXEL_MEAN:
- 27108.4928
- 29066.0223
- 26921.2527
- 39606.5559
- 6.0366
PIXEL_STD:
- 7118.1259
- 6383.3102
- 6026.0482
- 6578.2162
- 6.1443
PROPOSAL_GENERATOR:
  MIN_SIZE: 0
  NAME: RPN
RESNETS:
  DEFORM_MODULATED: false
  DEFORM_NUM_GROUPS: 1
  DEFORM_ON_PER_STAGE:
  - false
  - false
  - false
  - false
DEPTH: 101
NORM: SyncBN
NUM_GROUPS: 1
OUT_FEATURES:
- res2
- res5
RES2_OUT_CHANNELS: 256
RES4_DILATION: 1
RES5_DILATION: 2
RES5_MULTI_GRID:
- 1
- 2
- 4
STEM_OUT_CHANNELS: 128
STEM_TYPE: deeplab
STRIDE_IN_1X1: false
WIDTH_PER_GROUP: 64
RETINANET:
  BBOX_REG_LOSS_TYPE: smooth_l1
  BBOX_REG_WEIGHTS: &id001
```

```
- 1.0
- 1.0
- 1.0
- 1.0
FOCAL_LOSS_ALPHA: 0.25
FOCAL_LOSS_GAMMA: 2.0
IN_FEATURES:
- p3
- p4
- p5
- p6
- p7
IOU_LABELS:
- 0
- -1
- 1
IOU_THRESHOLDS:
- 0.4
- 0.5
NMS_THRESH_TEST: 0.5
NORM: ''
NUM_CLASSES: 80
NUM_CONVS: 4
PRIOR_PROB: 0.01
SCORE_THRESH_TEST: 0.05
SMOOTH_L1_LOSS_BETA: 0.1
TOPK_CANDIDATES_TEST: 1000
ROI_BOX_CASCADE_HEAD:
BBOX_REG_WEIGHTS:
- - 10.0
- - 10.0
- - 5.0
- - 5.0
- - 20.0
- - 20.0
- - 10.0
- - 10.0
- - 30.0
- - 30.0
- - 15.0
- - 15.0
IOUS:
- 0.5
- 0.6
- 0.7
ROI_BOX_HEAD:
BBOX_REG_LOSS_TYPE: smooth_l1
BBOX_REG_LOSS_WEIGHT: 1.0
BBOX_REG_WEIGHTS:
```

```

- 10.0
- 10.0
- 5.0
- 5.0
CLS_AGNOSTIC_BBOX_REG: false
CONV_DIM: 256
FC_DIM: 1024
NAME: FastRCNNConvFCHead
NORM: ''
NUM_CONV: 0
NUM_FC: 2
POOLER_RESOLUTION: 7
POOLER_SAMPLING_RATIO: 0
POOLER_TYPE: ROIAlignV2
SMOOTH_L1_BETA: 0.0
TRAIN_ON_PRED_BOXES: false
ROI_HEADS:
  BATCH_SIZE_PER_IMAGE: 512
  IN_FEATURES:
    - res5
  IOU_LABELS:
    - 0
    - 1
  IOU_THRESHOLDS:
    - 0.5
  NAME: StandardROIHeads
  NMS_THRESH_TEST: 0.5
  NUM_CLASSES: 80
  POSITIVE_FRACTION: 0.25
  PROPOSAL_APPEND_GT: true
  SCORE_THRESH_TEST: 0.05
ROI_KEYPOINT_HEAD:
  CONV_DIMS:
    - 512
    - 512
    - 512
    - 512
    - 512
    - 512
    - 512
    - 512
  LOSS_WEIGHT: 1.0
  MIN_KEYPOINTS_PER_IMAGE: 1
  NAME: KRCNNConvDeconvUpsampleHead
  NORMALIZE_LOSS_BY_VISIBLE_KEYPOINTS: true
  NUM_KEYPOINTS: 17
  POOLER_RESOLUTION: 14
  POOLER_SAMPLING_RATIO: 0
  POOLER_TYPE: ROIAlignV2

```

```

ROI_MASK_HEAD:
  CLS_AGNOSTIC_MASK: false
  CONV_DIM: 256
  NAME: MaskRCNNConvUpsampleHead
  NORM: ''
  NUM_CONV: 4
  POOLER_RESOLUTION: 14
  POOLER_SAMPLING_RATIO: 0
  POOLER_TYPE: ROIAlignV2
RPN:
  BATCH_SIZE_PER_IMAGE: 256
  BBOX_REG_LOSS_TYPE: smooth_l1
  BBOX_REG_LOSS_WEIGHT: 1.0
  BBOX_REG_WEIGHTS: *id001
  BOUNDARY_THRESH: -1
  HEAD_NAME: StandardRPNHead
  IN_FEATURES:
  - res5
  IOU_LABELS:
  - 0
  - -1
  - 1
  IOU_THRESHOLDS:
  - 0.3
  - 0.7
  LOSS_WEIGHT: 1.0
  NMS_THRESH: 0.7
  POSITIVE_FRACTION: 0.5
  POST_NMS_TOPK_TEST: 1000
  POST_NMS_TOPK_TRAIN: 2000
  PRE_NMS_TOPK_TEST: 6000
  PRE_NMS_TOPK_TRAIN: 12000
  SMOOTH_L1_BETA: 0.0
SEM_SEG_HEAD:
  ASPP_CHANNELS: 256
  ASPP_DILATIONS:
  - 6
  - 12
  - 18
  ASPP_DROPOUT: 0.1
  COMMON_STRIDE: 4
  CONVS_DIM: 256
  IGNORE_VALUE: 255
  IN_FEATURES:
  - res2
  - res5
  LOSS_TYPE: hard_pixel_mining
  LOSS_WEIGHT: 1.0
  NAME: DeepLabV3PlusHead

```

```

NORM: SyncBN
NUM_CLASSES: 11
PROJECT_CHANNELS:
- 48
PROJECT_FEATURES:
- res2
USE_DEPTHWISE_SEPARABLE_CONV: false
WEIGHTS: model_walous_iter-2.RGBIH.pth
OUTPUT_DIR: output_walous_iter-2.RGBIH20
SEED: -1
SOLVER:
AMP:
  ENABLED: false
BASE_LR: 0.001
BIAS_LR_FACTOR: 1.0
CHECKPOINT_PERIOD: 5000
CLIP_GRADIENTS:
  CLIP_TYPE: value
  CLIP_VALUE: 1.0
  ENABLED: false
  NORM_TYPE: 2.0
GAMMA: 0.1
IMS_PER_BATCH: 16
LR_SCHEDULER_NAME: WarmupPolyLR
MAX_ITER: 35000
MOMENTUM: 0.9
NESTEROV: false
POLY_LR_CONSTANT_ENDING: 0.0
POLY_LR_POWER: 0.9
REFERENCE_WORLD_SIZE: 0
STEPS:
- 60000
- 80000
WARMUP_FACTOR: 0.001
WARMUP_ITERS: 1000
WARMUP_METHOD: linear
WEIGHT_DECAY: 0.0001
WEIGHT_DECAY_BIAS: 0.0001
WEIGHT_DECAY_NORM: 0.0
TEST:
AUG:
  ENABLED: false
  FLIP: true
  MAX_SIZE: 4000
  MIN_SIZES:
- 400
- 500
- 600
- 700

```

```
- 800
- 900
- 1000
- 1100
- 1200
DETECTIONS_PER_IMAGE: 100
EVAL_PERIOD: 1000
EXPECTED_RESULTS: []
KEYPOINT_OKS_SIGMAS: []
PRECISE_BN:
  ENABLED: false
  NUM_ITER: 200
VERSION: 2
VIS_PERIOD: 0
```