



cerfo

FORMATION
ACCOMPAGNEMENT
RECHERCHE
EN FORESTERIE

NOTE TECHNIQUE NO 2023-02

SEPTEMBRE 2023



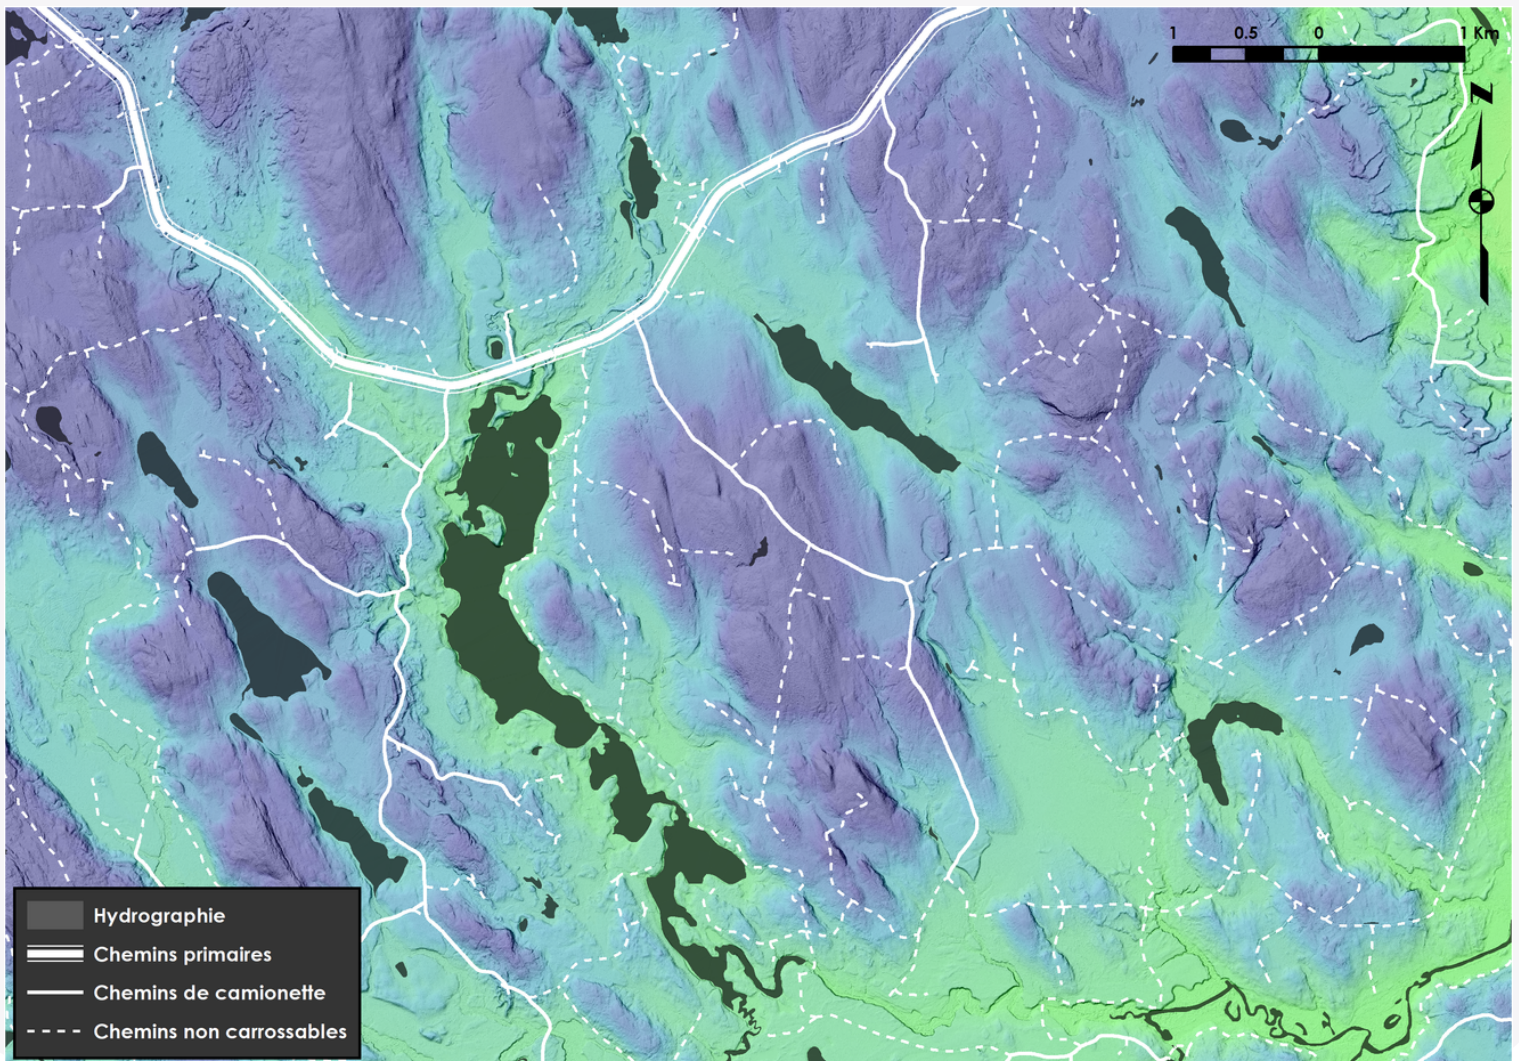
Développement d'une méthode cartographique de détection de réseaux par télédétection et apprentissage profond

Contexte	2
Objectifs du projet	3
Principales étapes	3
01. Création des jeux de données géospatiales d'entraînement et de validation	3
02. Entraînement des algorithmes de segmentation	4
03. Post-traitement	5
Résultats et interprétation	6-7
Limites	8
Pistes d'amélioration	8
Conclusion	9
Principales références	10



CONTEXTE

La mise à jour de données géospatiales requiert traditionnellement beaucoup de temps et d'efforts en fonction des territoires à traiter. Ces données, telles que le réseau routier et les données hydrographiques, permettent l'analyse du territoire pour en faciliter la gestion et l'évaluation des risques en situation d'urgence (p. ex. inondation et feux de forêt) et l'impact des changements climatiques. Les développements technologiques des dernières années, autant en intelligence artificielle qu'en observation de la Terre, permettent d'entrevoir de nouvelles solutions automatiques pour la mise à jour de ce type de données. C'est dans cette optique que le CERFO a développé une méthode générale et automatique de cartographie de réseau (p. ex. réseau routier et hydrographique) grâce à l'apprentissage profond.





Objectifs du projet

L'objectif principal du projet est de développer une méthode cartographique pour détecter des réseaux de divers types (routier, hydrographique, etc.) avec de multiples sources de données. Cette méthode a été testée avec trois combinaisons de données pour en mesurer les performances :

1. Détection de chemins forestiers avec des données lidar;
2. Détection de chemins forestiers avec l'imagerie satellitaire optique Sentinel-2;
3. Détection de cours d'eau surfaciques avec l'imagerie aérienne.

Principales étapes

La méthode développée comporte trois principales étapes, en premier l'élaboration des jeux de données géospatiales d'entraînement et de validation, en second l'entraînement et l'application d'algorithmes d'apprentissage profond pour la segmentation du réseau et finalement le post-traitement de cette segmentation permettant d'améliorer la continuité du réseau détecté.

01

Création des jeux de données géospatiales d'entraînement et de validation

Afin d'assurer la robustesse et la reproductibilité de la méthode, trois sources de données différentes ont été utilisées pour créer trois jeux de données représentant deux types de réseau (routier et hydrologique) :

1. Chemins forestiers avec des données lidar : Ce jeu de données a été conçu grâce à des bases de données du CERFO venant de trois projets dans les régions du Témiscamingue (Genest et al., 2022) et de la Mauricie ainsi que dans la municipalité régionale du comté de Portneuf. Les métriques utilisées par l'algorithme sont le modèle numérique de hauteur (MNH), le modèle numérique de terrain ombré multidirectionnel, le coefficient de variation (CV) et la pente, calculées à 1 m de résolution spatiale;
2. Chemins forestiers avec l'imagerie Sentinel-2 : Ce jeu de données, développé lors d'un projet avec la coopérative forestière La Nord-Côtère (Bour et al., 2021), comporte quatre bandes spectrales à 10 m de résolution spatiale, soit les bandes rouge, verte, bleue et proche infrarouge;
3. Cours d'eau surfacique avec l'imagerie aérienne : Ce jeu de données a été construit lors d'un projet mené par le CERFO (Marchal et al., 2022) visant l'identification des cours d'eau surfacique dans la Communauté métropolitaine de Québec et l'analyse de leur mobilité dans le temps. Ce jeu de données est constitué d'images ayant les bandes rouge, verte et bleue à 30 cm de résolution spatiale. Le but de l'utilisation de ce jeu de données est de démontrer la polyvalence de la méthode pour des types de réseaux variés.

Chaque métrique ou image des jeux de données doit ensuite être préparée pour pouvoir être utilisée par un algorithme de segmentation d'image. Cette préparation consiste d'abord à centrer-réduire les métriques et images par leur moyenne et écart-type calculés sur l'ensemble des territoires des jeux de données respectifs. Par la suite, les données sont découpées en imagerie carrées de 256 par 256 pixels, pouvant être utilisées par l'algorithme d'apprentissage profond pour la segmentation des réseaux.

02 Entraînement des algorithmes de segmentation

La détection initiale du réseau se fait par segmentation. Celle-ci permet d'attribuer à chaque pixel d'une image une prédiction correspondant à la probabilité que le pixel fasse partie du réseau. Pour faire cette segmentation, un ensemble de trois modèles d'apprentissage profond a été entraîné afin d'améliorer la certitude et la reproductibilité des réseaux segmentés (Dong et al., 2020). En effet, si tous les modèles de l'ensemble font la même prédiction, la confiance envers celle-ci est beaucoup plus grande que si les modèles font des prédictions différentes. Il est ensuite plus facile, lors du post-traitement, d'attribuer un seuil de confiance à la segmentation pour déterminer quels pixels constituent le réseau.

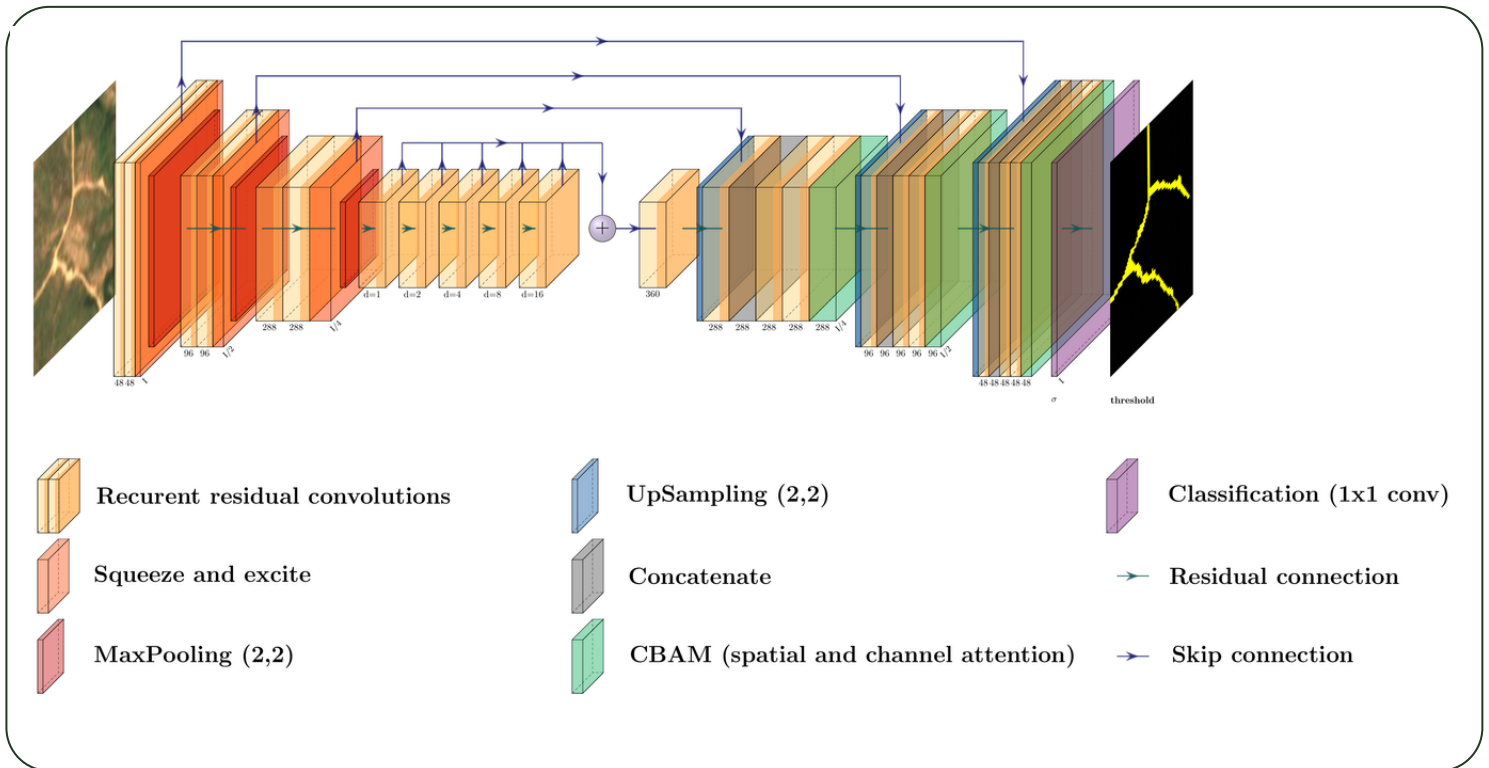


FIGURE 1 Schéma du attr2unet utilisé lors de la segmentation des réseaux, montrant la segmentation d'une image de chemin forestier sur Sentinel-2.

Les algorithmes d'apprentissage profond sélectionnés sont Attr2unet (Zuo et al., 2021), HRNet (Wang et al., 2020) et Coswin-Unet (Cao et al., 2021; Dong et al., 2022). Les deux premiers sont des réseaux de neurones à convolutions et représentent l'état de l'art dans plusieurs domaines de l'intelligence artificielle, notamment l'imagerie médicale, la réalité augmentée et la télédétection. Le dernier algorithme est quant à lui très récent et tire profit des Transformers (Dosovitskiy et al., 2021), une architecture de plus en plus utilisée en vision par ordinateur (Khan et al., 2022). Cet ensemble d'algorithmes possédant des architectures très différentes permet d'exploiter les forces et faiblesses de chacune d'elles pour maximiser la détection des réseaux. La Figure 1 montre l'architecture du Attr2unet et schématise la segmentation de chemins forestiers sur une image.

03

Post-traitement

Une fois les modèles entraînés et appliqués sur le territoire d'intérêt, il faut transformer la segmentation (probabilité par pixel) en un réseau binaire, où la valeur de 1 représente la présence du réseau et 0 l'absence de réseau. Pour ce faire, les prédictions des trois modèles de l'ensemble sont additionnées et un seuil de confiance de 85 % (trouvé de façon à optimiser le f1-score en validation) est appliqué à la prédiction, permettant d'obtenir un premier masque binaire. Par la suite, une technique de post-traitement supplémentaire a été développée pour faire des corrections sur trois types d'erreurs fréquemment observées sur les masques, soit un réseau discontinué, un segment de réseau n'étant pas relié au réseau principal et un segment de réseau détecté par erreur (commission). Cette technique consiste en 5 étapes, décrites et illustrées ici-bas

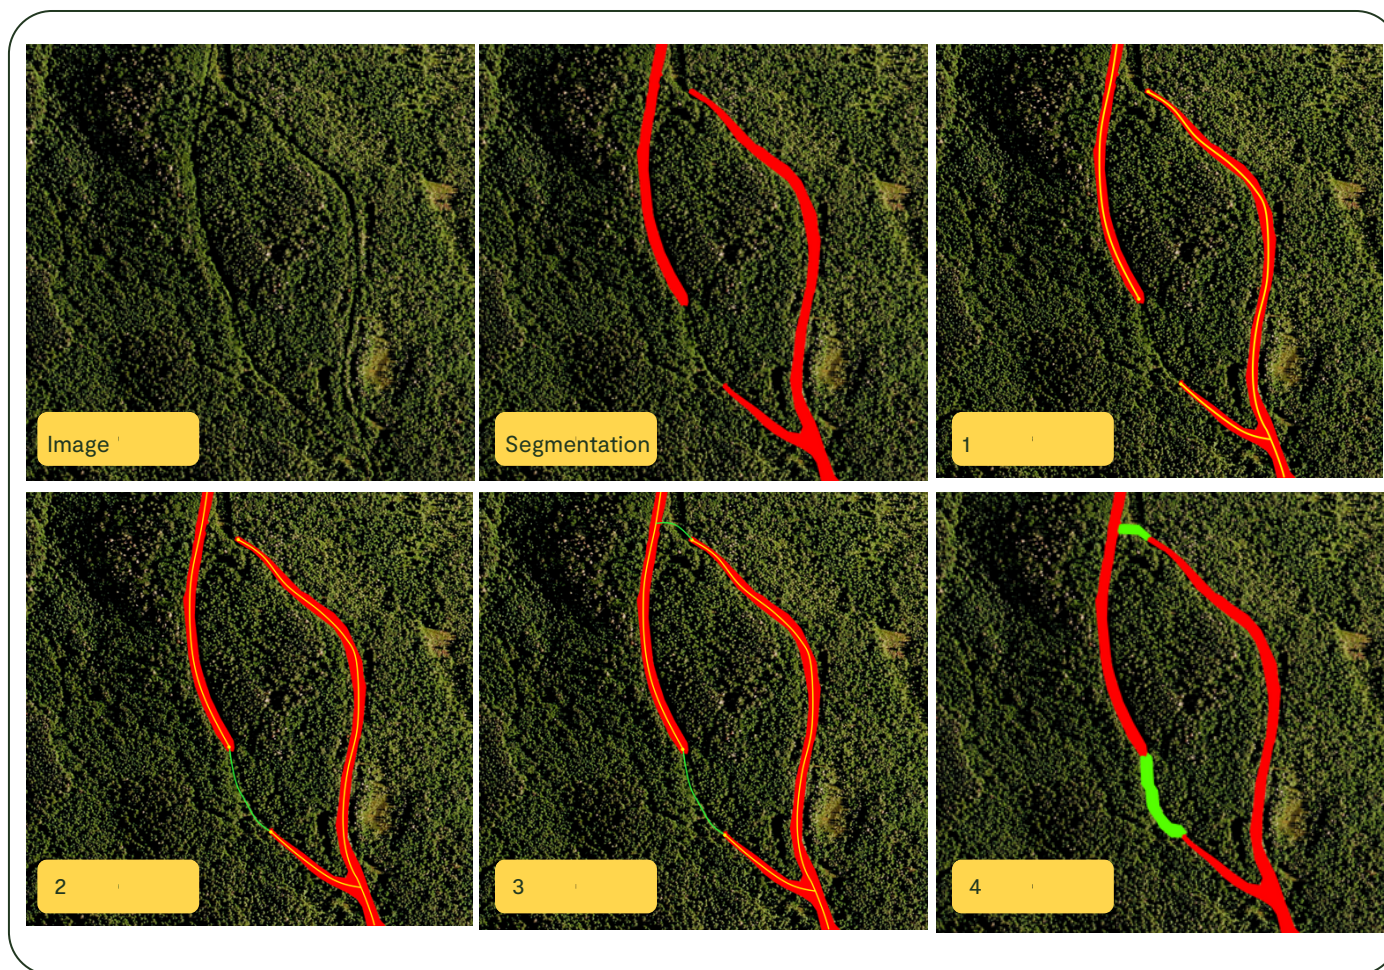


FIGURE 2 Schéma du post-traitement illustrant les différentes étapes. À noter que l'étape 5 a été omise à cette échelle.

1. Extraction de la centre-ligne et des extrémités du réseau détecté;
2. Connexion des extrémités qui sont à proximité l'une d'elles, trouvée par la méthode du chemin de moindre coût sur la prédiction;
3. Connexion des extrémités qui sont à proximité du réseau principal, trouvé par la méthode du chemin de moindre coût sur la prédiction;
4. Calcul des largeurs des nouvelles connexions afin qu'elles aient la même largeur que les segments qui y sont connectés;
5. Suppression de tous les segments ayant une longueur inférieure à 4 km (seuil choisi visuellement selon la taille des prédictions), permettant d'éviter les erreurs de commission.

Résultats et interprétation

L'utilisation de plusieurs jeux de données a permis d'assurer le fonctionnement de la méthode et du post-traitement sur différents types de capteurs (lidar, caméra optique) et de résolutions (30 cm, 1 m, 10 m) et d'analyser les performances et les limites attendues. Des exemples de résultats sont illustrés à la Figure 3.

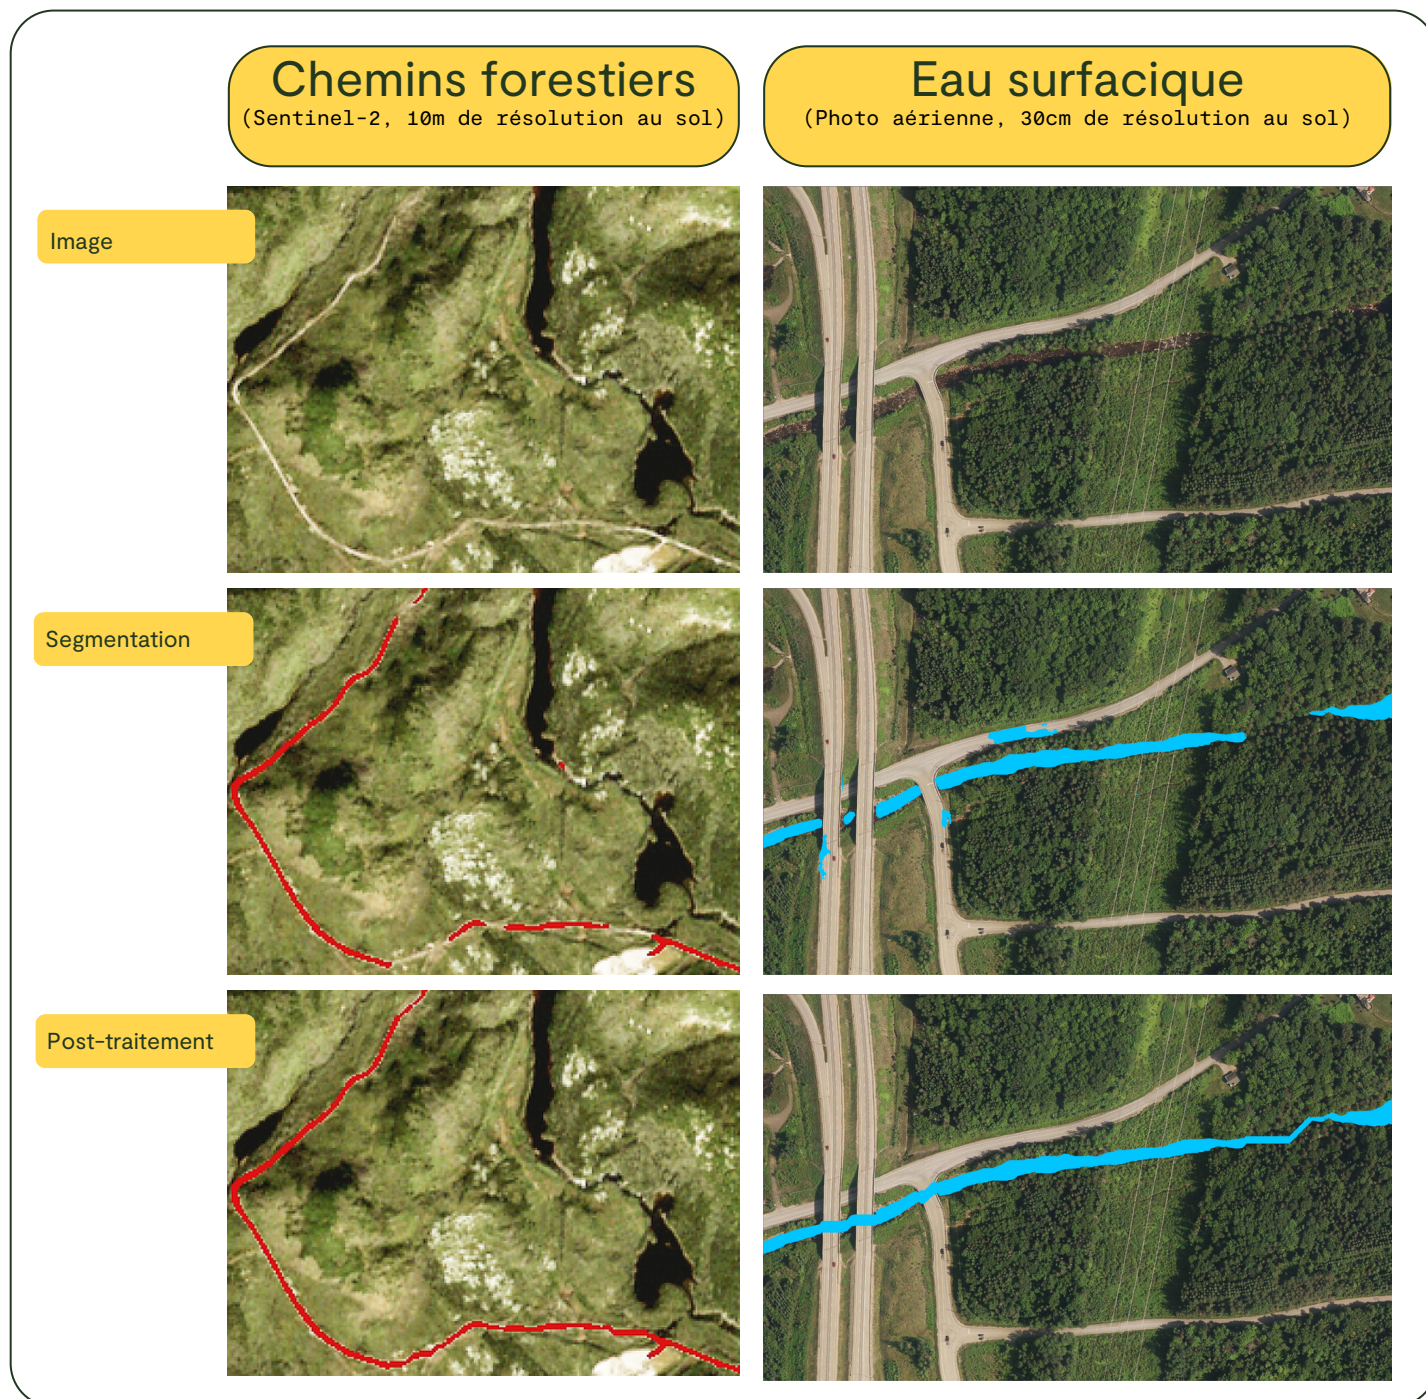


FIGURE 3 Exemple de segmentation de post-traitement sur données satellitaires (gauche) et aériennes (droite). Les chemins forestiers sont en rouge et les cours d'eau surfaciques en bleu



Le Tableau 1 montre d'abord une grande différence entre le nombre de pixels faisant partie du réseau et les autres. Dans les trois jeux de données, les pixels faisant partie d'un chemin ou d'un cours d'eau comptent entre 0,5 et 2,1 % comparativement à ceux ne faisant pas partie du réseau. Cette différence est à prendre en compte lors de l'analyse des performances pour ne pas sous-évaluer les erreurs de commission de la classe « autre », car chaque pourcentage d'erreur engendre entre 60 et 200 fois plus de pixels erronés.

Afin de mesurer les performances de la méthode et d'étudier l'effet du post-traitement, le F1-score a été mesuré pour chacun des jeux de données avant et après le post-traitement. De plus, les matrices d'erreur ont été calculées suite à l'application de la méthode (incluant le post-traitement) et sont montrées au Tableau 2. Ces résultats sont satisfaisants pour la segmentation et la détection des réseaux, atteignant des précisions entre 75 et 90 % pour la détection des réseaux. De plus, les erreurs de commission (entre 0,2 et 0,9 %) et d'omission (entre 10,0 et 25,0 %) restent relativement faibles, indiquant une très bonne confiance dans la qualité des réseaux détectés et une faible quantité de chemins faussement cartographiés.

En ce qui concerne l'impact du post-traitement sur la segmentation, le principal effet est une diminution considérable des erreurs de commission se traduisant par une augmentation du F1-score se situant entre 1 et 2,5 %. Bien que cette augmentation soit petite, elle indique une meilleure continuité dans le réseau détecté et une très grande confiance envers celui-ci. En effet, l'étape 5 du post-traitement, soit la suppression des segments n'étant reliés à aucune partie du réseau, a tendance à supprimer des segments de vieux chemins ou de petits ruisseaux faisant partie du réseau. Cette étape ajoute quelques erreurs d'omission et explique le gain plus faible concernant le F1 score. Cependant, ces suppressions permettent d'augmenter la continuité du réseau détecté et de maximiser la confiance envers celui-ci.

Tableau 1. Résultats comparatifs du f1 score de validation des trois jeux de données

	Proportion du territoire occupé par le réseau [%]	F1 score	
		Segmentation	Post-Traitement
Chemins sur données lidar	1,6	0,7683	0,7932
Chemins sur Sentinel-2	0,5	0,6819	0,6933
Eau surfacique	2,1	0,7984	0,8104

Tableau 2. Matrices d'erreur de validation des trois jeux de données suite au post-traitement.

Références						
Chemins sur données lidar		Chemins sur Sentinel-2		Eau surfacique		
	Autre	Réseau	Autre	Réseau	Autre	Réseau
Autre (prédictions)	0,9961	0,0039	0,9916	0,0084	0,9983	0,0017
Réseau (prédictions)	0,1070	0,8930	0,1410	0,8590	0,2456	0,7544

En conclusion, la méthode développée permet de cartographier différents types de réseaux, allant des chemins forestiers avec des données lidar à l'identification de l'eau surfacique avec l'imagerie aérienne. De plus, la détection peut atteindre jusqu'à 90 % de précision et assure une continuité dans le réseau, aspect souvent nécessaire pour un suivi temporel ou son utilisation par d'éventuels utilisateurs.

Limites

Bien que l'algorithme ait montré une bonne capacité à détecter et cartographier différents types de réseaux, deux limites ont été relevées




FIGURE 4 Exemple d'un segment de vieux chemin sous couvert forestier n'ayant pas été détecté par la méthode.

Premièrement, comme mentionné dans la section sur les résultats, une limite importante est l'augmentation des erreurs d'omission lorsque le réseau est peu visible. En effet, il s'agit d'une faiblesse des algorithmes de vision par ordinateur qui sont incapable de détecter quelque chose qu'ils ne voient pas bien. Ces omissions sont corrigées, en partie, par la technique de post-traitement développée qui supprime les segments indépendants. Il s'agit d'un choix qui a été fait afin de favoriser la continuité du réseau détecté. Cependant, la longueur minimale de quatre kilomètres a été mise comme paramètre ajustable dans l'algorithme de post-traitement et est à la discrétion de l'utilisateur afin de trouver des chemins plus anciens ou peu visibles.

Deuxièmement, bien que l'algorithme de post-traitement permette de relier une grande quantité de segments et d'en assurer la continuité, il s'agit d'un algorithme systématique qui peut commettre des erreurs. Un exemple serait, un pont ou un ponceau effondré qui crée une réelle discontinuité dans le réseau, mais qui serait reliée à l'étape du post-traitement. Ces obstructions ponctuelles sont importantes à considérer dans l'analyse du réseau et crée des erreurs au niveau de la continuité, mais sont tout de même reliées de façon systématique.

Pistes d'amélioration

Afin de pallier les limitations de la méthode, plusieurs pistes d'amélioration ont été identifiées.

D'abord, un algorithme de détection de défauts ponctuels pourrait être développé afin de s'assurer de créer une brisure dans le réseau à ces endroits. Le défi de cet algorithme demeure cependant grand puisque chaque type de réseau n'a pas nécessairement le même type d'obstruction ponctuelle. Il peut s'agir, par exemple, d'un pont effondré dans le cas d'un réseau routier ou d'un nouveau barrage dans le cas d'un cours d'eau.

Il pourrait ensuite être possible de développer une méthode moins systématique, basée sur la vision par ordinateur et l'intelligence artificielle, afin de faire le post-traitement. Des algorithmes de ce type, utilisant l'apprentissage par renforcement, ont été développés et fournissent des résultats prometteurs (Jagwani, 2021). Hors, la difficulté réside dans l'entraînement et la convergence de ces algorithmes afin d'obtenir des résultats intéressants et robustes, qui ont été laissés comme pistes d'amélioration dans le cadre de ce projet.

Conclusion

Le projet visait le développement d'une méthode automatique et générale de détection de réseau étant assez polyvalente et robuste pour qu'elle soit appliquée sur différents types de données (p. ex. lidar, imagerie satellitaire, imagerie aérienne) et différentes résolutions au sol (p. ex. 30 cm et 1 m). Pour ce faire, trois jeux de données distinctifs ont été construits afin d'entraîner trois modèles de segmentation et de développer une toute nouvelle technique de post-traitement. Les performances de détection, variant entre 75 et 90 % de précision selon les jeux de données, sont très satisfaisantes et démontrent le potentiel d'application face à différentes problématiques.

Cependant, certaines limitations ont été observées, notamment concernant l'omission de parties peu visibles du réseau, où celles-ci se retrouvent supprimées par l'algorithme de post-traitement. De plus, la méthode actuelle risque de joindre des parties du réseau qui ne communiquent pas réellement étant donné la présence d'obstacles ponctuels qui ne sont pas détectés.

Certaines pistes d'amélioration sont envisagées pour pallier ces limitations, visant l'amélioration de l'algorithme de post-traitement grâce à l'apprentissage par renforcement et la vision par ordinateur. D'autres techniques ayant beaucoup de potentiel sont également activement développées depuis quelques années seulement, notamment les Graph Neural Networks et les Transformers, et doivent rester dans la mire des chercheurs et des chercheuses pour l'amélioration continue des techniques de segmentation et de détection.




FIGURE 5 Exemple de prédiction sur données lidar dans la région de Portneuf.



Références

Bour, B., Genest, M.-A., Rashidfar, M. et Varin, M. (2021) Comparaison de méthodes de détection de chemins forestiers à partir d'imagerie satellitaire (Sentinel-2) : apprentissage automatique vs profond. (Technote No. 2021-03) (p. 5). CERFO.

Cao, H., Wang, Y., Chen, J., Jiang, D., Zhang, X., Tian, Q. et Wang, M. (2021) Swin-Unet: Unet-like Pure Transformer for Medical Image Segmentation. arXiv:2105.05537 [cs, eess].

Dong, X., Bao, J., Chen, Dongdong, Zhang, W., Yu, N., Yuan, L., Chen, Dong et Guo, B. (2022) CSWin Transformer: A General Vision Transformer Backbone with Cross-Shaped Windows. arXiv:2107.00652 [cs].

Dong, X., Yu, Z., Cao, W., Shi, Y. et Ma, Q. (2020) A survey on ensemble learning. Frontiers of Computer Science, vol. 14, n° 2, p. 241-258.

Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J. et Houshly, N. (2021) An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. arXiv:2010.11929 [cs].

Genest, M.-A., Bour, B., Coutier, C. et Varin, M. (2022) Détection de chemins forestiers et de leur état à partir de données lidar et d'apprentissage profond - Cas de la MRC du Témiscamingue (Technote No. 2022-07) (p. 6). Québec (QC) : Centre d'enseignement et de recherche de Sainte-Foy inc. (CERFO).

Jagwani, S. (2021) Map Inference from Satellite Segmentation Data through Reinforcement Learning: A Novel Approach. Thèse de doctorat, Massachusetts Institute of Technology, 56 p.

Khan, S., Naseer, M., Hayat, M., Zamir, S. W., Khan, F. S. et Shah, M. (2022) Transformers in Vision: A Survey. ACM Computing Surveys, vol. 54, n°10 s, p. 1-41.

Marchal, J., Gallagher-Duval, X., Genest, M.-A., Rashidfar, M. et Varin, M. (2022) Mobilité passée et future de 24 rivières de la Communauté métropolitaine de Québec (p. 5). CERFO.

Wang, J., Sun, K., Cheng, T., Jiang, B., Deng, C., Zhao, Y., Liu, D., Mu, Y., Tan, M., Wang, X., Liu, W. et Xiao, B. (2020) Deep High-Resolution Representation Learning for Visual Recognition. arXiv:1908.07919 [cs].

Zuo, Q., Chen, S. et Wang, Z. (2021) R2AU-Net : Attention Recurrent Residual Convolutional Neural Network for Multimodal Medical Image Segmentation. Security and Communication Networks, vol. 2021, p. e6625688.

cerfo

FORMATION
ACCOMPAGNEMENT
RECHERCHE
EN FORESTERIE

Tél. : (418) 659-4225
Courriel : info@cerfo.qc.ca

Communiquez avec notre équipe :

Marc-Antoine Genest, M. Sc.

Batistin Bour, M. Sc.

Clément Coutier, techn. forest.

Mathieu Varin, M. Sc.

