

WalousMàJ

-

Mise à jour 2025

Reference	ASL-WALOUS-2025-01
Issue	1
Revision	0
Project	Walous
Issue date	15/07/2025

	Name	Company	Signature
Author	Gustin Julien	Aerospacelab	
Approval	Celik Eyyup	Aerospacelab	

Table des matières

TABLE DES MATIÈRES	2
1 OBJET DU RAPPORT.....	3
2 MÉTHODE DE PRODUCTION	3
2.1 PIPELINE	3
2.1.1 <i>Prétraitement des données</i> :.....	3
2.1.2 <i>Inférence</i> :.....	4
2.2 ARCHITECTURE DU MODÈLE	4
2.3 ENTRAÎNEMENT	4
2.3.1 <i>Données d'entraînement</i> :.....	4
2.3.2 <i>Protocole d'entraînement</i>	6
3 RÉSULTATS CARTOGRAPHIQUES	7
3.1 PRODUIT 2023 ILLUSTRÉ	7
3.2 PRODUIT DE CHANGEMENT 2018-2023	8
4 VALIDATION	9
5 LIMITES	10
6 CONCLUSION	11
APPENDIX 1 CONFIGURATION DU MODÈLE	12

1 Objet du rapport

Ce rapport détaille la production de la version 2023 de la carte d'occupation des sols de Wallonie, le produit WAL_OCS_IA_2023, réalisé dans le cadre du projet de mise-à-jour WalousMàj Maintenance, suite au projet WALOUS. Nous avons modernisé le produit WAL_OCS en utilisant des bibliothèques spécialisées en imagerie satellite avec intelligence artificielle (IA), notamment en restructurant le projet à l'aide de la bibliothèque RasterVision. Cette mise à jour vise à améliorer les méthodes d'entraînement, à rendre le modèle plus généraliste pour les futures données, et à réduire la quantité de post-traitement nécessaire.

Pour plus d'information concernant le contexte de ce projet nous proposons au lecteur de lire le rapport sur la solution précédente.

2 Méthode de production




Figure 1: Architecture du modèle. Le modèle DeepLabV3+ prend en entrée la concaténation de l'orthophoto et du Modèle Numérique de Hauteur (MNH), et génère en sortie une carte de prédiction où chaque pixel est associé à une classe d'occupation du sol. Cette carte peut ensuite être comparée à une carte de référence labellisée pour produire une carte de changement.

2.1 Pipeline

Dans cette nouvelle version, le pipeline a été simplifié pour minimiser l'altération des résultats du modèle. Le processus est désormais divisé en deux étapes indépendantes : le prétraitement des données et l'inférence.

2.1.1 Prétraitement des données

1. Calcul du Modèle Numérique de Hauteur (MNH) en soustrayant le Modèle Numérique de Terrain (MNT) issu du LiDAR 2020/22 et du Modèle Numérique de Surface (MNS) photogrammétrique déduit de la couverture en orthophotos 2023 ;
2. Reprojection des données dans le système de projection EPSG:3812 et uniformisation de la résolution à 1m ;
3. Les images utilisées pour l'entraînement du modèle (orthophotos 2018), initialement en 16 bits (valeurs de 0 à 65535), sont converties en 8 bits (valeurs de 0 à 255) pour alléger les fichiers et faciliter le traitement.

4. Les valeurs utiles sont ramenées dans l'intervalle 0–255 par une simple mise à l'échelle. Les pixels sans données (nodata) sont conservés à 0 pour pouvoir être facilement ignorés par la suite ;
5. Normalisation du MNH pour maintenir les valeurs entre -5 et 25 sur une échelle de 0 à 255, optimisant ainsi la précision du modèle ;
6. Concaténation des données finales.

2.1.2 Inférence

Les images sont directement utilisées pour l'inférence, où le modèle renvoie les prédictions correspondant à chaque pixel comme illustré dans la Figure 1: *Architecture du modèle*. Le modèle DeepLabV3+ prend en entrée la concaténation de l'orthophoto et du Modèle Numérique de Hauteur (MNH), et génère en sortie une carte de prédiction où chaque pixel est associé à une classe d'occupation du sol. Cette carte peut ensuite être comparée à une carte de référence labellisée pour produire une carte de changement.

2.2 Architecture du modèle

Le modèle de segmentation repose sur l'architecture DEEPLABV3+ de Google (Chen et al., 2017), implémentée via la bibliothèque [segmentation_models.pytorch](#). Nous avons choisi d'utiliser l'encodeur EfficientNet-B5 à la place de ResNet101, après une évaluation approfondie pour optimiser les performances du modèle.

La configuration du modèle est proposée en Annexe.

2.3 Entraînement

2.3.1 Données d'entraînement

Les données d'entraînement proviennent principalement du jeu de données labellisé de 2018, sélectionné pour sa qualité et pour sa période d'acquisition estivale. Toutefois, depuis cette période, les caméras utilisées pour l'acquisition des orthophotos ont changées, ce qui a entraîné des différences notables comme illustré à la Figure 2. On observe une légère variation de contraste dans les canaux RGB, une différence dans l'infrarouge, ainsi qu'une amélioration significative du MNH, qui est plus net en 2023 alors qu'il était plus flou en 2018.




Figure 2: *Comparaison des données entre 2018 et 2023.*

De haut en bas : données de 2018 puis de 2023. De gauche à droite : orthophoto RGB, image infrarouge (IR) et MNH. On observe une amélioration de la netteté des images en 2023, un contraste légèrement

différent dans le RGB, une variation de rendu dans l'IR, ainsi qu'un MNH plus précis et moins flou qu'en 2018.

2.3.1.1 Augmentation artificielle des données :

Utiliser directement les données de 2018 sans adaptation peut introduire un "distribution shift", un phénomène où les données d'entraînement ne représentent pas fidèlement celles utilisées en test ou en production, ce qui peut dégrader les performances du modèle.

Pour atténuer cet écart et améliorer la capacité de généralisation du modèle, nous avons appliqué plusieurs techniques d'augmentation de données : modification de la saturation, du contraste, de la luminosité, ainsi que des rotations. Cela permet de rendre le modèle plus robuste face aux variations de capteurs et de conditions d'acquisition. Un exemple de ces transformations est présenté à la Figure 3.




Figure 3: *Exemple d'augmentations appliquées.* En haut à gauche : image originale ; en haut à droite : augmentation de la luminosité ; en bas à gauche : diminution du contraste ; en bas à droite : augmentation de la saturation.

2.3.1.2 Séparation des données



Figure 4: *Répartition spatiale des données* — entraînement (2018), validation (2018) et évaluation (2023), de gauche à droite.

La séparation des données en plusieurs sous-ensembles est une étape cruciale pour assurer un entraînement efficace et une évaluation fiable du modèle :

- **Données d'entraînement** : Ce sont les données utilisées pour apprendre les paramètres du réseau de neurones. Le modèle s'ajuste uniquement sur cet ensemble afin d'extraire des patterns représentatifs ;
- **Données de validation** : Cet ensemble n'est pas utilisé pour l'entraînement direct, mais sert à surveiller les performances du modèle en cours d'entraînement. Il permet notamment de détecter et prévenir l'overfitting, c'est-à-dire un apprentissage excessif des données d'entraînement au détriment de la généralisation ;
- **Données d'évaluation** : Ces données sont complètement indépendantes des phases d'entraînement et de validation. Elles sont utilisées pour évaluer qualitativement et quantitativement les performances finales du modèle sur des données nouvelles, similaires à celles rencontrées en production.

Cette séparation assure que le modèle ne se contente pas de mémoriser les données d'entraînement, mais qu'il apprend à généraliser sur des données nouvelles.

Dans notre cas spécifique, les données d'entraînement et de validation proviennent du jeu labellisé de 2018, tandis que les données d'évaluation sont issues de 2023. Ce choix s'appuie sur l'existence d'un jeu de points labellisés récent, permettant une évaluation précise du modèle sur des données récentes, et une évaluation qualitative des résultats.

2.3.2 Protocole d'entraînement

L'entraînement du modèle de deep learning repose sur la sélection et l'optimisation d'hyperparamètres clés tels que le type d'encodeur, l'optimiseur, le taux d'apprentissage (learning rate) et la stratégie de planification du taux (scheduler). Étant donné le coût computationnel et environnemental important lié à l'exploration exhaustive de toutes les combinaisons possibles, il est nécessaire de limiter l'espace de recherche à un sous-ensemble pertinent.

2.3.2.1 Protocole mis en place :

- Réduction du jeu d'entraînement à la moitié de sa taille pour accélérer la phase d'entraînement ;
- Utilisation d'un jeu de validation fixe, afin d'assurer une comparaison cohérente des différentes configurations ;
- Critère d'évaluation principal : maximisation de la F1-score moyenne sur le jeu de validation ;
- Durée d'entraînement limitée à 25 epochs par configuration pour un compromis entre rapidité et pertinence des résultats.

2.3.2.2 Hyperparamètres explorés :

- Learning rates : 0.05, 0.007, 0.001, **0.0001**, 0.00001;
- Encodeurs : resnext50_32x4d, resnext101_32x8d, tu-xception71, **efficientnet-b5** ;
- Optimiseurs : SGD, Adam, **AdamW**;
- Schedulers : ReduceLROnPlateau, OneCycleLR, **PolynomialLR**, LinearLR.

Les hyperparamètres retenus pour l'entraînement final — effectué cette fois sur l'ensemble des données d'entraînement pendant 40 epochs — sont indiqués en **gras**.

3 Résultats cartographiques

3.1 Produit 2023 illustré



Figure 5: À gauche, une image satellite en RGB ; à droite, sa version segmentée selon les classes d'occupation du sol.

3.2 Produit de changement 2018-2023

La carte de changement permet de visualiser les évolutions de l'occupation du sol entre 2018 et 2023. Chaque changement est encodé à l'aide de la formule suivante :

$$code = b \times 100 + a$$

Où b représente la classe précédente (ici 2018) et a la nouvelle classe (2023). Ce format permet de regrouper toutes les transitions possibles dans une seule couche, tout en conservant l'information d'origine et de destination.

Les figures ci-dessous illustrent cet encodage pour une zone test située à Grivegnée :



Figure 6: Grivegnée 2018




Figure 7: Grivegnée 2023



Figure 8: Changement 2018-2023

Afin d'améliorer la lisibilité et la fiabilité de la carte de changement, nous avons généré un produit dérivé : la carte de changement "sieved". Ce produit applique un filtre morphologique permettant de supprimer :

- Les petites prédictions isolées (souvent liées à des artefacts en bordure de classe) ;
- Les faux positifs provoqués par de légers décalages de géolocalisation.




Figure 9: Application du filtrage sieved permettant de supprimer la majorité des effets de bord et des petites imperfections de prédiction.

4 Validation

L'évaluation du modèle a été réalisée sur un jeu de test indépendant (TEST_Set) de 1710 points définis et annoté par le SPW, avec pour objectif de mesurer sa capacité de généralisation sur des données récentes. Les performances ont été synthétisées dans une matrice de confusion, similaire à celles utilisées dans les évaluations précédentes.

Deux nouvelles classes ont été introduites dans cette version du test set : **résineux < 3m** et **feuillus < 3m**. Bien que ces classes soient peu représentées quantitativement dans les données, elles apportent une granularité supplémentaire pertinente pour certaines analyses thématiques.



L'exactitude globale de WAL_OCS_IA_2023 est de 87.1%. Il est important de prendre en considération que la qualité de la classification varie de classes en classes, et ne correspond pas en tout point à la réalité de terrain. Ainsi, les résultats révèlent un **taux de précision producteur (producer accuracy)** élevé pour la majorité des classes, ce qui indique que les pixels d'une classe donnée dans la vérité terrain sont correctement prédits dans la plupart des cas. On note notamment :

- Une excellente précision pour les classes « Eaux de surface » (96.72 %), « Couvert herbacé en rotation » (96.58 %), « Constructions artificielles hors sol » (92.46 %) et « Couvert herbacé toute l'année » (92.40 %) ;

- Des performances satisfaisantes pour les classes forestières dominantes : « **Résineux > 3m** » (80.59 %) et « **Feuillus > 3m** » (85.26 %).

En revanche, certaines classes restent plus difficiles à distinguer :

- « **Sols nus** » (46.53 %) est confondu dans près de 37 % des cas avec « **Couvert herbacé toute l'année** », probablement en raison de similarités spectrales et texturales dans certaines conditions d'acquisition ;
- Les classes « **Résineux < 3m** » et « **Feuillus < 3m** », récemment introduites, présentent une confusion notable avec leurs homologues de plus grande taille. Cela reflète la difficulté intrinsèque à discriminer des structures arborées jeunes ou de faible hauteur à partir des seules images disponibles.

Ces résultats confirment toutefois la **capacité de généralisation** du modèle : bien que l'entraînement ait été réalisé exclusivement sur des données de 2018, les performances obtenues sur des images acquises en 2023 restent élevées, démontrant la robustesse du pipeline mis en place et l'efficacité des méthodes d'augmentation appliquées durant l'entraînement.

5 Limites

Les principales limites du modèle sont liées à la qualité et à la cohérence des données d'entrée. Quelques cas problématiques sont illustrés ci-dessous :

Orthophoto 2023





Prediction




MNH



On observe un artefact dans le MNH (Modèle Numérique de Hauteur), visible sous la forme d'un "trou" noir au centre du bâtiment. Le modèle interprète alors cette zone comme étant de la voirie, ce qui entraîne une erreur de classification



La présence de reflets sur la surface de l'eau fausse la hauteur perçue dans le MNH, ce qui induit le modèle en erreur dans la prédiction des classes (confusion entre eau, route et infrastructure). Les erreurs de classification sur les principaux cours et surfaces d'eau, facilement identifiable par photo-interprétation, ont été corrigées en post-traitement par le SPW.



La résolution native du modèle ne permet pas de restituer parfaitement des formes carrées ou régulières. Cela peut engendrer des imprécisions sur les contours, en particulier dans les zones résidentielles à forte densité.

6 Conclusion

Cette nouvelle version de la carte d'occupation des sols WAL_OCS marque une étape importante dans l'évolution de la chaîne de production cartographique pour la Wallonie. L'intégration d'un pipeline plus épuré, l'usage d'une architecture de modèle performante (DeepLabV3+ avec EfficientNet-B5), ainsi que l'amélioration des stratégies d'augmentation des données ont permis de renforcer la robustesse et la généralisation du modèle.

Malgré certaines limites inhérentes aux données d'entrée (bruit, artefacts, résolution), les résultats obtenus en 2023 démontrent une amélioration en précision et en cohérence spatiale, permettant d'atteindre les seuils de qualité définis par le marché. La capacité du modèle à prédire fidèlement des classes complexes sur des images récentes, bien qu'entraîné uniquement sur des données de 2018, valide les choix méthodologiques appliqués.

Appendix 1 Configuration du modèle

```
# Model
model_name: "deeplabv3plus"
encoder_name: "efficientnet-b5"
encoder_weights: "imagenet"

# Training
batch_size: 16
learning_rate: 0.0001
img_size: 512
epochs: 40
scheduler: "polynomial"
optimizer: "adamW"
momentum: 0.9
weight_decay: 0.0001

decoder_atrous_rates: [12, 24, 36]
encoder_output_stride: 16

# Data processing
normalize_method: "standard"
computed_channel_means: [0.485, 0.456, 0.406, 0.614, 0.354]
computed_channel_stds: [0.229, 0.224, 0.225, 0.129, 0.276]
```