



Technote

cerfo

FORMATION
ACCOMPAGNEMENT
RECHERCHE
EN FORESTERIE

NOTE TECHNIQUE NO 2023-03

Octobre 2023



Cartographier les combustibles forestiers pour un futur ignifugé

Contexte et objectifs du projet

- 01. Données utilisées et prétraitements
- 02. Algorithme de détection de bâtiments
- 03. Algorithme de classification des combustibles forestiers
- 04. Cartographie
- 05. Performances
- Limites
- Recommandations
- Références

- 01.
- 02.
- 03.
- 04.
- 07.
- 08.
- 10.
- 12.
- 13.

ÉQUIPE DE RÉALISATION

- Batistin Bour, M. Sc.
- Marc-Antoine Genest, M. Sc.
- Martin Dupuis, M. Sc.
- Fiston Nininahazwe, M. Sc.
- Marc-Antoine Martineau, tech. geom.
- Clément Coutier, tech. for.
- Samuel Veilleux, M. Sc.
- Mathieu Varin, M. Sc.

Contexte

Les feux de forêt constituent la perturbation naturelle principale des forêts du Québec, et peuvent être une menace importante pour certaines populations. Les modèles climatiques convergent vers une augmentation de l'occurrence des feux dans le futur. Il est donc impératif d'identifier les zones d'habitations humaines à risque afin de mettre en œuvre des actions pour atténuer leur vulnérabilité. La Société de protection des forêts contre le feu (SOPFEU) soumet des recommandations aux municipalités afin de réduire les risques liés aux incendies de végétation. La visualisation des secteurs à risque est un élément clé dans l'élaboration de ces recommandations (Figure 1). Toutefois, dans la zone nordique, très peu de données géospatiales existent pour caractériser l'environnement et les infrastructures. L'utilisation de la photo-interprétation comme méthode d'inventaire pour les municipalités constitue une tâche de grande ampleur. Dans ce contexte, le développement d'outils d'automatisation de la cartographie des combustibles forestiers et des bâtiments a le potentiel d'augmenter la capacité de la SOPFEU à agir.

Objectifs du projet

Développer des algorithmes permettant de classer et de cartographier les combustibles forestiers et l'exposition aux risques afin d'aider les communautés à réduire les risques liés aux incendies de végétation de la zone nordique [1]

01

Développer un algorithme basé sur l'intelligence artificielle permettant d'identifier et de classer les combustibles forestiers et l'emprise des bâtiments en zone nordique à partir d'images satellitaires à très haute résolution spatiale (THRS; 50 cm minimum);

02

Fournir des cartes de combustibles forestiers et d'exposition aux risques pour 7 communautés;

03

Identifier les renforcements de l'algorithme nécessaires à son intégration dans un outil automatique permettant une autonomie de la SOPFEU dans les zones nordique et intensive.



FIGURE 1. Feu à proximité de Sept-Îles survenu au printemps 2023, imagerie Sentinel-2.

Méthodologie

1. Données utilisées et prétraitements

Les images satellitaires ont été choisies par secteur selon la disponibilité d'images exemptes de nuages pendant la saison de croissance de la végétation, en favorisant les images les plus récentes possibles. Un total de 22 images satellitaires ont ainsi été sélectionnées, acquises entre 2017 et 2022 (Tableau 1). Tous les secteurs bénéficient de plusieurs images acquises par différents satellites à différentes dates (Figure 2). Certains secteurs profitent même de plusieurs images acquises à différentes dates par un même satellite.

Satellite	Résolution Panchromatique	Résolution Multispectrale	Largeur de bande spectrale (nm)					Nombre d'images disponibles
			Pan *	Bleu	Vert	Rouge	PIR *	
Jillin-14	0,5 m	2 m	450-800	450-510	510-580	630-690	770-895	8
Kompsat-3	0,5 m	2 m	450-900	450-520	520-600	630-690	760-900	5
Pléiades-1B	0,5 m	2 m	480-820	450-530	510-590	620-700	775-915	4
WorldView-2	0,46 m	1,8 m	450-800	450-510	510-580	630-690	770-895	2
WorldView-3	0,31 m	1,24 m	450-800	450-510	510-580	630-690	770-895	3

*Pan : panchromatique
*PIR : proche infrarouge

TABLEAU 1. Détail des images satellitaires utilisées.




FIGURE 2. Carte de la localisation des secteurs d'intérêt et disponibilité des images satellitaires (l'emprise des images est approximative).

Plusieurs prétraitements ont été appliqués à chaque image. Premièrement, des corrections atmosphériques ont été appliquées pour obtenir une réflectance au niveau du sol. Ensuite, les bandes multispectrales ont été fusionnées avec la bande panchromatique (pansharpening) pour obtenir des images rééchantillonnées à 50 cm de résolution spatiale. Par la suite, afin d'orthorectifier et superposer correctement les images d'un même secteur, un modèle numérique de terrain du Shuttle Radar Topography Mission [2] a été utilisé tandis qu'une image de référence (sélectionnée en se basant sur une analyse visuelle du meilleur positionnement de l'image par rapport aux autres éléments fixes tels que le réseau routier) a été utilisée pour collecter les points de contrôle visibles sur celle-ci et sur l'image à corriger. L'erreur quadratique moyenne est, en moyenne, de 0,46 pixel, soit 23 cm. Tous ces prétraitements ont été réalisés à l'aide de Catalyst Professional.

2. Algorithme de détection de bâtiments

2.1 Données disponibles et entraînement d'un premier algorithme

La détection des bâtiments est un aspect important du projet, nécessaire à l'évaluation des zones à risque. Cependant, elle s'avère difficile, car il y a peu de bâtiments dans les secteurs d'intérêt. L'entraînement d'un algorithme de cartographie automatique nécessite un grand nombre de données d'entraînement, et il n'y avait pas assez de bâtiments présents dans les images acquises pour entraîner un algorithme. Toutefois, ce type de détection est d'un grand intérêt pour divers acteurs dans le suivi du développement urbain par exemple. C'est dans cette optique que IQT Labs, en partenariat avec Maxar, a fondé les compétitions SpaceNet Challenge et publié plusieurs jeux de données pour la détection de bâtiments partout à travers le monde depuis 2016 [3].

Ces jeux de données contiennent environ 67 000 km² d'images annotées et plus de 11 millions d'empreintes de bâtiments. Ils ont permis de créer un premier jeu de données d'entraînement sur les satellites WorldView-2 et 3 contenant environ 60 000 imagerie de 256 par 256 pixels. Une standardisation par satellite a été appliquée aux images pour l'uniformisation des histogrammes. Ce jeu de données a été utilisé pour l'entraînement d'un premier algorithme de détection de bâtiments, de type Attention-recurrent-residual-Unet.

2.2 Apprentissage actif et ajustement fin

L'algorithme entraîné a été appliqué sur les images WorldView-2 et 3 des secteurs d'intérêt et a permis de détecter environ 50 % des bâtiments (les résultats sur les autres images satellitaires n'ont pas été concluants et n'ont pas été utilisés à cette étape). Cette première détection a servi d'aide à la photo-interprétation afin de créer un jeu de données d'environ 1 000 imagerie à Chibougamau et à La Romaine sur l'ensemble des satellites utilisés dans le cadre du projet.

L'algorithme de détection de bâtiments a ensuite été ajusté avec ce jeu de données, en fixant les paramètres de l'algorithme et en n'entraînant que sa dernière couche neuronale, soit la couche de classification. Cette technique a permis d'obtenir un taux de détection d'environ 75 % des bâtiments sur toutes les images acquises.

Une seconde itération de photo-interprétation a été faite afin de générer un jeu de données de 15 000 imagerie. Ce jeu de données a été fusionné avec celui de SpaceNet afin d'avoir un jeu de données de 75 000 imagerie pour entraîner l'algorithme final de détection de bâtiments multi-capteurs. Ce dernier a permis de détecter environ 90 % des bâtiments sur l'ensemble des capteurs (figure 3).



FIGURE 3 . Exemple de détection de bâtiments (contour rouge) à Chibougamau sur l'imagerie WorldView-3.

2.3 Post-traitement

La technique de post-traitement implémentée consiste d'abord à supprimer les bâtiments détectés possédant une aire plus petite que 2 m², permettant de corriger la plupart des erreurs de commission. Ensuite, étant donnée la faible quantité de bâtiments dans les secteurs d'intérêt, des corrections manuelles ont été apportées afin de s'assurer de la qualité de la détection.

Ces post-traitements ont été faits pour chaque image satellitaire acquise permettant d'avoir un masque de bâtiments par image satellitaire, utilisé lors du post-traitement des prédictions de combustibles pour la classe de gazon.

3. Algorithme de classification des combustibles forestiers

3.1. Données de référence pour la classification

Afin d'obtenir des données de référence pour entraîner l'algorithme de classification, des classes de combustibles forestiers ont été définies pour d'abord photo-interpréter des zones de chaque secteur d'intérêt dans chaque image. Bien que plusieurs systèmes de classes de combustibles forestiers existent déjà, les classes actuellement disponibles au Canada font l'objet d'un travail de refonte. Ainsi, des classes plus générales pouvant être raffinées dans le futur ont été élaborées (tableau 2).

Classes de combustible	Éléments inclus
Non Combustible	Sablière, Roc, route
Eau	Étendue d'eau, rivière
Milieu Humide	Dénudé humide, marais, marécage
Végétation Rase	Cladonie, mousse, bryophyte
Gazon	Végétation basse entretenue
Végétation Basse	Terrain avec herbacées non entretenues
Végétation Arbustive	Terrain avec arbustes
Forêt à couvert feuillu	Essences feuillues majoritaires, aulnaie
Forêt à couvert résineux	Essences résineuses majoritaires

TABLEAU 2. Classes de combustibles prises en compte pour entraîner l'algorithme de classification et description des éléments inclus.

Dans chaque secteur d'intérêt, des zones de photo-interprétation ont été délimitées par des carrés de 4 ha, superficie qui permet un découpage optimal des données par la suite (figure 4). Ces zones, d'abord photo-interprétées sur une image, ont été reportées et ajustées sur les autres images superposées permettant ainsi de rapidement augmenter les données de référence pour plusieurs satellites. Chaque classe a été caractérisée en quantités le plus égales possible. Au total, les zones photo-interprétées et adaptées à chaque image satellite représentent près de 9 774 hectares.

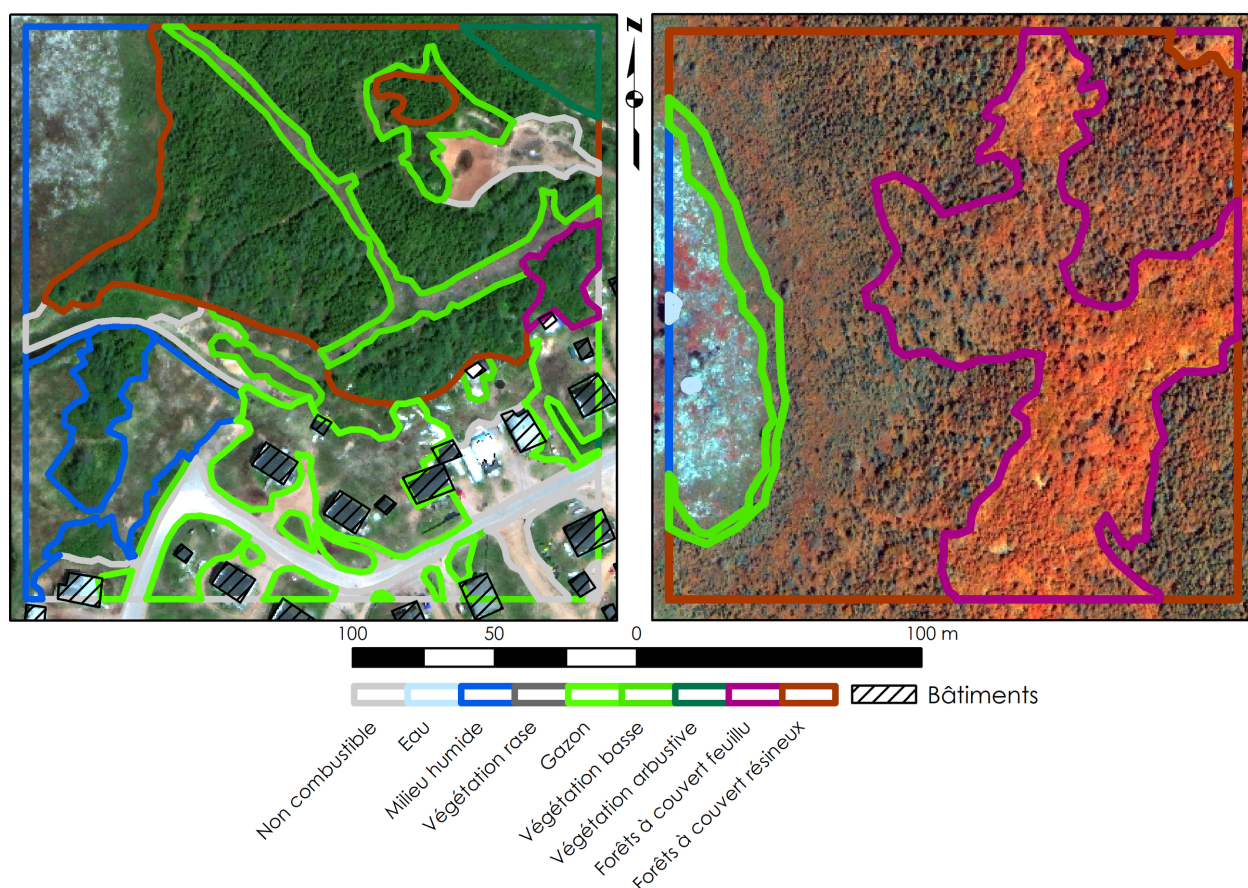


FIGURE 4. Exemples de zones de photo-interprétation avec une image Worldview-3 en couleurs vraies (Rouge-Vert-Bleu; à gauche) et fausses couleurs (Proche Infrarouge-Vert-Bleu; à droite).

3.2 Préparation des jeux de données

Les algorithmes d'apprentissage profond ont besoin de données uniformes, nécessitant de normaliser et de découper les images satellitaires afin de créer deux jeux de données, soit des imagerie d'entraînement et de validation.

La présence de plusieurs satellites, et donc de capteurs, peut poser un problème, car les histogrammes des images peuvent varier et impacter la performance et la robustesse des algorithmes. Pour pallier ce problème, une normalisation utilisant les moyennes et les écarts-types de chacun des satellites a été effectuée et chaque image standardisée (moyenne de zéro et écart-type de 1) en fonction du satellite.

Par la suite, les images satellitaires ont été découpées en imagerie de 96 par 96 pixels (48 par 48 mètres) afin de créer 11 640 imagerie (figure 5). Parmi ces imagerie, toutes celles se situant à Chevery et celles ayant été acquises par le satellite WorldView-3 à Kegaska ont été utilisées comme jeu de validation, tandis que le reste a été utilisé comme jeu d'entraînement. Cette séparation a permis d'avoir 9 705 imagerie d'entraînement et 1 935 imagerie de validation, soit un ratio d'environ 83 % d'entraînement et 17 % de validation.




FIGURE 5. Exemple d'une imagerie (Worldview-3) utilisée lors de l'entraînement d'un algorithme de classification des combustibles forestiers. Les couleurs de l'image de droite représentent les classes utilisées.

3.3 Entraînement de l'algorithme

La technique choisie pour déterminer le type de combustible forestier est la segmentation sémantique, permettant d'attribuer une classe par pixel à une image. Un ensemble d'algorithmes de segmentation sémantique a été entraîné. Les ensembles d'algorithmes, couramment utilisés en intelligence artificielle, ont pour but d'augmenter la précision d'une classification en réalisant des prédictions avec plusieurs algorithmes sur une même image. En fusionnant ensuite ses prédictions, par exemple par une moyenne, les valeurs aberrantes qu'un algorithme unique pourrait prédire sont ainsi exclues. La force de cette approche provient donc de la diversité d'algorithmes entraînés afin que ceux-ci commettent des erreurs différentes qui seront réduites lorsque combinés.

Deux architectures différentes ont été sélectionnées, chacune entraînée avec deux fonctions de pertes différentes, créant un ensemble de quatre algorithmes. D'abord, deux architectures très différentes ont été utilisées, le Attention-recurent-residual-Unet [4] utilisant les convolutions uniquement (figure 6) et le ConSwin-Unet [5] utilisant un mélange de convolutions et de transformers. Ensuite, la première fonction de perte utilisée est la Dice Loss combinée avec un encodage dur et la seconde est l'entropie croisée binaire combinée avec un encodage lisse [6]. Ces deux fonctions de pertes ont pour but de favoriser des précisions égales et confiantes pour chacune des classes dans le cas de la première fonction et d'incorporer une notion de "doute" diminuant les risques et l'impact du surapprentissage dans le cas de la deuxième.

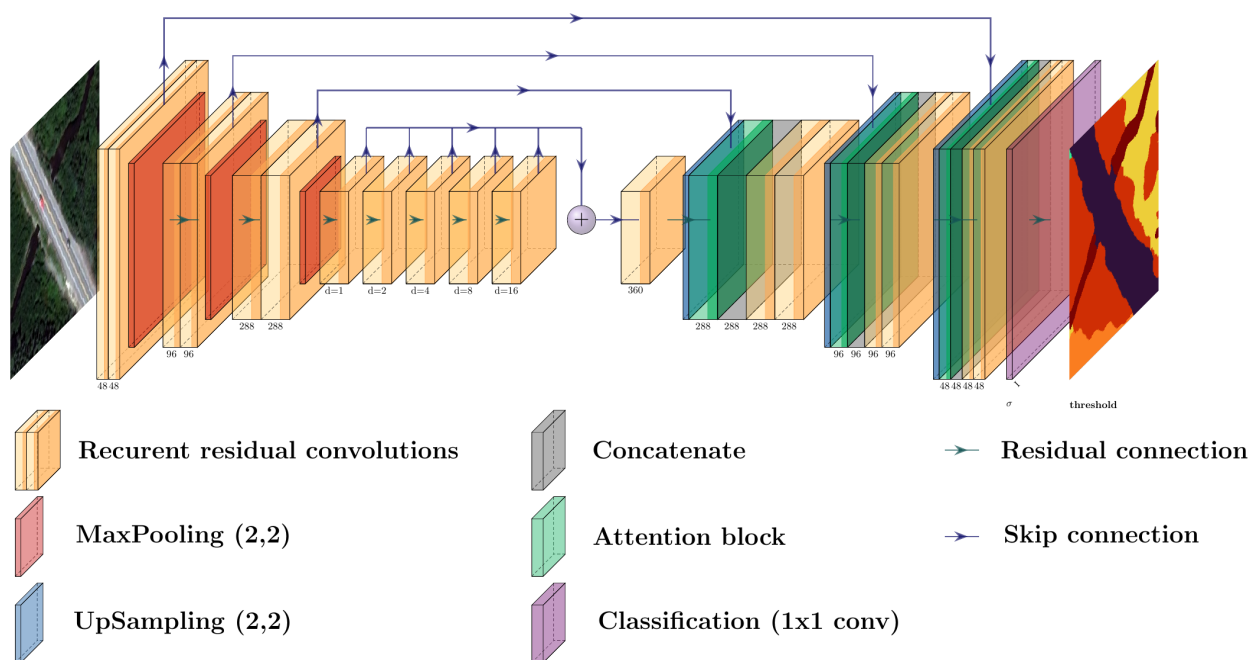


FIGURE 6. Schéma de l'algorithme Attention-recurent-residual-Unet

Ces quatre algorithmes ont été entraînés pour 75 itérations avec une taille de batch de 64 imquettes et un taux d'apprentissage de $7e-4$ avec une diminution co-sinusoidale jusqu'à 0. Le temps d'entraînement est d'environ quatre heures par algorithme sur une carte graphique A6000.

3.4 Prédiction et post-traitements

Pour appliquer l'algorithme à une image satellitaire, trois étapes ont été nécessaires. D'abord, en fonction du satellite, l'image a été normalisée avec les mêmes moyennes et écart-types calculés lors de la préparation des données. Par la suite, une prédiction par algorithme de l'ensemble a été réalisée en balayant l'image avec une fenêtre de 96 par 96 pixels pour extraire des imquettes à prédire et enregistrer le résultat. Finalement, une fois les quatre prédictions réalisées, elles ont été moyennées et la classe à assigner a été déterminée par le plus grand score dans un pixel.

Des post-traitements ont ensuite été appliqués:

- Dans la classification, les éléments de moins de 10 m² ont été supprimés et remplacés grâce à un algorithme de plus proche voisin. Cette technique a permis d'éliminer certains artefacts et de retirer les éléments qui ne sont pas d'intérêt dans la classification;
- Les zones de "gazon" se situant à plus de 75 mètres d'un bâtiment ont été converties en "végétation basse", ce qui permet d'éliminer les confusions entre ces deux classes dans des zones considérées, par hypothèse, non entretenues.

4. Cartographie

La méthode a été appliquée à l'image la plus récente disponible dans chaque secteur, permettant d'obtenir une cartographie des bâtiments et des combustibles forestiers pour chaque communauté. Des produits dérivés de la cartographie des combustibles forestiers ont pu être créés. Premièrement, la présence de combustibles dangereux, soit les forêts à couvert résineux, à proximité des bâtiments a été identifiée. Deuxièmement, les expositions à la chaleur radiante et à la dissémination des feux à courte et longue distance, soit les cartes d'évaluation Intelli-feu [7], ont été calculées selon les méthodes de Beverly et al. (2010) [8] (figure 7).

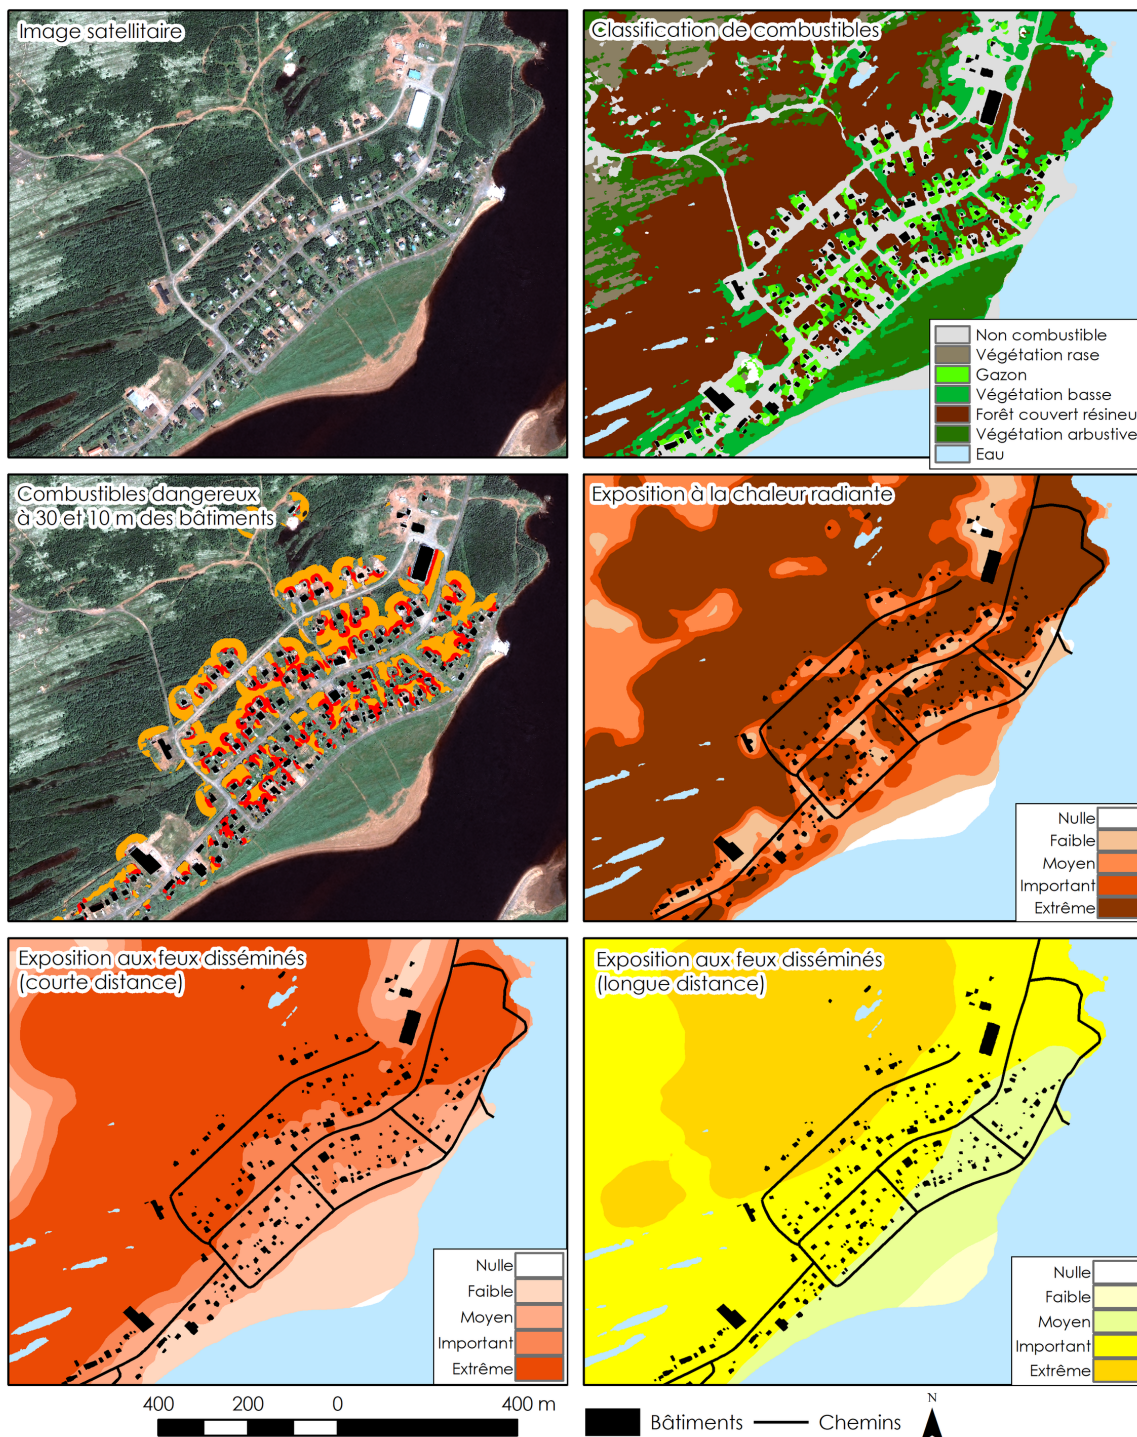


FIGURE 7. Exemple de classifications de combustibles forestiers issues de l'algorithme développé, ainsi que des cartes d'analyses des risques d'exposition aux feux de végétation qui en sont dérivées.

5. Performances

Les performances de classification ont été évaluées en validant par photo-interprétation la classe attribuée à 20 polygones par classe sélectionnée aléatoirement, pour tous les secteurs et images satellites disponibles, soit un total de 4 140 polygones.

Par classe, le succès de classification global est excellent pour la classe Eau et Gazon (95 et 91 % de succès respectivement) et très bon pour les classes Non combustible et Forêt à couvert résineux (89 et 89 % de succès respectivement). La classe Milieux Humide est quant à elle la classe avec le moins de performances avec 48 % de succès de classification (figure 8).




FIGURE 8. Les performances de classification par classe, tous secteurs et satellites confondus.

L'analyse des performances a également été réalisée en quantifiant les erreurs de classification (figure 9). La classe Milieu Humide, qui présente le plus faible succès de classification, est généralement mal classifié en tant que Végétation Rase (12 % des erreurs), Non Combustible (8 % des erreurs), Végétation Basse (6 % des erreurs), Végétation Arbustive (6 % des erreurs) et Eau (4,3 % des erreurs). L'information importante qui ressort de cette analyse est que la classe Forêt à couvert Résineux n'a pas été retrouvée dans les erreurs de classification, ce qui montre que l'algorithme n'est pas susceptible d'omettre cette classe de combustible forestier dangereux.




FIGURE 9. Pourcentage de polygones de validation erronés, par classe.

5. Performances... suite

L'analyse des performances a également été réalisée par satellite (figure 10). Le secteur de La Romaine a été utilisé, étant couvert par quatre satellites. Globalement, les performances sont similaires entre les satellites, excepté pour les résultats provenant des images Jilin-14 qui sont nettement moins performants, même dans des classes à succès élevé tel que la classe Eau.




FIGURE 10. Comparaison des performances de classification selon la source d'image satellitaire, secteur La Romaine.

Entre les secteurs d'intérêt, des variations de performances ont été relevées (figure 11). La classe Eau reste la classe avec le plus de succès, mais montre un succès beaucoup plus faible dans le secteur de Vieux-Fort où les conditions d'ensoleillement causent beaucoup de reflets dans l'image WorldView-3. Dans les classes de végétation, la classe Gazon est la classe présentant le moins de variation entre les secteurs, ce qui concorde avec la similarité des espaces gazonnés entourant les bâtiments. La classe Végétation rase, comprenant surtout la végétation typique de toundra, montre peu de variation de performance entre les secteurs.




FIGURE 11. Comparaison des performances de classification selon les secteurs d'intérêt.

Limites

- **Qualité des données satellitaires**

Bien que les satellites utilisés dans ce projet aient tous des résolutions natives similaires, la qualité de la donnée est très variable. Les données WorldView-2/3 et Pléiades-1B sont de très grande qualité. Les images issues de Kompsat-3 sont de qualité légèrement inférieure, mais n'ont pas d'impact sur la précision obtenue dans la classification (figure 12). Les images issues de Jilin-14 sont cependant de qualité très mauvaise, avec entre autres une définition des objets beaucoup moins nette qu'avec WorldView-2/3 et des aberrations chromatiques proches des bâtiments ou à l'interface de surfaces ayant des brillances nettement différentes, ce qui concorde avec les observations d'autres utilisateurs de ces données [9]. Les images Jilin-14 ont été très difficiles à photo-interpréter. Les classifications réalisées avec ces images montrent des performances nettement en dessous des autres satellites (figure 12). Pour ces raisons, l'utilisation de Jilin-14 n'est pas recommandée pour cette application.



FIGURE 12. Comparaison de la qualité des images satellitaires, à une résolution spatiale de 0,5 m.

• Bâtiments

Les principales limites observées pour la détection des bâtiments sont :

1. Quelques rares commissions de petites aires sur des roches ou du sol nu;
2. Des omissions pour les grandes surfaces comme les centres commerciaux;
3. Des omissions pour les petits bâtiments comme les cabanons et les poulaillers;
4. Quelques omissions pour les toits de forme ou de couleurs moins fréquentes, comme le rouge.

• Classification de combustibles forestiers

L'analyse de performance de la cartographie a fait ressortir certaines limites de l'algorithme. L'algorithme est très sévère sur l'identification de résineux, et tend vers la commission, ce qui a été un choix lors du développement de l'algorithme afin d'éviter l'omission de cette classe de combustible dangereux. Cependant, il a été remarqué qu'en conséquence la présence de feuillus est sous-estimée. Ce défaut est accentué par la faible présence de feuillus dans les secteurs d'intérêt, ce qui a limité le nombre de données d'entraînement. Ensuite, les cours d'eau étroits (de quelques mètres de large) ne sont généralement pas détectés étant donné la résolution spatiale utilisée de 0,5 m (figure 13). Une certaine confusion est présente entre les classes de végétation Basse, Arbustive et Feuillues, provenant d'une difficulté lors de la photo-interprétation à évaluer la hauteur de la végétation présente dans l'image. En effet, seul le secteur de Chibougamau dispose d'une couverture lidar permettant d'identifier ces éléments. La classe Milieu Humide, qui présente les plus faibles performances, est difficile à classifier dans le contexte nordique où les zones humides présentent une grande diversité végétale et hydrographique. Enfin, les différences de performances observées entre les secteurs suggèrent que l'algorithme actuel n'est pas prêt à être déployé à l'ensemble de la zone nordique et nécessite un développement supplémentaire pour être généralisable. De façon générale, la faible disponibilité de points de contrôle terrain ou de données plus précises que les images satellitaires (p. : drone) limite la certitude de certaines classes dans les données de référence.



FIGURE 13. Exemple de difficulté de détection (contour blanc) des cours d'eau étroits.

• Autres combustibles dangereux

Les coupes forestières avec la présence de débris et les plantations sont des combustibles forestiers d'intérêt, mais ont seulement été identifiées à proximité de Chibougamau ce qui n'était pas suffisant pour générer le volume de données de référence nécessaire à l'entraînement d'algorithmes. Ces classes ont donc été omises pour le moment.



Recommandations

Selon les limites actuelles identifiées dans la méthodologie, plusieurs recommandations peuvent être émises pour mener vers un outil de cartographie des combustibles forestiers généralisable.

1. Généralisation de l'algorithme:

Plusieurs ajouts de données sont nécessaires pour généraliser l'algorithme. L'exercice mené dans le cadre de ce projet pourrait être répété dans de nouveaux secteurs présentant des configurations non rencontrées jusqu'à présent, tel que secteurs avec des aménagements forestiers ou des infrastructures hydroélectriques par exemple. Cet ajout de données de référence est également nécessaire pour améliorer l'algorithme de détection de bâtiments, essentiel au calcul des produits finaux.

Le projet a permis d'identifier trois satellites pouvant être utilisés pour cartographier les combustibles forestiers. Afin d'augmenter les possibilités d'obtenir une image récente, l'ajout de satellites à THRS (tel que Kompsat-7 ou Pléiades Neo) devra être effectué. À noter cependant que toutes les images satellitaires nécessitent à ce jour des pré-traitements nécessitant des compétences avancées en imagerie. Des produits prétraités existent pour certains satellites, des tests devraient donc être effectués pour valider leur compatibilité avec la méthode développée.

L'absence de points de contrôle a souvent été relevée par les photo-interprètes lors de la création des données de référence. Ainsi, pour des développements futurs, une campagne de validation terrain des cartographies réalisées ainsi que des prises de point de contrôle dans des nouveaux secteurs devra être réalisée. Ces données permettront d'augmenter considérablement la confiance dans les données de référence.

2. Outil d'automatisation:

Les outils développés dans le cadre de ce projet sont à ce jour dans un format nécessitant une certaine expertise en géomatique, imagerie et apprentissage profond pour être appliqué. La mise en forme de ces outils dans une interface graphique simplifierait l'utilisation de ces outils et permettrait un transfert efficace de la méthodologie développée.

3. Zone intensive:

La zone intensive englobe le sud du Québec jusqu'au 52^{ème} parallèle approximativement. Les résultats obtenus à Chibougamau (inclus dans la zone intensive) montrent que l'algorithme actuel a un bon potentiel pour être appliqué dans un contexte de forêt boréale nordique. Cependant, les forêts plus au sud n'ont pas été incluses dans le développement. Compte tenu de la grande diversité présente plus au sud, des efforts considérables de développement seront nécessaires pour aboutir à un algorithme applicable à l'ensemble de la zone intensive d'intervention.



Références

[1]: L'intervention de la SOPFEU dans les différentes zones de protection.

<https://sopfeu.qc.ca/lintervention-de-la-sopfeu-dans-les-differentes-zones-de-protection/>

[2]: NASA Shuttle Radar Topography Mission (SRTM)(2013). Shuttle Radar Topography Mission (SRTM) Global. Distributed by OpenTopography.

<https://doi.org/10.5069/G9445JDF>

[3]: SpaceNet on Amazon Web Services (AWS). "Datasets." The SpaceNet Catalog.

<https://spacenet.ai/datasets/>

[4] Qiang Zuo, Songyu Chen, Zhifang Wang (2021) 2AU-Net: Attention Recurrent Residual Convolutional Neural Network for Multimodal Medical Image Segmentation, Secur. Commun. Networks.

[5] Feng X, Wang T, Yang X, Zhang M, Guo W, Wang W. ConvWin-UNet: UNet-like hierarchical vision Transformer combined with convolution for medical image segmentation. Math Biosci Eng. 2023 Jan;20(1):128-144.

<https://doi.org/10.3934/mbe.2023007>

[6] Chang-Bin Zhang, Peng-Tao Jiang, Qibin Hou, Yunchao Wei, Qi Han, Zhen Li and Ming-Ming Cheng (2021), Delving Deep Into Label Smoothing, {IEEE} Transactions on Image Processing, vol. 30, p. 5984-5996.

[7]: Intelli-Feu - Guide

https://sopfeu.qc.ca/wp-content/uploads/2023/08/Begins_at_Home_Guide-With_Self-Assessment-SOPFEU-Web_Version-FR.pdf

[8] : Beverly, J. L., Bothwell, P., Conner, J. C. R. et Herd, E. P. K. (2010) Assessing the exposure of the built environment to potential ignition sources generated from vegetative fuel. International Journal of Wildland Fire, vol. 19, n°3, p. 299.

[9] : Technical Note on Quality Assessment for Jilin-1 GF02

<https://earth.esa.int/eogateway/documents/20142/37627/Technical+Note+on+Quality+Assessment+for+Jilin-1+GF02.pdf/7a5b331c-b726-1d3a-7c78-d90e5f352e13>

cerfo

FORMATION
ACCOMPAGNEMENT
RECHERCHE
EN FORESTERIE

Tél. : (418) 659-4225

Courriel : info@cerfo.qc.ca

Communiquez avec notre équipe :

Batistin Bour, M. Sc.

bbour@cerfo.qc.ca

Marc-Antoine Genest, M. Sc.

magenest@cerfo.qc.ca

Martin Dupuis, M. Sc.

mdupuis@cerfo.qc.ca

Fiston Nininahazwe, M. Sc.

fnininahazwe@cerfo.qc.ca

Marc-Antoine Martineau, tech. geom.

mamartineau@cerfo.qc.ca

Clément Coutier, tech. for.

ccoutier@cerfo.qc.ca

Samuel Veilleux, M. Sc.

sveilleux@cerfo.qc.ca

Mathieu Varin, M. Sc.

mvarin@cerfo.qc.ca

