

Département de géomatique appliquée

Faculté des lettres et sciences humaines

Université de Sherbrooke

Étude de la formation de la glace de rivière à l'aide d'images optiques acquises par drone

Victoria Litalien

Essai présenté pour l'obtention du grade de Maître ès Sciences en Géomatique appliquée et  
télédétection, cheminement de type cours

Octobre 2023

© *Victoria Litalien, 2023*

## Composition du jury

Étude de la formation de la glace de rivière à l'aide d'images optiques acquises par drone

Victoria Litalien

Cet essai a été évalué par un jury composé des personnes suivantes :

Mélanie Trudel, directrice de recherche

(Département de génie civil et génie du bâtiment, Faculté de génie, Université de Sherbrooke)

Jérôme Théau, codirecteur de recherche

(Département de géomatique appliquée, Faculté des lettres et sciences humaines, Université de Sherbrooke)

Samuel Foucher, codirecteur de recherche

(Département de géomatique appliquée, Faculté des lettres et sciences humaines, Université de Sherbrooke)

Alexandre Langlois, évaluateur interne

(Département de géomatique appliquée, Faculté des lettres et sciences humaines, Université de Sherbrooke)

## Sommaire

Au Québec, la présence de glace de rivière est associée aux risques d'inondations hivernales et printanières. Avec la collaboration de plusieurs partenaires, le ministère des Affaires municipales et de l'Habitation (MAMH) a mandaté une équipe de l'Université de Sherbrooke pour caractériser les zones inondables causées par la présence de glace fluviale. À cet effet, des modèles hydrodynamiques de glace seront utilisés. Pour faire fonctionner ces modèles, une collecte de données est nécessaire afin de connaître les valeurs des paramètres d'entrée. Les données collectées sont aussi utiles pour effectuer la validation et la calibration des modèles. La concentration de frasil et l'étendue du couvert de glace sont notamment des données importantes à acquérir pour la modélisation de la glace de rivière. L'objectif du projet était de développer une méthode d'acquisition et de traitement d'images optiques de la glace fluviale acquises par drone afin de générer des données d'étendue et de concentration de glace fluviale utiles à la génération des paramètres d'entrées, au calage et à la validation des modèles hydrodynamiques de glace. Pour ce faire, des images ont été acquises sur les rivières Coaticook, Massawippi et Saint-François à l'hiver 2022-2023. À l'aide de ces images, un premier réseau de neurones convolutifs a été entraîné à segmenter celles-ci en trois classes : glace statique, eau et autres. Lors de la validation, le modèle a obtenu une valeur moyenne d'*Intersection over Union* (IoU) de 96%. Une inférence a également été effectuée sur une série temporelle du jeu de données de tests qui a permis d'obtenir des cartes de segmentation. En obtenant le nombre de pixels de chaque classe et la résolution de l'image, l'étendue de la glace statique a pu être calculée et comparée aux degrés-jours sous zéro. Par la suite, deux réseaux de neurones convolutifs ont été entraînés et comparés pour calculer la concentration de la glace en mouvement. Un réseau entraîné en segmentation sémantique a séparé les images en deux classes : glace en mouvement et eau. Lors de l'étape de la validation, l'IoU moyen s'est élevé à 82%. En obtenant le nombre de pixels de chaque classe, la concentration de glace en mouvement a été calculée. L'autre réseau a été entraîné en mode régression afin de produire une carte de concentration à partir de laquelle la concentration totale a pu être obtenue. Lors de l'étape de la validation, ce réseau a obtenu une distance L1 (différence entre la prédiction et la vraie mesure) de 2%. Cette approche semble donc plus fiable. Bien que ces résultats aient permis une caractérisation relativement précise du couvert de glace, l'inférence réalisée sur le jeu de données de test a permis d'identifier certaines limites de ces réseaux, comme le manque de certains éléments dans le jeu d'entraînement et la confusion entre certaines classes. Ces travaux fournissent une approche

opérationnelle pour la caractérisation du couvert de glace fluviale par imagerie drone. Des études ultérieures seront menées afin de corriger les limites rencontrées.

**Mots clés :** Glace de rivière, frasil, drone, réseaux de neurones convolutifs, modélisation hydrodynamique de glace

## **Remerciements**

Je souhaite remercier ma directrice d'essai, Mélanie Trudel, et mes codirecteurs, Jérôme Théau et Samuel Foucher. Leur mentorat et leur engagement m'ont permis de développer mes compétences et de réaliser ce projet. Merci pour vos commentaires constructifs et vos conseils! Je tiens également à remercier Jason Duguay et Mathieu Fouquet qui m'ont accompagné lors de l'acquisition des données et qui ont toujours montré un grand intérêt sur l'avancement de mes travaux. Je remercie également mon conjoint, ma famille et mes amis pour leurs encouragements au cours des derniers mois. Finalement, je remercie le ministère des Affaires municipales et de l'Habitation ainsi que le conseil de recherches en sciences naturelles et en génie pour leur soutien au projet.

## Table des matières

<b>Sommaire .....</b>	<b>iii</b>
<b>Remerciements .....</b>	<b>v</b>
<b>Liste des figures .....</b>	<b>viii</b>
<b>Liste des tableaux .....</b>	<b>xii</b>
<b>Liste des annexes .....</b>	<b>xiii</b>
<b>1 Introduction .....</b>	<b>1</b>
1.1 Mise en contexte.....	1
1.2 Problématique.....	1
1.3 Objectifs .....	3
<b>2 Cadre théorique.....</b>	<b>4</b>
2.1 Processus de formation de la glace fluviale et description des types de glace fluviale .....	4
2.1.1 Glace de rive.....	4
2.1.2 Frasil.....	5
2.1.3 Glace de fond .....	6
2.1.4 Aufeis .....	7
2.1.5 Glace thermique .....	7
2.1.6 Glace consolidée ou agglomérée.....	7
2.2 Plateformes et capteurs utilisés pour étudier la formation du couvert de glace fluviale.....	8
2.2.1 Plateformes et méthodes d’acquisition terrestres .....	10
2.2.2 Satellite.....	12
2.2.3 Drone.....	15
2.3 Méthodes de caractérisation de la glace fluviale.....	17
2.3.1 Classification de la glace fluviale.....	17
2.3.1.1 Les approches par méthodes de seuil .....	17
2.3.1.2 Les approches par machines à vecteurs de support.....	19
2.3.1.3 Les approches par réseaux de neurones profonds .....	21
2.3.2 Épaisseur de la glace fluviale .....	26
2.3.3 Évolution et étendue du couvert de glace.....	28

2.3.4	Vitesse de la glace fluviale.....	32
<b>3</b>	<b>Présentation des sites à l'étude.....</b>	<b>33</b>
<b>4</b>	<b>Matériel et méthode .....</b>	<b>36</b>
4.1	Acquisition des données.....	36
4.2	Préparation du modèle pour le calcul de l'étendue de la glace statique.....	39
4.2.1	Préparation et annotation des images .....	39
4.2.2	Entraînement du modèle.....	40
4.3	Préparation des modèles pour le calcul de la concentration de la glace en mouvement....	41
4.3.1	Préparation des imageries.....	42
4.3.2	Entraînement du modèle en mode segmentation sémantique .....	42
4.3.3	Entraînement du modèle en mode régression .....	43
4.4	Inférence.....	43
4.4.1	Quantification de l'étendue du couvert de glace.....	44
4.4.2	Concentration totale de la glace en mouvement.....	45
<b>5</b>	<b>Résultats .....</b>	<b>45</b>
5.1	Étendues du couvert de glace .....	45
5.2	Concentration totale de la glace en mouvement.....	51
<b>6</b>	<b>Interprétation et discussions des résultats .....</b>	<b>57</b>
6.1	Évaluation de l'atteinte des objectifs de l'essai .....	57
6.2	Évaluation des résultats et limites de l'essai .....	58
6.2.1	Évaluation de l'acquisition des données .....	58
6.2.2	Évaluation de l'annotation des images.....	60
6.2.3	Évaluation du calcul de l'étendue du couvert de glace .....	62
6.2.4	Évaluation du calcul de la concentration de la glace en mouvement.....	63
6.3	Recommandations et suite des travaux .....	65
<b>7</b>	<b>Conclusion.....</b>	<b>66</b>
	<b>Références .....</b>	<b>67</b>
	<b>Annexe 1 : Caractéristiques de la caméra du Mavic 3, DJI (tiré de DJI, s.d.) .....</b>	<b>72</b>
	<b>Annexe 2 : Listes des vidéos acquises sur les rivières à l'hiver 2022-2023.....</b>	<b>73</b>

## Liste des figures

<b>Figure 1</b> : Processus de formation du couvert de glace à partir du frasil (traduite de Lindenschmidt, 2020).....	5
<b>Figure 2</b> : Frasil (a) sous forme de <i>slush</i> et (b) sous forme de radeaux (photos prises par Victoria Litalien). .....	6
<b>Figure 3</b> : Glace de fond transportant des cailloux et des sédiments fins sur la rivière de la Paix en Alberta (tirée de Kalke <i>et al.</i> , 2015).....	6
<b>Figure 4</b> : (a) Mesure de l'épaisseur de la glace dans un trou foré. (b) Carotte de glace extraite présentant différentes couches de glace (modifiée de Lindenschmidt, 2020).....	10
<b>Figure 5</b> : Instruments d'acquisition terrestre. (a) Profileur de glace en eau peu profonde ( <i>Shallow River Ice Profiler</i> , SWIP) (tirée de Buermans <i>et al.</i> , 2011). (b) Radar à pénétration de sol ( <i>Ground Penetrating Radar</i> , GPR) (tirée de Fu <i>et al.</i> , 2018). (c) Courantomètre acoustique à effet Doppler ( <i>Acoustic Doppler Current Profilers</i> , ADCP) (tirée de Chave <i>et al.</i> , 2004). .....	11
<b>Figure 6</b> : Caméra avec intervallo-mètre pouvant être attachée (a) avec une vis ou (b) une sangle à un arbre. (c) Des batteries et une carte SD sont nécessaire au bon fonctionnement de l'appareil (tirée de Lindenschmidt, 2020). .....	12
<b>Figure 7</b> : Interaction des micro-ondes avec (A et B) un couvert de glace thermique et (C et D) un couvert de glace consolidée (traduite de Lindenschmidt, 2020).....	14
<b>Figure 8</b> : Drone (a) à voilure fixe, (b) à voilure rotative (modifiée de Ren <i>et al.</i> , 2019) et (c) à voilure fixe à décollage verticale (tirée de Okulski et Lawryńczuk, 2022). .....	16
<b>Figure 9</b> : Exemple d'histogramme bimodal où l'arrière-plan et les objets de l'image ont des valeurs de pixels pouvant être séparées par un seuil (T) (traduite de Rogowska, 2009).....	18
<b>Figure 10</b> : Exemple de composé coloré du RADARSAT-2 (a) en mode fin large (F0W3) et (b) en quadripolarisation standard large (SQ21W) utilisé pour la classification des types de glace (traduite de Das <i>et al.</i> , 2015).....	19
<b>Figure 11</b> : Fonctionnement des machines à vecteurs de support : (a) Deux classes (cercles noirs et blancs) et trois hyperplans potentiels, (b) L'hyperplan final (ligne noire) se trouve au milieu de la marge (zone entre les lignes pointillées). Les vecteurs de support (points encerclés) sont les objets les plus proches de l'hyperplan (tirée de Russell et Norvig, 2010). .....	20
<b>Figure 12</b> : (a) Perceptron multicouche ( <i>Multi-Layer Perceptron</i> ). La couche d'entrée est composée du jeu de données. Les couches cachées sont connectées par les canaux et rejoignent la	



couche de sortie où en ressort le résultat. (b) Architecture d'un réseau de neurones convolutif. Les neurones sont en trois dimensions, chaque couche reçoit et produit des informations 3D. La hauteur (ligne bleue) et la largeur (ligne rouge) des couches cachées correspondent aux dimensions de l'image d'entrée. La profondeur (ligne verte) correspond au nombre de filtres dans la couche convolutive (modifiée de Stanford University, s.d.). .....22

**Figure 13** : Paramètres nécessaires aux calculs de la profondeur de l'eau au-dessus du transducteur acoustique et de la distance entre la face inférieure du couvert de glace et la surface de l'eau (tirée de Buermans *et al.*, 2011).....28

**Figure 14** : Série temporelle prise par une caméra en rive permettant d'analyser la formation du couvert de glace (tirée de Lindenschmidt, 2020). .....29

**Figure 15** : Comparaison de (a) la vélocimétrie par analyse de séquences d'images à grande échelle (Large-Scale Particle Image Velocimetry, LSPIV) et de (b) la vélocimétrie de suivi de particules (Particle Tracking Velocimetry, PTV) (traduite de Jolley *et al.*, 2021).....33

**Figure 16** : Emplacement des sites d'acquisition des données sur les rivières Coaticook (C) et Massawippi (M). .....34

**Figure 17** : Emplacement du site d'acquisition des données sur la rivière Saint-François (SF)...35

**Figure 18** : Organigramme du projet. ....37

**Figure 19** : Matériel utilisé : (a) Deux cônes utilisés comme cibles, (b) un ruban à mesurer, (c) un drone Mavic 3, sa manette et son étui (photo prise par Victoria Litalien). .....38

**Figure 20** : Interface de *Segment.ai*. Les lignes blanches représentent les contours des *superpixels* générés par le logiciel. La taille des *superpixels* est ajustable avec l'outil (en haut à gauche). En cliquant sur un *superpixel*, il est alors possible d'indiquer la classe associée (polygone bleu). Des outils de type brosse et polygone sont aussi disponibles pour effectuer des ajustements.....40

**Figure 21** : Suivi des différentes métriques d'évaluation de l'entraînement du modèle sur le logiciel *Weights and Biase* : (a) l'*Intersection over Union* moyen et (b) la fonction de perte selon les époques. Les courbes de couleurs représentent chacune un entraînement différent. ....41

**Figure 22** : Traitements appliqués sur (a) une imagerie classifiée comme de l'eau par le premier modèle : (b) filtre Sobel de détection de contours et (c) méthode de seuil manuelle. ....42

**Figure 23** : Résultats de la segmentation sémantique effectuée par le modèle (inférence en imagerie multiples) superposés en transparence au jeu de données de test. Les images ont été acquises sur la rivière Coaticook au site C2 (a) le 10 janvier 2023, (b) le 11 janvier 2023, (c) le 12

janvier 2023 et le (d) 17 janvier 2023. Les zones jaunes ont été classifiées dans la catégorie autres, les zones turquoise ont été classifiées comme de la glace statique et les zones bleues ont été classifiées comme de l'eau libre (incluant la glace en mouvement). Les pixels noirs n'ont pas été classifiés par le modèle. Les zones encerclées en rouge indiquent des erreurs de classification...46

**Figure 24** : Cartes de scores des segmentations obtenues lors de l'inférence (imassettes multiples) des images acquises (jeu de données de test) sur la rivière Coaticook au site C2 (a) le 10 janvier 2023, (b) 11 janvier 2023, (c) 12 janvier 2023 et (d) 17 janvier 2023. Les zones encerclées en noir indiquent l'emplacement d'arbre ou d'ombre projetée par un arbre.....47

**Figure 25** : Comparaison de l'évolution de l'étendue du couvert de glace entre le 10 et 17 janvier 2023 au site C1 avec les degrés-jours sous zéros cumulés. ....48

**Figure 26** : Résultats de la segmentation effectuée par le modèle (inférence en imassettes multiples) superposés en transparence au jeu de données de test. Les images ont été acquises (a) sur la rivière Massawippi au site M3 le 1<sup>er</sup> février 2023 et (b) sur la rivière Saint-François au site SF1 le 31 janvier 2023. Les zones jaunes ont été classifiées dans la catégorie autres, les zones turquoise ont été classifiées comme de la glace statique et les zones bleues ont été classifiées comme de l'eau libre (incluant la glace en mouvement). Les pixels noirs n'ont pas été classifiés par le modèle. Les zones encerclées en rouge indiquent des erreurs de classification. Cartes de scores (c) du résultat de la rivière Massawippi et (d) du résultat de la rivière Saint-François.....49

**Figure 27** : Résultats de la segmentation effectuée par le modèle (inférence en imassettes multiples) superposés en transparence à une orthomosaïque acquise sur la rivière Coaticook (C2) dans le cadre d'un autre projet. Les zones jaunes ont été classifiées dans la catégorie autres, les zones turquoise ont été classifiées comme de la glace statique et les zones bleues ont été classifiées comme de l'eau libre (incluant la glace en mouvement). Les pixels noirs n'ont pas été classifiés par le modèle. Les cercles rouges identifient les erreurs de classification importantes. ....51

**Figure 28** : Segmentation sémantique (inférence en imassettes multiples) pour le calcul de la concentration de la glace en mouvement de la série temporelle (jeu de données de test) acquise sur la rivière Coaticook (site C2) (a) le 10 janvier 2023, (b) 11 janvier 2023, (c) le 12 janvier 2023 et (d) le 17 janvier 2023. Les pixels classifiés comme de l'eau sont en bleu et les pixels classifiés comme de la glace en mouvement sont en rouge. Les zones encerclées en blanc indiquent les arbres surplombant la rivière ou les ombres créées par ceux-ci ayant été classifiées comme de la glace en mouvement. ....52

**Figure 29** : Segmentation sémantique (inférence en imagerie multiples) pour le calcul de la concentration de la glace en mouvement sur un jeu de données de test. (a) Image acquise sur la rivière Massawippi (site M3) et (b) image acquise sur la rivière Saint-François (site SF1). Les pixels classifiés comme de l'eau sont en bleu et les pixels classifiés comme de la glace en mouvement sont en rouge. ....53

**Figure 30** : Cartes de concentration (inférence en imagerie multiples) des différentes images (jeu de données de test) acquises sur les trois rivières à l'étude. Cartes de concentration de la rivière Coaticook (site C2) (a) le 10 janvier 2023, (b) 11 janvier 2023, (c) le 12 janvier 2023 et (d) le 17 janvier 2023. (d) Carte de concentration de la rivière Massawippi (site M3) le 1<sup>er</sup> février 2023. (e) Carte de concentration de la rivière Saint-François (site SF1) le 31 janvier 2023. Les zones encerclées en gris indiquent les endroits où il y a un arbre ou une ombre créée par un arbre. ....55

**Figure 31** : Comparaison d'une (a) image utilisée pour l'entraînement des modèles dans le cadre de l'étude de Singh *et al.* (2020) représentant majoritairement du frazil sous forme de radeaux et (b) d'une image utilisée pour l'entraînement des modèles dans le cadre de l'essai représentant majoritairement du frazil sous forme de *slush*. ....59

**Figure 32** : Confluence de la rivière Coaticook et de la rivière Massawippi. Le frazil provenant de la rivière Coaticook se déverse dans la rivière Massawippi. Aucun frazil ne provient de celle-ci (photo prise par Victoria Litalien)..... 60

## Liste des tableaux

<b>Tableau 1</b> : Processus de formation et types de glace formée selon la vitesse d'écoulement (inspiré de Lindenschmidt, 2020).....	8
<b>Tableau 2</b> : Présentation des études consultées portant sur la segmentation de la glace de rivière à l'aide de réseaux de neurones convolutifs ( <i>Convolutional Neural Network</i> , CNN).....	23
<b>Tableau 3</b> : Capteurs, bandes spectrales et longueurs d'onde utilisés par Li <i>et al.</i> (2020) pour calculer le NDSI ( <i>Normalized Difference Snow Index</i> ) et par Li <i>et al.</i> (2021) pour calculer le RDRI ( <i>Relative Difference River Ice</i> ).....	30
<b>Tableau 4</b> : Vidéos acquises lors de la campagne terrain.....	38
<b>Tableau 5</b> : Vidéos sélectionnées pour l'extraction d'images.....	39
<b>Tableau 6</b> : Nombre de pixels par classes et résultats du calcul de l'étendue du couvert de glace selon l'image de la série temporelle acquise sur la rivière Coaticook au site C2. ....	48
<b>Tableau 7</b> : Nombre de pixels par classes et résultats du calcul de l'étendue du couvert de glace pour l'image acquise sur la rivière Massawippi au site M3 et l'image acquise sur la rivière Saint-François au site SF1. ....	50
<b>Tableau 8</b> : Superficie (m <sup>2</sup> ) par classes selon l'image inférée. ....	54
<b>Tableau 9</b> : Concentrations de glace en mouvement obtenues selon la méthode de régression et la méthode de segmentation. ....	56
<b>Tableau 10</b> : Comparaison des concentrations avec les températures minimales précédant l'acquisition des données et avec les températures au moment de l'acquisition. ....	56

## **Liste des annexes**

<b>Annexe 1</b> : Caractéristiques de la caméra du Mavic 3, DJI (tiré de DJI, s.d.).....	72
<b>Annexe 2</b> : Listes des vidéos acquises sur les rivières à l’hiver 2022-2023 .....	73

# **1 Introduction**

## **1.1 Mise en contexte**

Dans l'hémisphère nord, le comportement des cours d'eau est influencé par l'hiver et ses températures froides (Hicks et Beltaos, 2008). La glace fluviale, les processus de formation et de débâcle (rupture du couvert de glace) qui y sont liés ont, entre autres, des impacts sur l'écologie (Thellman *et al.*, 2021) et sur la morphologie des rivières (Kalke *et al.*, 2015). En effet, la glace fluviale peut être, par exemple, à l'origine de l'érosion des rives et d'un déplacement de sédiments (Kalke *et al.*, 2015). De plus, en modifiant les caractéristiques physiques de l'environnement, telles que le débit, la lumière et la température, la glace de rivière a un impact sur plusieurs aspects écologiques importants relatifs à la qualité des habitats pour les différentes espèces (Thellman *et al.*, 2021). La présence de glace de rivière est aussi associée aux risques d'inondations hivernales et printanières.

Les inondations causées par la glace fluviale sont généralement plus dévastatrices que les inondations en eau libre, notamment à cause de la présence d'embâcles de glace. Les embâcles de glace sont des amas de glace flottante obstruant le cours d'eau. Ils peuvent se produire lors de la formation du couvert de glace, lors de redoux hivernaux ou lors de la débâcle au printemps. Les embâcles génèrent des niveaux d'eau plus élevés qu'un niveau d'eau habituel. Les blocs et les plaques de glace transportées par le courant augmentent également les risques pour les infrastructures et les personnes (Lindenschmidt, 2020). Les inondations causées par la présence de la glace de rivière peuvent nécessiter des évacuations et des relocalisations de certaines communautés. Il est estimé que les inondations par embâcles coûtent environ cent millions de dollars annuellement au Canada (Committee on River Ice Processes and the Environment, 2023). Bien que les processus de la glace fluviale ont des répercussions sur la sécurité et l'économie, peu d'études se penchent sur ceux-ci et beaucoup de travail reste à faire pour bien les comprendre (Committee on River Ice Processes and the Environment, 2023).

## **1.2 Problématique**

Ce présent essai s'inscrit dans un projet de plus grande envergure financé par le ministère des Affaires municipales et de l'Habitation (MAMH) ainsi qu'un projet du programme Alliance du conseil de recherches en sciences naturelles et en génie (CRSNG-Alliance). Plusieurs partenaires sont inclus dans le projet en plus du MAMH dont la municipalité régionale de comté (MRC) du

Haut-Saint-François, la MRC de Coaticook et la Ville de Sherbrooke. L'objectif du projet est de caractériser les zones inondables causées par la présence de glace afin de mieux s'organiser face à ces événements coûteux et dangereux. Pour ce faire, des modèles hydrodynamiques de glace seront utilisés. Pour faire fonctionner ces modèles, une collecte de données est nécessaire afin de connaître les valeurs des paramètres d'entrées, tels que l'épaisseur de la glace et le volume de glace entrant. Les méthodes d'acquisition et de traitement des données nécessaires aux fonctionnements des modèles sont en développement et leurs applications présentent plusieurs défis.

L'étude de la glace de rivière comprend des enjeux de sécurité. En effet, lors de la prise de données *in situ*, il est généralement nécessaire d'embarquer sur le couvert de glace. En cas d'une fracture de ce dernier, une chute dans l'eau glacée peut survenir. L'acquisition de données *in situ* est également coûteuse en temps et est logistiquement complexe, spécialement lorsqu'elle se produit dans des zones éloignées avec des conditions météorologiques difficiles. Des méthodes de télédétection sont donc préférables, même si elles ne sont pas parfaites. Les satellites, les caméras en rive et les drones en sont des exemples, ayant chacun des avantages et des inconvénients. La plupart des données satellitaires possèdent généralement des résolutions spatiales de plusieurs mètres, ce qui n'est pas assez précis pour l'étude des petites rivières. Dans ces cas, des données ayant des résolutions spatiales de l'ordre du centimètre sont nécessaires. Les données satellitaires ont aussi des lacunes au niveau de la résolution temporelle puisque des données ne sont pas nécessairement acquises tous les jours aux sites à l'étude (Simoes et Clark, 2020). De leur côté, les caméras en rive permettent d'obtenir des résolutions spatiales et temporelles plus élevées que les satellites, mais sur une zone plus restreinte. Ces caméras ont également une prise de vue latérale de la rivière ce qui génère des images avec d'importantes distorsions. Pour leur part, les drones permettent aussi de produire des données à très haute résolution spatiale (ordre du centimètre) et temporelle. Selon la méthode d'acquisition employée, il est également possible de produire des données sans distorsions importantes couvrant une plus grande section de rivière que la caméra en rive. L'utilisation de drones pour l'étude de la glace semble donc une avenue intéressante même si elle est peu documentée dans ce cas précis (Alfredsen *et al.*, 2018; Lin *et al.*, 2012).

La génération des concentrations ou d'étendues des différents types de glaces (données utiles à la modélisation) représente plusieurs défis, entre autres puisque la glace varie temporellement et spatialement. De plus, la classification des types de glace est complexe puisqu'il existe de fortes

variations à l'intérieur d'une même classe et que les classes partagent plusieurs similarités entre elles (Singh *et al.*, 2020). Les méthodes de segmentation d'image classique ne génèrent pas de résultats satisfaisants en plus d'être subjectives et de demander un travail considérable. Quant à elle, la méthode de machine à vecteurs de support (SVM) permet de fournir une classification binaire (eau/glace), mais n'arrive pas à différencier correctement les différents types de glace (Kalke et Loewen, 2018). Des études récentes démontrent que l'utilisation de réseaux de neurones profonds semble fournir des résultats prometteurs (Ansari *et al.*, 2020; Singh *et al.*, 2020; Sola, 2022; Zhang *et al.*, 2021), bien que la méthode reste à être généralisée. En effet, la méthode n'a été appliquée que sur quelques rivières assez larges (plus d'une centaine de mètres) et quelques dates. L'utilisation d'un réseau de neurones profond comporte tout de même encore des difficultés. Peu de jeux de données d'entraînement annotés sont disponibles. La technique d'annotation des images utilisée dans le cadre des différentes études, soit la segmentation sémantique, est également difficile à appliquer puisque la distinction visuelle entre les types de glace et la délimitation des frontières des objets ne sont pas toujours évidentes (Ansari *et al.*, 2021; Singh *et al.*, 2020; Zhang *et al.*, 2020, 2021). L'exploration d'autres techniques d'annotation serait intéressante. Finalement, à la connaissance des auteurs, aucun réseau de neurones disponible ne répond aux besoins du projet actuel. En effet, les différentes conditions des sites à l'étude (largeur des rivières, caractéristiques des types de glace) ne concordent pas avec celles des études menées antérieurement. Dans le cadre du projet, une méthode d'acquisition et de traitement doit être développée afin d'obtenir les données souhaitées et de pouvoir éventuellement les utiliser pour déterminer les paramètres d'entrées, de faire la validation et de faire le calage des modèles hydrodynamique de glace.

### **1.3 Objectifs**

L'objectif principal de l'essai est de développer une méthode d'acquisition et de traitement d'images optiques de la glace fluviale acquises par drone afin de générer des données d'étendue et de concentration de glace fluviale utiles à la génération des paramètres d'entrées, au calage et à la validation des modèles hydrodynamiques de glace. Les objectifs secondaires sont les suivants :

1. Déterminer les conditions et la méthode optimales d'acquisition des images à l'aide d'un capteur optique monté sur un drone permettant d'obtenir les données d'étendue et de concentration de la glace fluviale ;



2. Développer une méthode de traitement des images afin d'obtenir une étendue de glace statique et une concentration de la glace en mouvement ;
3. Quantifier l'étendue du couvert de glace de la rivière et la concentration de la glace en mouvement à partir des images acquises par drone.

À la suite de cet essai, les méthodes et les données générées pourront être utilisées dans le cadre de la modélisation de la glace de rivière.

## **2 Cadre théorique**

Pour modéliser la glace de rivière, il est important de comprendre les processus de formation de celle-ci et ses différents types. Ces thèmes sont abordés dans la section 2.1 . Ensuite, les méthodes d'acquisition des données nécessaires pour ce sujet d'étude sont présentées à la section 2.2. Les méthodes de traitements des données pour l'obtention des différents paramètres sont décrites à section 2.3.

### **2.1 Processus de formation de la glace fluviale et description des types de glace fluviale**


Il existe quatre processus de formation de la glace fluviale, soit la formation de la glace de rive, du frazil, de la glace de fond et d'*aufeis*. Ces quatre processus sont responsables du développement du couvert de glace. Celui-ci peut être divisé en deux catégories : la glace thermique et la glace consolidée ou agglomérée.

#### **2.1.1 Glace de rive**


Lorsque la température de surface de l'eau atteint 0°C et que la température de l'air est située en dessous du point de congélation, une fine couche de glace transparente peut se former sur les rivières. Cette couche se forme dans des secteurs à faible vitesse, tels que près des berges. La faible turbulence de ces zones permet à la glace de rester sur place et de ne pas être emportée plus en aval. Avec le refroidissement, cette mince couche de glace s'épaissit et devient de la glace de rive. La glace de rive peut aussi se développer à partir d'une accumulation de frazil (décrit à la section 2.1.2). Au cours de l'hiver, la glace de rive des deux berges peut s'étendre vers le centre de la rivière jusqu'à se rejoindre. Celle-ci peut également se détacher des berges, produisant des radeaux de glace. Les radeaux sont transportés vers l'aval et peuvent éventuellement s'adhérer à d'autre couvert de glace ou rester coincés entre des îles et la berge de la rivière (Lindenschmidt, 2020).

### 2.1.2 Frasil

Le frasil est un des principaux processus de formation de glace fluviale. Il se forme lorsque la température de l'eau se situe entre 0 et -0,5 °C et qu'une certaine turbulence est présente (Figure 1). Ces conditions permettent la formation de cristaux de glace assez petits pour rester en suspension dans l'eau. Les cristaux, naturellement adhésifs, se regroupent pour former des flocons. Puisque ceux-ci possèdent une meilleure flottabilité que les cristaux individuels, ils remontent à la surface sous forme de neige fondue (communément appelé *slush*). Lorsque la *slush* est soumise à des températures sous le point de congélation, elle forme des radeaux de glace (Figure 1 et Figure 2) (Singh *et al.*, 2020). Ces petits radeaux peuvent s'adhérer les uns aux autres pour former des radeaux de plus grande taille. Puisque les radeaux se heurtent régulièrement les uns aux autres, ceux-ci ont généralement des formes circulaires (Lindenschmidt, 2020).



**Figure 1 :** Processus de formation du couvert de glace à partir du frasil (traduite de Lindenschmidt, 2020). Éventuellement, les radeaux de glace (de frasil ou de glace de rive) rencontrent des obstacles, tels qu'un rétrécissement de la rivière, une île ou un couvert de glace déjà formé. Ces obstacles forcent les radeaux à rester et à geler sur place, ce qui permet au couvert de glace de se développer. De plus, lorsque la densité des radeaux est élevée, l'eau située entre les différents types de glace peut geler et ainsi former un couvert de glace (Lindenschmidt, 2020).



**Figure 2 :** Frazil (a) sous forme de *slush* et (b) sous forme de radeaux (photos prises par Victoria Litalien).

### 2.1.3 *Glace de fond*

Comme illustré à la Figure 1, des cristaux et des flocons de frazil peuvent descendre jusqu'au fond de la rivière si la turbulence est assez élevée. Les cristaux et les flocons peuvent alors adhérer au lit de la rivière, particulièrement aux lits constitués de gravier ou de cailloux. Ce type de glace nécessite des froids extrêmes pour se former, ce qui survient donc généralement la nuit. Au matin, lorsque la radiation solaire pénètre et réchauffe le lit de la rivière, la glace de fond peut se détacher et remonter à la surface (Lindenschmidt, 2020). La glace de fond peut également se détacher mécaniquement lorsque la force de flottaison exercée sur la glace de fond est supérieure à la force d'adhésion du lit (Kalke *et al.*, 2015). En se détachant, la glace de fond transporte des sédiments du lit de la rivière et les dépose sur le dessous du couvert de glace. Ce type de glace joue un rôle important dans les processus de transport des sédiments fluviaux puisqu'il a la capacité d'envelopper facilement des particules de sédiments de grandes tailles (Kempema et Ettema, 2011) comme on peut le voir à la Figure 3.



**Figure 3 :** Glace de fond transportant des cailloux et des sédiments fins sur la rivière de la Paix en Alberta (tirée de Kalke *et al.*, 2015).

#### **2.1.4 Aufeis**

*Aufeis* est un mot allemand qui se traduit par l'expression « sur glace ». Un *aufeis* est donc littéralement de la glace se formant sur le dessus de la glace existante (Figure 1). Ce phénomène se produit lorsque de l'eau s'écoule sur le couvert de glace déjà formé. L'eau gèle et épaissit ce dernier (Lindenschmidt, 2020). L'écoulement de l'eau provient généralement des fissures du couvert de glace. Puisque l'épaisseur de la glace de fond et de la glace de surface augmente au cours de l'hiver, l'espace disponible pour l'écoulement de l'eau se réduit. La pression qui en résulte peut forcer l'eau à s'écouler par les fissures (Turcotte *et al.*, 2017). L'écoulement de l'eau peut également provenir d'autres sources, tel que l'exfiltration de l'eau souterraine. Les *aufeis* peuvent aussi se former sur la glace de fond (Lindenschmidt, 2020).

#### **2.1.5 Glace thermique**

La glace thermique est un des deux types de glace fluviale. Elle se forme lorsque la glace de rive s'épaissit grâce aux températures froides. Elle est composée de glace colonnaire, c'est-à-dire, de cristaux allongés verticaux. Les cristaux possèdent cette forme puisque la chaleur de la rivière quitte celle-ci en direction de l'atmosphère. Ces cristaux particuliers rendent la glace thermique lisse et transparente, bien qu'elle nous apparaisse noire à cause de l'absence de diffusion de la lumière vers la surface. Ce type de glace se forme lorsque les vitesses d'écoulement sont faibles (Tableau 1) (Lindenschmidt, 2020). Au début de l'hiver, la glace thermique est plus résistante que la glace consolidée (discutée à la section 2.1.6). Cependant, la glace thermique absorbe plus d'énergie solaire et donc se détériore plus rapidement lors d'un redoux (Lindenschmidt, 2020).

#### **2.1.6 Glace consolidée ou agglomérée**

La glace consolidée est le second type de glace fluviale. Elle est rugueuse et blanche. Elle se forme habituellement lorsque les vitesses d'écoulement se situent entre 0,4 et 0,7 m/s (Tableau 1). Ces vitesses sont idéales pour la formation de frasil. Puisque les cristaux de frasil ne se forment pas dans une seule direction, contrairement à la glace colonnaire, la lumière est diffusée vers la surface. Sous ces conditions, certains morceaux de glace peuvent être submergés et passer en dessous du couvert de glace. Ces morceaux s'attachent au-dessous du couvert de glace causant l'épaississement de ce dernier. La *slush* ou les radeaux de frasil peuvent aussi aller se juxtaposer (Figure 1) à un couvert de glace existant. Les vitesses d'écoulement plus rapides (entre 0,7 et 1,5 m/s) entraînent et bousculent les morceaux de glace sur le front de glace (amont du couvert de

glace). Les morceaux de glace s'entassent alors sur le front créant une texture rugueuse (Lindenschmidt, 2020).

**Tableau 1** : Processus de formation et types de glace formée selon la vitesse d'écoulement (inspiré de Lindenschmidt, 2020).

Vitesses d'écoulement (m/s)	Processus de formation	Types de glace formée
<0,4	Glace de rive	Glace thermique
0,4-0,7	Frasil	Glace consolidée ou agglomérée
0,7-1,5	Accumulation de glace bousculée sur le front de glace	Glace consolidée ou agglomérée
>1,5	Aucun	Eau libre persistant tout l'hiver

## 2.2 Plateformes et capteurs utilisés pour étudier la formation du couvert de glace fluviale

Plusieurs modèles numériques existent afin d'étudier la glace fluviale, dont des modèles unidimensionnels et bidimensionnels. Les trois modèles unidimensionnels les plus utilisés sont HEC-RAS (US Army Corps of Engineers, s.d.), River1D (River Ice Research Group, 2023) et RIVICE (Lindenschmidt, 2017). Seulement deux modèles bidimensionnels sont présentement accessibles pour les chercheurs, soient CRISSP2D et KHIONE. CRISSP2D appartient à Manitoba Hydro et KHIONE appartient à Telemac-Mascaret. Ces modèles nécessitent certains paramètres d'entrées pour réaliser la modélisation. En effet, plusieurs paramètres sont importants lors de l'étude et la modélisation de la glace de rivière, dont la concentration de la glace en mouvement, l'épaisseur du couvert de glace, la vitesse de la glace et l'étendue du couvert de glace.

La concentration de glace est généralement exprimée en pourcentage, en fonction de la surface occupée par la glace par rapport à la surface de la rivière (Zhang *et al.*, 2021). Il s'agit d'un des facteurs les plus importants pour prédire les processus de formation des couverts de glace (Zhang *et al.*, 2021). C'est particulièrement le cas pour la concentration de frasil qui contribue de manière significative au développement de ceux-ci. Cette mesure permet également de valider les taux de croissance générés par les modèles hydrodynamiques. De plus, le volume de la glace de rivière en mouvement par unité de temps ( $m^3/s$ ) est nécessaire à la modélisation des processus de formation du couvert de glace (Duguay *et al.*, 2023). Évaluer la concentration de glace est une première étape vers l'obtention de ce paramètre.

L'épaisseur du couvert de glace fluviale est également importante à suivre afin de prédire l'épaisseur maximale atteinte à la fin de l'hiver (Lindenschmidt, 2020). L'épaisseur du couvert de glace peut être formée de plusieurs couches de type de glace donnant des informations sur les

différents épisodes de gel. Le long d'un couvert de glace, l'épaisseur peut être très hétérogène. Plusieurs mesures à intervalle régulier sont donc nécessaires pour bien caractériser ce paramètre (Lindenschmidt, 2020). L'épaisseur du couvert de glace est aussi un paramètre d'entrée des modèles hydrodynamiques (Duguay *et al.*, 2023).

Pour sa part, la vitesse de la glace donne un bon aperçu de l'hydrodynamique d'une rivière et est une donnée pertinente pour le calage et la validation des modèles hydrodynamiques (Daigle *et al.*, 2013). La vitesse de la glace peut aussi aider à comprendre les processus de formation des embâcles. C'est également une variable importante à obtenir rapidement lors d'inondations hivernales afin d'évaluer les impacts potentiels de celles-ci (Wang *et al.*, 2022). La vitesse de la glace est généralement exprimée en m/s.


Finalement, l'évolution de l'étendue du couvert de glace est également un paramètre important pour le calage et la validation des modèles hydrodynamiques. Par exemple, la limite de l'eau libre est un paramètre d'entrée pour plusieurs modèles (Duguay *et al.*, 2023). L'étendue du couvert de glace peut-être exprimé en km<sup>2</sup> ou en m<sup>2</sup> selon l'importance de la rivière (Ansari *et al.*, 2017; Li *et al.*, 2020). Elle peut aussi être exprimée en pourcentage, selon la surface occupée par la glace par rapport à la surface de la rivière. L'évolution du couvert de glace peut être étudiée à l'aide de la position du front de glace. À l'aide de cette information et d'une analyse temporelle, la vitesse de croissance et de la récession de la glace peut être calculée (Ansari *et al.*, 2017). Des analyses temporelles suivant l'évolution du couvert de glace permettent également de cibler les périodes propices aux débâcles et aux embâcles (Beaton *et al.*, 2019).

Pour faire le suivi de ces paramètres, des plateformes et des capteurs sont nécessaires. Généralement, les méthodes de collecte des données sur la glace de rivière nécessitent de s'aventurer sur le couvert de glace. Il s'agit d'une pratique dangereuse qui demande une bonne planification et des règles de sécurité appropriées (Andrishak et Hicks, 2015). Les mesures *in situ* demandent beaucoup de temps, particulièrement lorsqu'un long tronçon de rivière doit être caractérisé. De plus, les mesures doivent parfois être effectuées dans des régions éloignées avec des conditions météorologiques difficiles. Les divers plateformes et capteurs de télédétection permettent d'éviter certains de ces problèmes bien qu'elles possèdent également des limites. Le fonctionnement des différents capteurs et plateformes est abordé dans cette section.

### 2.2.1 Plateformes et méthodes d'acquisition terrestres

Plusieurs plateformes et méthodes d'acquisition terrestres permettent de collecter des données sur la glace de rivières : le forage, le profileur de glace en eau peu profonde (*Shallow River Ice Profiler*, SWIP), le radar à pénétration de sol (*Ground Penetrating Radar*, GPR), le courantomètre acoustique à effet Doppler (*Acoustic Doppler Current Profilers*, ADCP) et la caméra en rives.

Le forage est une méthode d'acquisition terrestre qui permet de mesurer directement l'épaisseur du couvert de glace. Une équipe doit se rendre sur celui-ci et forer un trou à l'aide d'une tarière. L'épaisseur peut par la suite être mesurée à l'aide d'un bâton de mesure muni d'une équerre à angle droit à son extrémité (Figure 4). Différentes mesures peuvent être effectuées tout au long du trou afin d'évaluer l'épaisseur des différentes couches de glace présentes. Ces informations permettent de comprendre comment le couvert de glace s'est formé et d'évaluer sa solidité. Les carottes de glaces extraites par la tarière peuvent aussi fournir des informations intéressantes sur les processus de formation du couvert de glace (Lindenschmidt, 2020).



**Figure 4 :** (a) Mesure de l'épaisseur de la glace dans un trou foré. (b) Carotte de glace extraite présentant différentes couches de glace (modifiée de Lindenschmidt, 2020).

L'épaisseur du couvert de glace fluviale peut aussi être mesurée avec un SWIP, un sonar submersible (Figure 5). Le SWIP peut également mesurer la concentration de frasil en suspension. Cet instrument doit être installé au fond de la rivière par une équipe de plongeurs afin qu'il soit bien orienté vers le haut et fixé au lit. Une colonne d'eau d'une profondeur minimale de 0,5 m et maximale de 20 m est également nécessaire à son bon fonctionnement. Le SWIP émet des impulsions acoustiques vers la surface. Ces impulsions sont réfléchies par les différents éléments présents dans la colonne d'eau et sont retournées vers le SWIP. Un transducteur installé sur



l'instrument calcule le laps de temps entre le départ et le retour de l'impulsion. À partir de cette mesure et d'une estimation de la vitesse du son selon la température de l'eau, la distance entre le SWIP et les éléments de la colonne d'eau peut être calculée. Le SWIP est muni d'un mode cible et d'un mode profilage. Le mode cible est utilisé pour calculer l'épaisseur de la glace. À l'aide de ce mode et d'un algorithme, le SWIP est capable de déterminer si le signal reçu provient d'un couvert de glace ou de l'interface air-eau et ainsi mesurer l'épaisseur du couvert de glace. Le mode profilage est utilisé pour détecter la présence de frasil sous forme de cristaux ou de *slush* et pour étudier la composition du couvert de glace (Buermans *et al.*, 2011).

Le GPR est un autre instrument permettant d'obtenir une mesure de l'épaisseur du couvert de glace (Figure 5). Il est traditionnellement directement déposé sur la glace. Lorsque l'instrument est déposé sur la glace, il est tiré par des humains ou des véhicules sur la distance désirée. Le radar est équipé d'une antenne émettant des ondes électromagnétiques à impulsion courte et à haute fréquence vers la glace. Les ondes sont réfléchies par les différentes couches et sont retournées à l'antenne de réception de l'instrument. Tout comme dans le cas du SWIP, le temps du parcours des ondes est utilisé pour calculer l'épaisseur de la glace (Fu *et al.*, 2018).


Les ADCP sont généralement utilisés pour mesurer le débit des rivières. Ils peuvent être fixes ou mobiles. Chave *et al.* (2004) ont utilisé un ADCP fixe submergé pour suivre la vitesse des plaques de glace du fleuve Saint-Laurent (Figure 5). Ce type d'instrument utilise l'effet Doppler pour calculer la vitesse des particules présente dans l'eau. En d'autres mots, l'instrument émet des impulsions sonores et utilise la modification dans la fréquence des retours pour mesurer la vitesse des plaques de glace.



**Figure 5 :** Instruments d'acquisition terrestre. (a) Profileur de glace en eau peu profonde (*Shallow River Ice Profiler*, SWIP) (tirée de Buermans *et al.*, 2011). (b) Radar à pénétration de sol (*Ground Penetrating Radar*, GPR) (tirée de Fu *et al.*, 2018). (c) Courantomètre acoustique à effet Doppler (*Acoustic Doppler Current Profilers*, ADCP) (tirée de Chave *et al.*, 2004).



Quelques chercheurs ont utilisé des caméras en rives optiques (Figure 6) pour étudier la formation de la glace de rivière (Ansari *et al.*, 2017; Bourgault, 2008; Jedrzychowski et Kujawski, 2014; Simoes et Clark, 2020). Il s'agit du même type de caméra utilisée pour la chasse ou les inventaires fauniques. Ces caméras, attachées à un arbre ou un poteau sur le bord de la rive, permettent d'acquérir une série de données temporelle grâce à leur intervallo-mètre. Cette option permet de prendre automatiquement une image à des intervalles de temps prédéfinis par l'utilisateur. De plus, leur utilisation est facile et non dispendieuse (Bourgault, 2008). Par contre, leur installation peut être limitée par certaines contraintes géographiques. L'utilisation des images peut aussi représenter des défis à cause des mouvements de la caméra dus au vent et des conditions d'éclairage (Ansari *et al.*, 2017). Un autre élément contraignant est la prise de vue oblique des caméras qui génèrent des images avec d'importantes distorsions. Une géorectification de celles-ci est nécessaire pour la production de résultats quantitatifs (Ansari *et al.*, 2017; Bourgault, 2008; Simoes et Clark, 2020).



**Figure 6** : Caméra avec intervallo-mètre pouvant être attachée (a) avec une vis ou (b) une sangle à un arbre. (c) Des batteries et une carte SD sont nécessaire au bon fonctionnement de l'appareil (tirée de Lindenschmidt, 2020).

### 2.2.2 Satellite


Pour l'étude de la glace fluviale, deux types de capteurs à bord de satellites sont utilisés : les capteurs multispectraux et les radars à synthèse d'ouverture (RSO). Les capteurs multispectraux possèdent un fonctionnement semblable à celui d'un appareil photographique traditionnel. Les bandes multispectrales du capteur enregistrent des informations sur la réflectance (rayonnement

réfléchi) de la Terre dans le visible, le proche et le moyen infrarouge. Il s'agit de capteurs passifs qui n'émettent pas leur propre source d'énergie. Par exemple, les images produites par les satellites Landsat (Li *et al.*, 2020, 2021), MODIS (*Moderate Resolution Imaging Spectroradiometer*) (Beaton *et al.*, 2019; Chaouch *et al.*, 2014; Kraatz *et al.*, 2016) et la constellation Sentinel-2 (Altena et Kääh, 2021; Li *et al.*, 2021) sont utilisées pour l'étude de la glace de rivière. À partir de ces images, des informations concernant l'évolution et l'entendue du couvert de glace fluviale (Beaton *et al.*, 2019; Chaouch *et al.*, 2014; Kraatz *et al.*, 2016; Li *et al.*, 2020, 2021) (section 2.3.3) et de la vitesse de la glace fluviale (Altena et Kääh, 2021) (section 2.3.4) peuvent être calculées. Les images issues de ces satellites sont utilisées pour les rivières d'envergure. Par exemple, les largeurs moyennes des tronçons de rivières étudiées par Beaton *et al.* (2019) varient de 208 m à plus de 2 km. Dans le cas de Altena et Kääh (2021), la largeur de la rivière à l'étude est d'environ 3 km. Chaouch *et al.* (2014) et Kraatz *et al.* (2016) ont pour leur part étudié une des plus larges rivières du nord-est des États-Unis, soit la rivière Susquehanna pouvant atteindre jusqu'à 1,6 km.

Les RSO sont des capteurs actifs qui envoient leur propre source de rayonnement de manière oblique vers la cible. Le rayonnement est émis dans les micro-ondes. Celles-ci sont particulièrement sensibles aux surfaces à forte teneur en eau, d'où l'intérêt particulier de ce type d'ondes en hydrologie. Cette sensibilité est expliquée par la constante diélectrique de l'eau qui est élevée comparativement aux autres surfaces. La constante diélectrique d'un objet influence la quantité de micro-ondes réfléchié ou absorbé. Plus la constante est élevée, plus les ondes sont absorbées par la surface. Les micro-ondes sont également sensibles à la rugosité d'une surface. Plus une surface est rugueuse, plus les micro-ondes seront rétrodiffusées par la surface (Lindenschmidt, 2020).

Les RSO sont munis d'un récepteur qui permet de recevoir les micro-ondes rétrodiffusées par la surface de la Terre. Selon le type de glace et sa rugosité, la diffusion ne sera pas la même. Comme observé à la Figure 7, lorsque des micro-ondes atteignent un couvert de glace thermique, une portion d'entre elles pénètre ce dernier. Certaines d'entre elles sont diffusées à l'interface glace-eau, hors de portée du capteur. D'autres seront diffusées par des éléments du couvert de glace (bulles d'air, sédiments, microfissures, etc.) et pourront être saisis par le capteur. De leur côté, les micro-ondes ne pénétrant pas le couvert de glace sont réfléchies dans plusieurs directions et ne seront pas détectées. Dans le cas de la glace consolidée, la grande majorité des micro-ondes sont diffusées et

peuvent être captés (Lindenschmidt, 2020). Les données des satellites composant la constellation RADARSAT et les données du satellite Sentinel-1 sont issues de RSO. Elles sont utilisées pour étudier l'étendue, l'évolution et l'épaisseur de la glace des rivières (sections 2.3.3 et 2.3.4) assez larges (Li et Lindenschmidt, 2018; Lindenschmidt et Li, 2018; Mermoz *et al.*, 2014; Zhang *et al.*, 2019). Par exemple, Mermoz *et al.* (2014) ont étudié l'épaisseur de la glace de trois rivières canadiennes (rivière Koksoak, rivière Saint-François et rivière Mackenzie) sur des tronçons ayant une largeur minimale de 100 m. Une autre rivière canadienne étudiée à l'aide des données issues de RSO est la rivière aux Esclaves ayant une largeur moyenne d'environ 1 km (Li et Lindenschmidt, 2018; Lindenschmidt et Li, 2018; Zhang *et al.*, 2019).




**Figure 7 :** Interaction des micro-ondes avec (A et B) un couvert de glace thermique et (C et D) un couvert de glace consolidée (traduite de Lindenschmidt, 2020).

L'avantage d'utiliser des données issues de satellites est le champ d'observation très large qui n'est pas limité par les frontières nationales et les conditions géographiques (Zhang *et al.*, 2021). Cependant, les résolutions spatiales et temporelles ne sont généralement pas assez fines pour permettre un suivi intéressant de la glace de rivière. Puisque la période de revisite des satellites est généralement de plusieurs jours, aucune donnée n'est acquise pendant un certain laps de temps. De plus, les résolutions spatiales de plusieurs mètres permettent seulement d'étudier de larges rivières (Simoes et Clark, 2020). Finalement, puisque les capteurs multispectraux fonctionnent avec la réflectance de la Terre, la qualité des données acquises est fortement dépendante des conditions météorologiques. Par exemple, si une quantité importante de nuages est présente, la visibilité de la surface de la terre, et donc des rivières, sera grandement affectée. Ce problème peut être évité avec les RSO dont le rayonnement n'est pas affecté par ces conditions météorologiques (Lindenschmidt, 2020).

### 2.2.3 Drone

La fiabilité, les capacités techniques et la facilité d'utilisation des drones disponibles sur le marché ne cessent d'augmenter tandis que leur prix diminue. Le potentiel pour la recherche scientifique et les suivis opérationnels est grand. Les drones utilisés dans les études consultées sur la glace de rivière exploitent des capteurs optiques (Alfredsen *et al.*, 2018; Ansari *et al.*, 2020; Lin *et al.*, 2012; Singh *et al.*, 2020; Wang *et al.*, 2022; Zhang *et al.*, 2021). Bien qu'aucun exemple d'utilisation pour l'étude de la glace de rivière n'ait été trouvé, il est également possible d'installer des capteurs multispectraux, hyperspectraux, thermiques et lidar (*Light Detection and Ranging*) sur un drone (Yao *et al.*, 2019). L'utilisation de capteurs multispectraux (décrit à la section 2.2.2) et lidar sera étudiée au cours des prochaines années par une équipe de recherche de l'Université de Sherbrooke (Duguay *et al.*, 2023). Un capteur lidar est actif, il émet sa propre lumière qu'il envoie vers sa cible. En calculant le temps de retour de cette lumière, le capteur fournit des informations sur le profil topographique de la zone d'étude.

Il existe deux types de drones civils assez répandus : les drones à voilure rotative et les drones à voilure fixe (Figure 8). Chacun de ces types de drones possède ces avantages et ces inconvénients. Le fonctionnement des drones à voilures fixes est similaire à celui d'un avion. Les drones à voilure fixe ont la capacité de couvrir de grandes superficies puisqu'ils sont rapides, qu'ils peuvent voler à haute altitude et qu'ils ne sont pas énergivores. Les désavantages principaux de ce type de drone sont leur incapacité à effectuer des vols stationnaires et à décoller ou atterrir à la verticale. De leur côté, les drones à voilure rotative sont similaires aux hélicoptères puisque leur portance est assurée par une série d'hélices ayant une rotation horizontale. Ce type de drone peut voler à basse altitude, à faible vitesse et effectuer des vols stationnaires. Il décolle et atterrit à la verticale. Il est cependant moins bien adapté aux missions de longue durée puisque l'endurance de la batterie est plus faible (Ren *et al.*, 2019). Afin de combiner les avantages des deux types de drones, des modèles de drones à voilure fixe à décollage vertical (VTOL) sont en train de voir le jour (Okulski et Lawryńczuk, 2022). Pour le moment, ce type de drone est plus rare et dispendieux. Dans le cadre des études sur la glace de rivière consultées, la plupart des chercheurs ont préféré l'utilisation d'un drone à voilure rotative (Alfredsen *et al.*, 2018; Ansari *et al.*, 2020; Kalke et Loewen, 2018). Lin *et al.* (2012) ont pour leur part utilisé un drone à voilure fixe pour l'observation du fleuve Jaune en Chine et Zhang *et al.* (2021) ont combiné les deux types de drones pour acquérir des données sur ce même fleuve.



**Figure 8** : Drone (a) à voilure fixe, (b) à voilure rotative (modifiée de Ren *et al.*, 2019) et (c) à voilure fixe à décollage verticale (tirée de Okulski et Lawryńczuk, 2022).

L'utilisation de drone est bien adaptée à des environnements fluviaux dangereux. De plus, avec ces plateformes, il est possible d'acquérir des vidéos ou des images avec une prise de vue au nadir. Grâce à cette prise de vue, les images possèdent peu de distorsion et ne nécessitent pas de correction géométrique comparativement aux images prises par les caméras en rive (Tauro *et al.*, 2014). Les limites concernant l'utilisation des drones sont principalement liées aux conditions météorologiques, aux règlements en vigueur et à la capacité des batteries. En effet, la qualité des données peut être influencée par le vent, les précipitations et les conditions d'illumination (Lewis *et al.*, 2018). De plus, lorsque les températures sont froides, la durée d'utilisation des batteries peut diminuer rapidement. Il est d'ailleurs recommandé d'avoir plusieurs batteries et de les garder au chaud (Alfredsen *et al.*, 2018). Également, au Canada, le pilote de drone doit respecter les exigences réglementaires indiquées dans le *Règlement de l'aviation canadien* (RAC). Cela engendre certaines limitations, particulièrement si le pilote possède seulement un certificat pour les opérations de base des petits systèmes d'aéronef télépilote (SATP) à visibilité directe (VLOS). Dans ce cas, il est interdit de faire voler un drone dans certaines zones aériennes, le drone doit être gardé à vue et une altitude maximale doit être respectée (Transport Canada, 2021). Cela peut poser problème pour les plus grosses rivières où cette altitude doit être dépassée pour voir l'entièreté de leur largeur (Kalke et Loewen, 2018; Lewis *et al.*, 2018). Ces restrictions peuvent tout de même être contournées en faisant une demande de Certificat d'opérations aériennes spécialisées (COAS) pour un SATP auprès de Transport Canada (Transport Canada, 2021).

## 2.3 Méthodes de caractérisation de la glace fluviale

À la suite de l'acquisition des données par les multiples plateformes et capteurs présentés à la section 2.2, certains traitements sont nécessaires afin de caractériser la glace fluviale. Ceux-ci sont présentés dans cette section.

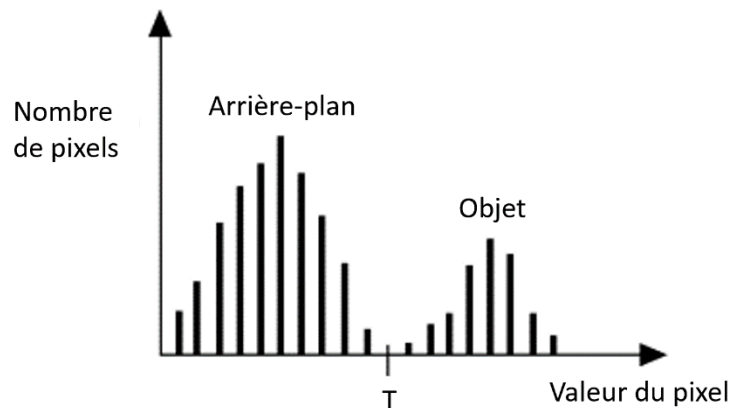
### 2.3.1 Classification de la glace fluviale

Comme discuté plus tôt (section 2.2), la concentration de glace fluviale est un facteur important pour la modélisation hydrodynamique de glace. La distinction entre la glace de fond détachée et le frazil est également importante pour la compréhension des processus de transport de sédiments et de formation du couvert de glace (Singh *et al.*, 2020; Sola, 2022). Grâce à leur haute résolution, les images de la glace de rivière acquises par drone ou par caméra en rive donnent un bon aperçu de l'état de celle-ci. Également, la segmentation de ces images en une ou plusieurs classes permet d'accéder à des informations quantifiées sur la densité et la distribution de la glace fluviale. Les méthodes de segmentation divisent une image en plusieurs groupes en considérant les similitudes des pixels (Sola, 2022). Kalke et Loewen (2018) ont identifié trois types de méthode de segmentation pouvant être intéressants pour l'étude de la glace fluviale, soient les méthodes de seuil, les machines à vecteurs de support (*Support Vector Machine*, SVM) et les réseaux de neurones convolutifs (*Convolutional Neural Network*, CNN).

#### 2.3.1.1 Les approches par méthodes de seuil

Parmi les méthodes de seuil, on retrouve la méthode de seuil traditionnelle et la méthode de seuil automatisée. La méthode de seuil traditionnelle est une méthode de traitement d'image de base qui part du principe que l'histogramme de l'image est bimodal (Figure 9) (Rogowska, 2009). Elle utilise donc les différences de niveau de gris ou de couleur d'une image afin d'extraire les objets qui y sont représentés à l'aide d'un seuil unique. Celui-ci est sélectionné et chaque pixel est classifié selon le rapport de leur valeur à ce seuil. Par exemple, tous les pixels ayant une valeur supérieure au seuil sont remplacés par un pixel blanc et tous les pixels ayant une valeur inférieure au seuil sont remplacés par un pixel noir. Lorsqu'un seul seuil est utilisé, cette technique produit donc des résultats binaires. Généralement, lorsque la méthode de seuil traditionnel est utilisée, un seuil constant est appliqué à une série d'images puisqu'il est choisi manuellement par l'utilisateur. Cela implique donc que les images doivent avoir des histogrammes similaires pour avoir des résultats intéressants (Russ, 2011). Pour sa part, la méthode de seuil automatisé part du même principe de

base, mais permet de s'adapter aux différents histogrammes. Deux types de méthode de seuil automatisé existent : global et local. La méthode globale applique un seuil à chaque image, mais celui-ci change d'une image à l'autre selon son histogramme. Cette méthode n'obtient pas de bons résultats lorsque les objets ont des valeurs de pixels très différentes ou que les images possèdent des variations spatiales importantes. La méthode locale vient répondre à ces problèmes. Elle calcule de manière automatique un seuil pour chaque pixel en se basant sur les statistiques (moyenne et médiane) des valeurs des pixels de son voisinage (Ansari *et al.*, 2017). En bref, l'utilisation des méthodes de seuil est simple, mais le bon seuil est difficile à déterminer (Zhang *et al.*, 2021). En utilisant des images optiques, ces méthodes permettent de segmenter les images de la glace de rivière en deux classes (eau/glace), mais ne permettent pas de distinguer les différents types de glace présente sur une image (Kalke et Loewen, 2018).

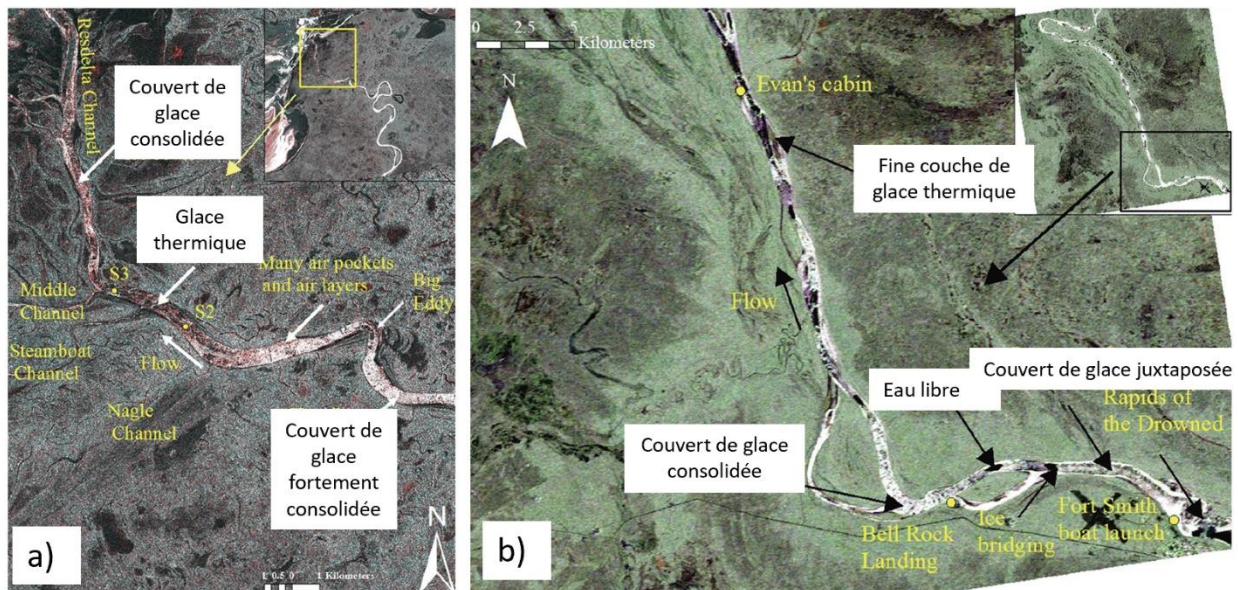


**Figure 9 :** Exemple d'histogramme bimodal où l'arrière-plan et les objets de l'image ont des valeurs de pixels pouvant être séparées par un seuil (T) (traduite de Rogowska, 2009).

Das et al. (2015) ont utilisé la méthode de seuil sur des données issues du satellite RADARSAT-2 (section 2.2.2) pour classifier la glace fluviale en trois classes (eau libre, glace thermique et glace consolidée/juxtaposée). Dépendamment du site, le mode fin large (F0W3 ; canaux HH-polarisation et HV-polarisation ; angle d'incidence de 38,7° à 45,3°) ou la quadripolarisation standard large (SQ21W ; canaux HH-, HV-, VH-, et VV-polarisation ; angle d'incidence de 40,2° à 41,6°) a été utilisé. Deux tronçons de la rivière des Esclaves, située dans les Territoires du Nord-Ouest, étaient à l'étude. La période d'étude s'étalait sur un hiver complet, soit de novembre 2013 à mars 2014. Tout d'abord, les images ont été converties au format TIFF et ont été traitées dans ArcGIS. Une ligne a été générée au centre de la rivière et un point a été ajouté à tous les 100 m. À partir de ces points, des zones tampons circulaires ont été générées. La valeur moyenne d'intensité de



rétrodiffusion de ces zones a été calculée et utilisée pour procéder à la classification. Une analyse visuelle des images RADARSAT-2 a permis de déterminer les seuils pour chacune des classes. Pour le premier site (mode fin large), des valeurs de rétrodiffusion très basse (-18 à -22 dB) apparaissaient comme des régions très sombres dans l'image et ont été considérées comme de l'eau libre. Les régions sombres ayant des valeurs plus élevées (-15 to -18 dB) ont été majoritairement considérées comme de la glace thermique. Les zones plus éclairées (plus que -12 dB) ont été considérées comme de la glace consolidée. Pour le deuxième site (quadripolarisation standard large), les sections d'eau étaient aussi caractérisées par des valeurs très faibles et apparaissaient noires. Les valeurs faibles apparaissant comme rougeâtres étaient considérées comme de la glace thermique et les valeurs plus élevées apparaissant plus lumineuses étaient considérées comme de la glace consolidée.



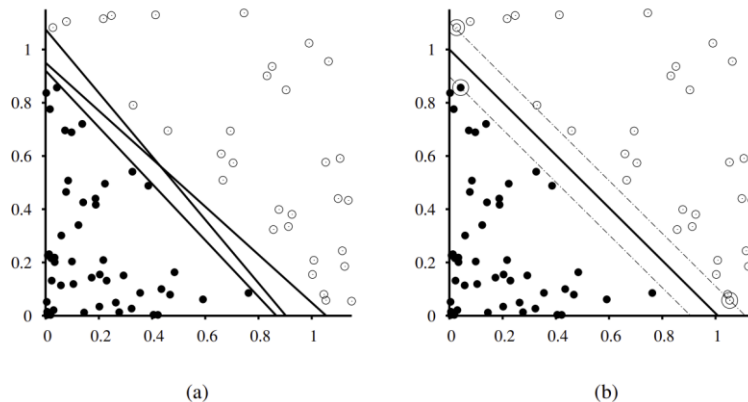
**Figure 10 :** Exemple de composé coloré du RADARSAT-2 (a) en mode fin large (F0W3) et (b) en quadripolarisation standard large (SQ21W) utilisé pour la classification des types de glace (traduite de Das *et al.*, 2015).

### 2.3.1.2 Les approches par machines à vecteurs de support

Les SVMs sont une des méthodes d'apprentissage automatique supervisées « prêtes à l'emploi » les plus populaires. Comme les autres méthodes d'apprentissage automatique, les SVMs ont besoin d'un jeu de données d'entraînement dont ils vont apprendre les règles. Une série d'images déjà annotée est donc nécessaire. Dans cette méthode, tous les objets à classifier sont représentés par un point dans un espace à n dimensions (Figure 11). Les SVMs produisent la classification en créant



un hyperplan permettant de séparer les points de chaque catégorie. Plusieurs options d'hyperplans séparant les catégories dans l'espace à n dimensions sont possibles. L'hyperplan sélectionné est celui qui maximise la distance (appelée marge) entre les points des catégories (Russell et Norvig, 2010).



**Figure 11 :** Fonctionnement des machines à vecteurs de support : (a) Deux classes (cercles noirs et blancs) et trois hyperplans potentiels, (b) L'hyperplan final (ligne noire) se trouve au milieu de la marge (zone entre les lignes pointillées). Les vecteurs de support (points encadrés) sont les objets les plus proches de l'hyperplan (tirée de Russell et Norvig, 2010).

Dans le but de développer une méthode de traitement permettant de calculer la concentration de glace de surface et de distinguer la glace de fond détachée du frazil, Kalke et Loewen (2018) ont comparé les méthodes de seuils aux SVMs. Des images ont été acquises sur trois sites. Ils étaient situés sur des rivières Albertaines, un sur la rivière Saskatchewan Nord et les deux autres sur la rivière de la Paix. Les images de la rivière Saskatchewan Nord ont été acquises à l'aide de caméras installées sur des ponts et d'un drone tandis que les images sur la rivière de la Paix ont été acquises à l'aide d'un drone seulement. Sur la rivière de la Paix, les vols de drone se sont produits du 21 au 23 janvier 2016 et du 14 au 15 janvier 2017. Les caméras ont été installées du 15 novembre au 18 décembre 2016 et ont été programmées pour prendre des images chaque minute de 9h00 à 16h00. Sur la rivière Saskatchewan Nord, les vols ont été effectués du 1<sup>er</sup> au 3 décembre 2016. Dans un premier temps, un SVM a été entraîné pour chacun des sites à distinguer l'eau de la glace. Les images ont également été traitées à l'aide de quatre méthodes de seuil (deux méthodes automatiques et deux méthodes manuelles). Les SVMs ont obtenu des précisions variant de 80% à 94%. De leur côté, les méthodes de seuils ont obtenu des précisions variant de 38% à 93%. Par la suite, un SVM a été entraîné à distinguer la glace de fond détachée au frazil et la concentration de chacun de ces

éléments a été calculée. La segmentation réalisée a obtenu une faible précision et l'erreur absolue des mesures de concentration se situe entre 1% et 10%. De plus, les images utilisées pour entraîner le SVM étaient subjectives puisqu'il a été difficile pour les auteurs de distinguer la glace de fond détachée du frasil. En conclusion, dans le cadre de la segmentation de la glace de rivière, les SVMs semblent produire de meilleures classifications eau/glace que les méthodes de seuils. Par contre, les classifications selon le type de glace (glace de fond détachée/frasil) présentent des résultats peu précis.

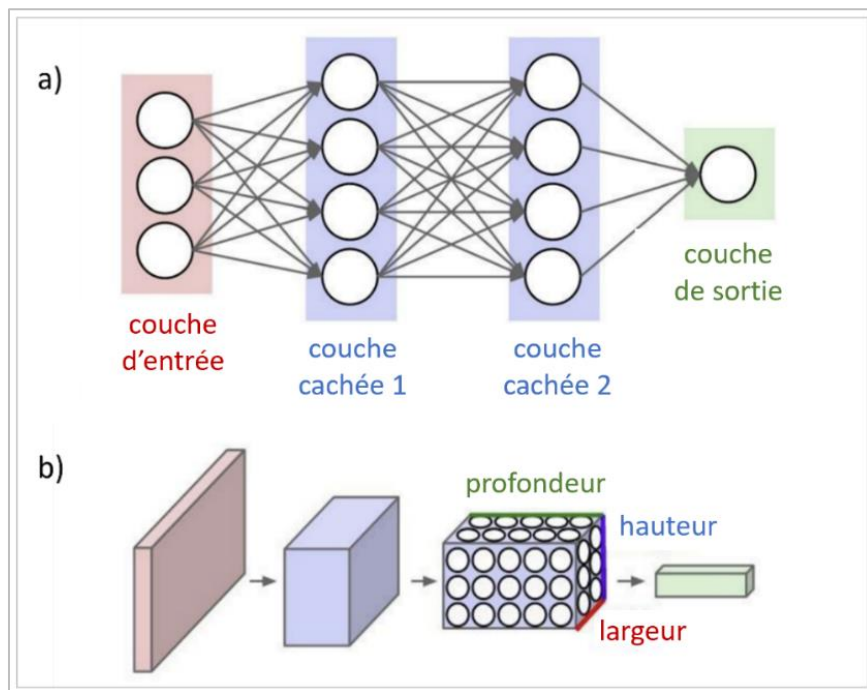
### 2.3.1.3 Les approches par réseaux de neurones profonds

Les perceptrons multicouches (*Multi-Layer Perceptron*, MLP) sont inspirés du cerveau humain. Pour fonctionner, tout comme les SVMs, ils nécessitent d'être entraîné avec un jeu de données déjà annoté. Les MLPs sont composés d'une couche d'entrée, d'une couche de sortie et de couches cachées entre les deux (Figure 12). Les différentes couches sont composées de neurones. Les données présentées au modèle constituent la couche d'entrée (Ma *et al.*, 2019). Les informations sont transmises d'une couche à l'autre par des canaux ayant une valeur unique. Les canaux sont donc tous pondérés différemment. Les neurones possèdent également chacun un poids que l'on appelle biais. La fonction d'activation du réseau décide quels neurones sont activés en calculant la somme pondérée des canaux et du biais. Les neurones activés par cette fonction transmettent l'information à la couche suivante et ainsi de suite jusqu'à la couche de sortie (Khan *et al.*, 2020). Les pondérations des canaux et des biais sont continuellement ajustées selon la fonction de coût qui compare les prédictions aux images manuellement segmentées. Le réseau tente de minimiser l'erreur observée par cette fonction. Ce processus se nomme rétropropagation. Il calcule le gradient de la fonction de coût selon le poids du neurone et tente d'atteindre l'erreur minimum au fur et à mesure de son apprentissage (Goodfellow *et al.*, 2016).

Il existe plusieurs types d'architecture de réseaux de neurones profonds (*Deep Neural Network*, DNN). Une des plus communes est le CNN (*Convolutional Neural Network*). Elle a été conçue pour le traitement de données sous forme matricielle, telle que les images (Khan *et al.*, 2020). Cette architecture a d'ailleurs été utilisée pour la classification de la glace de rivière (Ansari *et al.*, 2020; Singh *et al.*, 2020; Sola, 2022; Zhang *et al.*, 2021). Les CNNs partent du même principe que les MLPs, mais les neurones prennent la forme de tenseurs à trois dimensions (Figure 12). De plus, lorsque l'on utilise un CNN, les mêmes poids sont utilisés pour chacune des sections de l'image.

On dit alors que les poids sont partagés (Vaibhav *et al.*, 2021). C'est le principe des couches convolutives qui agissent comme des matrices de poids facilitant l'apprentissage du modèle (Khan *et al.*, 2020).

Les architectures de type SegNet permettent de réaliser des tâches de segmentation sémantique et sont généralement composées de deux sections: l'encodeur et le décodeur. L'encodeur est un CNN qui détermine les éléments permettant de distinguer chacune des classes. Pour ce faire, il effectue différentes séries de transformations sur l'image à l'aide des couches qui le composent. Par la suite, le décodeur utilise les caractéristiques déterminées par l'encodeur pour attribuer une classe à chaque pixel de l'image (Dorkhah *et al.*, 2023). L'architecture de type UNet est un des SegNet les plus utilisées en traitement d'images ayant une structure encodeur-décodeur. À la base, cette architecture a été conçue afin de traiter des images médicales (Ronneberger *et al.*, 2015). L'encodeur crée des cartes de caractéristiques sémantiques (*embeddings*) à faible résolution que le décodeur convertit ensuite en cartes de probabilités multi-classes (Ronneberger *et al.*, 2015).



**Figure 12 :** (a) Perceptron multicouche (*Multi-Layer Perceptron*). La couche d'entrée est composée du jeu de données. Les couches cachées sont connectées par les canaux et rejoignent la couche de sortie où en ressort le résultat. (b) Architecture d'un réseau de neurones convolutif. Les neurones sont en trois dimensions, chaque couche reçoit et produit des informations 3D. La hauteur (ligne bleue) et la largeur (ligne rouge) des couches cachées correspondent aux dimensions de l'image d'entrée. La profondeur (ligne verte) correspond au nombre de filtres dans la couche convolutive (modifiée de Stanford University, s.d.).

Quelques auteurs ont utilisé des CNNs pour effectuer une segmentation de la glace de rivière. Les paramètres utilisés, tels que les architectures ou les classes, varient d'une étude à l'autre. Les études consultées sont comparées au Tableau 2.

**Tableau 2** : Présentation des études consultées portant sur la segmentation de la glace de rivière à l'aide de réseaux de neurones convolutifs (*Convolutional Neural Network*, CNN).

Auteurs	Classes	Images annotées	Architecture	Rivières	Résultat
Singh <i>et al.</i> , 2020	Eau, frasil et glace de fond	50	Deeplab	rivière Saskatchewan Nord et rivière de la Paix, Alberta	IoU* frasil : 77 %
			UNet		IoU glace de fond : 62 %
			SegNet		IoU moyen (eau+glace) : 77%
			DenseNet		IoU frasil : 71%
			SVM		IoU glace de fond : 55 %
Sola et Scott, 2022	Eau, frasil et glace de fond	50	DSC LBC	rivière Saskatchewan Nord et rivière de la Paix, Alberta	IoU moyen (eau+glace) : 73%
Ansari <i>et al.</i> , 2020	Glacé de rive, glace détachée, frasil sous forme de <i>slush</i> et frasil sous forme de radeaux	50	Mask-RCNN	rivière Dauphin, Manitoba	IoU frasil : 62 %
Ansari <i>et al.</i> , 2021	Glacé de rive, glace détachée, forme de <i>slush</i> et frasil sous forme de radeaux, couvert de glace et eau	115	IceMaskNet	rivière Dauphin, Manitoba	IoU glace de fond : 53%
Zhang <i>et al.</i> , 2020	Eau, glace, autres	814	ICENET	fleuve Jaune, Chine	IoU moyen (eau+glace) : 70%
Zhang <i>et al.</i> , 2021	Eau, glace de rive, glace en mouvement et autres	1 525	ICENETv2	fleuve Jaune, Chine	IoU frasil : 61 %
					IoU glace de fond : 49 %
					IoU moyen (eau+glace) : 68%
					IoU frasil : 63%
					IoU glace de fond : 43%
					IoU moyen (eau+glace) : 66 %
					IoU moyen : 64% à 71%
					Précision : 97%
					Précision moyenne du pixel : 91%
					IoU moyen : 88%
					IoU moyen : 89%

\*Intersection sur l'union (*Intersection over Union*, IoU)

Singh *et al.* (2020) ont expérimenté quatre architectures de réseaux, soient Deeplab, Unet, SegNet et DenseNet. Les images utilisées ont été acquises durant l'hiver 2016 et 2017 sur la rivière Saskatchewan Nord et la rivière de la Paix dans le cadre de l'étude de Kalke et Loewen (2018)

expliquée à la section 2.3.1.2. Sur les sites d'acquisition de la rivière Saskatchewan Nord, la largeur de la rivière était approximativement de 200 à 250 mètres. Au site d'acquisition de la rivière de la Paix, la largeur de la rivière était d'environ 375 m. Les auteurs ont créé *l'Alberta river ice segmentation dataset* composé de 50 images annotées selon trois catégories (eau, frasil et glace de fond détachée) pour entraîner les modèles. Les mêmes images ont aussi été segmentées à l'aide d'un SVM à titre comparatif. Deux valeurs ont été utilisées pour évaluer le résultat des différentes architectures, soient la précision du pixel et l'intersection sur l'union (*Intersection over Union*, IoU). La précision est le rapport entre les pixels correctement classifiés et le nombre total de pixels d'une image. L'IoU mesure la similarité entre le masque généré par l'utilisateur et le masque généré par le réseau. L'aire de chevauchement des deux masques est divisée par l'aire totale des masques. L'IoU varie entre 0 et 1. Un IoU supérieur à 0,5 est considéré comme bon, bien que les attentes puissent varier d'un projet à l'autre (Zhu *et al.*, 2021). Dans le cadre de l'étude, ces valeurs ont été générées à partir du jeu de données de test pour les classes frasil et glace de fond détachée. Chacun des réseaux a offert des résultats intéressants et a mieux performé que le SVM. Bien que DeepLab a obtenu les meilleurs résultats quantitatifs, Unet a été jugé comme plus intéressant par les auteurs puisqu'il offrait de bons résultats quantitatifs et une bonne capacité de généralisation. La précision des pixels de Unet s'est élevée respectivement à 74% et 84% pour la glace de fond détachée et le frasil. L'IoU obtenu pour la glace de fond détachée est de 55% et de 71% pour le frasil. La segmentation de la glace de fond détachée a été moins réussie. Cela peut être expliqué en partie par le faible échantillonnage de cette catégorie. Effectivement, la glace de fond détachée constituait seulement 17% des pixels du jeu de données. De plus, une des principales difficultés rencontrées par les auteurs est l'annotation manuelle des images. La distinction entre les deux types de glace n'est pas aisée, même pour les experts. Les deux types de glaces présentent de fortes variations à l'intérieur de leur classe tout en partageant des similarités entre elles. Les formes des morceaux de glace sont également difficiles à délimiter.

Sola et Scott (2022) proposent un nouveau bloc convolutif simplifié (DSC LBC) avec moins de paramètres pour construire une architecture semblable à Unet, mais moins profonde. Leur objectif est d'explorer les compromis performance-latence possibles afin d'éventuellement pouvoir effectuer une segmentation en temps réel sur le terrain malgré les limitations concernant le matériel et la puissance de calcul. Le jeu de données utilisé, *l'Alberta river ice segmentation dataset*, est celui créé par Singh *et al.* (2020). Les classes sont donc également les mêmes. L'architecture

proposée par Sola et Scott (2022) offre des résultats comparables à Unet (jeu de donnée de tests) en plus d'avoir 99,9% moins de paramètres, d'opérations de multiplication et d'addition. De plus, l'architecture utilise 69,8% moins de mémoire que Unet. L'inférence s'effectue donc beaucoup plus rapidement.

Ansari *et al.* (2020) ont utilisé l'architecture Mask-RCNN et l'on entraîné avec 60 images annotées. Les images ont été acquises sur la rivière Dauphin au Manitoba. Elle est d'approximativement 52 km de long et relie le lac Saint-Martin au lac Winnipeg. Le nombre de dates et les moments d'acquisition ne sont pas mentionnés. Les images ont été segmentées en quatre classes (glace de rive, glace détachée, frasil sous forme de *slush* et frasil sous forme de radeaux). La précision de la segmentation obtenue s'élève à 97%. Cependant, la méthodologie permettant de générer cette valeur n'est pas présentée dans l'article. Ansari *et al.* (2021) ont continué les travaux pour développer un algorithme de détection et de segmentation automatisé en modifiant la structure du Mask-RCNN. Une classe pour l'eau et une classe pour les couverts de glaces ont été ajoutées aux quatre autres. 115 images, prises de novembre à mars de 2017 à 2020, ont été annotées selon ces classes. Avec cette méthode, la précision moyenne du pixel obtenu pour la segmentation s'élève à 91% pour le jeu de données de test. Selon les auteurs, les erreurs sont principalement dues au faible nombre d'images annotées et aux difficultés d'annotations. Effectivement, comme c'est le cas pour d'autres études présentées, les auteurs notent qu'il est difficile d'attribuer une classe à certains éléments même pour les experts.

Zhang *et al.* (2020) proposent leur propre architecture nommée ICENET. Les auteurs ont créé un jeu de données comprenant des images du fleuve Jaune, plus précisément du tronçon situé en Mongolie-Intérieure Ningxia, prises entre les mois de novembre et mars de 2015 à 2019. Le fleuve Jaune est une des plus longues rivières du monde (5 464 km) et possède une aire de drainage de 752,443 km<sup>2</sup>. La largeur du fleuve Jaune varie grandement à l'intérieur de la zone d'étude. Au total, 200 vidéos d'une longueur variant entre 10 et 50 minutes ont été acquises. Les prises de vues ainsi que les hauteurs des vols (entre 30 et 500 m) sont variables. Au final, 814 images ont été annotées selon trois classes : eau, glace et autres. Tout comme Singh *et al.* (2020), les auteurs ont rencontré des difficultés à délimiter clairement les frontières entre les différentes classes lors de l'annotation des images. Pour cette raison, l'annotation a été particulièrement coûteuse en temps. La segmentation a tout de même été un succès puisque la moyenne de l'IoU des classes s'est élevée

à 88% pour le jeu de données de test. Le jeu de données de test inclut les données de validation. Zhang *et al.* (2021) ont repris et amélioré l'architecture développée par Zhang *et al.* (2020) pour créer ICENETv2. Le même jeu de données a également été utilisé, mais, cette fois-ci, 1525 images ont été annotées selon 4 classes : glace de rive, glace en mouvement, eau et autres. La moyenne de l'IoU des classes est d'environ 89% pour le jeu de données de test. Le jeu de données de test inclut ici également les données de validation. Les auteurs ont également utilisé le résultat de la segmentation afin de calculer la concentration de la glace dérivante. Pour ce faire, le nombre de pixels de glace dérivante a été divisé par la somme du nombre de pixels d'eau et de glace dérivante. Les auteurs ont noté que pour calculer correctement la concentration, la prise de vue doit être au nadir et que les deux rives doivent apparaître sur l'image.

### 2.3.2 Épaisseur de la glace fluviale

Il est possible d'obtenir l'épaisseur de la glace fluviale en traitant les données provenant des RSOs, des GPRs et des SWIPs. Comme mentionné dans la section 2.2.2, les RSOs émettent des micro-ondes. Ces micro-ondes ne sont pas diffusées de la même manière selon le type de couvert de glace rencontré. En fait, plus le couvert de glace est épais, plus la rétrodiffusion atteignant le satellite est importante. Une corrélation entre l'épaisseur de glace et la rétrodiffusion a d'ailleurs été étudiée. Les données provenant de RADARSAT-2 ont été utilisées par Lindenschmidt *et al.* (2010) pour déduire l'épaisseur du couvert de glace sur la rivière Rouge située au Manitoba. Par la suite, d'autres auteurs se sont penchés sur le sujet et ont obtenu des résultats intéressants malgré quelques limitations dues à la présence de neige sur le couvert de glace (Li et Lindenschmidt, 2018; Lindenschmidt et Li, 2018; Mermoz *et al.*, 2014; Zhang *et al.*, 2019). Il a été conclu que les estimations obtenues à l'aide de cette méthode permettent de fournir un portrait général de l'épaisseur de la glace, mais qu'il existe une marge d'erreur importante. Par exemple, l'erreur quadratique moyenne des mesures d'épaisseur de glace estimée par Mermoz *et al.* (2014) s'élevait à 9,2 cm. Les mesures estimées ont été comparées à des mesures *in situ* prises à l'aide de tarière à glace et d'un ruban à mesurer ou d'un GPR.

Pour obtenir l'épaisseur de la glace à partir d'un GPR (section 2.2.1), il est nécessaire de transformer la mesure de temps obtenu (temps de parcours de l'onde) en épaisseur. Pour ce faire l'Équation 1 est utilisée. La variable  $c$  représente la vitesse des ondes électromagnétiques dans le vide, la variable  $t$  représente le temps de parcours de l'onde obtenu, la variable  $d$  représente la

distance entre les deux antennes du GPR (émission et réception) et la variable  $\varepsilon$  représente la constante diélectrique de la glace (Fu *et al.*, 2018). Dans l'étude de Fu *et al.* (2018), cette technique a été utilisée et les résultats ont été comparés à des mesures *in situ* prises avec une règle à angle droit. L'erreur quadratique moyenne s'élevait à 4 cm.

$$H = \sqrt{\frac{c^2 t^2 - \varepsilon d^2}{4\varepsilon}} \quad (1)$$

Pour calculer l'épaisseur de la glace à partir du SWIP, il faut tout d'abord déterminer la profondeur de l'eau au-dessus du transducteur acoustique à l'aide de l'Équation 2 :

$$\eta = (P_{btm} - P_{atm}) / \rho g - \Delta D \quad (2)$$


où  $\eta$  représente la profondeur de l'eau au-dessus du transducteur acoustique,  $P_{btm}$  représente la pression hydrostatique mesurée par le SWIP,  $P_{atm}$  représente la pression atmosphérique,  $\rho$  représente la densité de l'eau,  $g$  représente l'accélération de la gravité et  $\Delta D$  représente la séparation physique entre le transducteur acoustique et le capteur à pression hydrostatique (Buermans *et al.*, 2011).

Par la suite, il faut déterminer la distance entre la face inférieure du couvert de glace et la surface de l'eau en tenant compte de l'angle d'inclinaison du transducteur acoustique à l'aide de l'Équation 3 :

$$d = \eta - \beta * r * \cos \theta \quad (3)$$

où  $d$  représente la distance entre la face inférieure du couvert de glace et la surface de l'eau,  $\beta$  représente la vitesse du son dans l'eau en fonction d'autres facteurs,  $r$  représente la distance entre le transducteur et la surface inférieure de la glace et  $\theta$  représente l'angle d'inclinaison du transducteur acoustique (Buermans *et al.*, 2011). Les différentes variables des équations sont illustrées à la Figure 13 (Buermans *et al.*, 2011).






**Figure 13 :** Paramètres nécessaires aux calculs de la profondeur de l'eau au-dessus du transducteur acoustique et de la distance entre la face inférieure du couvert de glace et la surface de l'eau (tirée de Buermans *et al.*, 2011).

### 2.3.3 Évolution et étendue du couvert de glace

L'évolution et l'étendue du couvert de glace sont généralement étudiées à partir de l'analyse temporelle provenant de satellites ou de caméras en rive (Figure 14). Bien que peu étudiée dans le cas de la glace de rivière, cette analyse peut aussi se faire à partir d'images acquises par drone. Les informations retirées de ces analyses temporelles peuvent être quantitatives (Ansari *et al.*, 2017) ou qualitatives (Lindenschmidt, 2020). Ansari *et al.* (2017) ont extrait des informations concernant, entre autres, l'étendue et le taux d'avancement et de recul du couvert de glace d'une série temporelle d'images prises par des caméras en rive au cours d'un hiver. Pour ce faire, les auteurs ont tout d'abord géorectifié les images et les ont segmentées à l'aide de la méthode de seuil (expliquée à la section 2.3.1). Grâce à l'algorithme, les frontières du couvert de glace ont alors été tracées automatiquement sur chacune des images de la série temporelle. Par la suite, les coordonnées réelles des pixels correspondant aux frontières ont été déterminées. À partir de ces informations, les taux de déplacement ont pu être calculés. Les pixels classifiés comme étant de la glace ont également permis d'obtenir la superficie totale du couvert de glace. La validation de la méthode utilisée s'est effectuée en deux étapes, soient la validation de la géorectification et la validation des étendues des couverts de glace générés. La géorectification des images a été validée en comparant les points de contrôle au sol acquis lors de la campagne terrain à leur point

correspondant sur les images géorectifiées. La distance entre les deux points correspondants a été utilisée comme indicateur. L'erreur quadratique moyenne était inférieure à 30 mètres, ce qui a été jugé acceptable par les auteurs. Par la suite, les auteurs ont délimité les frontières des couverts de glace manuellement sur 30 images et l'aire du couvert de glace a été calculée à partir de celles-ci. Ces résultats ont été comparés à ceux générés automatiquement par l'algorithme. Une erreur quadratique moyenne a été obtenue pour chacun des deux sites à l'étude, soit 28 m<sup>2</sup> et 107 m<sup>2</sup> (moyenne de 68 m<sup>2</sup>). Dépendamment des jours, la surface totale du couvert de glace calculée manuellement pour le site ayant l'erreur quadratique moyenne la plus élevée (107 m<sup>2</sup>) variait d'environ 311 m<sup>2</sup> à 485 m<sup>2</sup>. Pour le site ayant l'erreur quadratique moyenne la plus faible (28 m<sup>2</sup>), la surface variait d'environ 73 m<sup>2</sup> à 85 m<sup>2</sup>.



**Figure 14** : Série temporelle prise par une caméra en rive permettant d'analyser la formation du couvert de glace (tirée de Lindenschmidt, 2020).

Des images satellites ont également été utilisées pour analyser la distribution du couvert de glace au travers des années. Li *et al.* (2020) ont utilisé l'indice NDSI (*Normalized Difference Snow Index*) et Li *et al.* (2021) ont utilisé un indice de leur cru, le RDRI (*Relative Difference River Ice*). Le NDSI est une équation calculant la différence normalisée entre les bandes spectrales du vert et de l'infrarouge court (Équation 4). Cet indice permet de mettre la neige en évidence dans les images. Pour calculer cet indice, Li *et al.* (2020) ont utilisé des images provenant de trois capteurs, soit le

Landsat 5 Thematic Mapper (TM), le Landsat 7 Enhanced TM (ETM+) et le Landsat 8 Operational Land Imager (OLI). Les bandes spectrales et les longueurs d'onde spécifiques utilisées sont présentées au Tableau 3. De son côté, le RDRI tente de distinguer la glace de rivière de la neige en se basant sur leur différence de réflectivité dans les bandes rouges et du proche infrarouge (Équation 5). Li *et al.* (2021) ont pu démontrer l'efficacité de leur indice pour différencier la neige de la glace de rivière, mais celui-ci n'est pas pertinent lorsque le couvert de glace fluviale est recouvert de neige. Des images provenant de trois capteurs Landsat (TM, ETM, OLI) et du capteur Sentinel-2 MultiSpectral Instrument (MSI) ont été utilisées par les auteurs (Tableau 3).

$$\text{NDSI} = \frac{\text{Vert} - \text{Infrarouge court}}{\text{Vert} + \text{Infrarouge court}} \quad (4)$$

$$\text{RDRI} = \frac{\text{Rouge} - \text{Proche infrarouge}}{\text{Proche infrarouge} + \text{Infrarouge court}} \quad (5)$$

**Tableau 3 :** Capteurs, bandes spectrales et longueurs d'onde utilisés par Li *et al.* (2020) pour calculer le NDSI (*Normalized Difference Snow Index*) et par Li *et al.* (2021) pour calculer le RDRI (*Relative Difference River Ice*).

Capteurs / Bandes spectrales	Landsat 5 Thematic Mapper (TM)	Landsat 7 Enhanced TM (ETM+)	Landsat 8 Operational Land Imager (OLI)	Sentinel-2 MultiSpectral Instrument (MSI)
Vert	Bande 2 520-600 nm	Bande 2 525-605 nm	Bande 3 525-600 nm	Bande 3 560 nm (35 nm)*
Rouge	Bande 3 630-690 nm	Bande 3 630-690 nm	Bande 4 630-680 nm	Bande 4 665 nm (30 nm)*
Proche infrarouge	Bande 4 760-900 nm	Bande 4 775-900 nm	Bande 5 845-885 nm	Bande 8 842 nm (115 nm)*
Infrarouge court	Bande 5 1550-1750 nm	Bande 5 1550-1750 nm	Bande 6 1560-1660 nm	Bande 11 1610 nm (90 nm)*

\*longueur d'onde centrale (largeur de bande)

Beaton *et al.* (2019) ont étudié l'évolution du couvert de glace de cinq rivières ontariennes se déversant dans la baie James et la baie d'Hudson (Moose, Albany, Attawapiskat, Winisk et Severn) à l'aide des données du satellite MODIS. Le but principal de l'étude était de développer une méthode permettant de générer les dates de débâcles des couverts de glaces. Le second objectif était de calculer des statistiques (durée, variabilité annuelle et ordre des débâcles) à partir des dates

généralisées afin d'améliorer la compréhension des processus de glace de la zone à l'étude. Pour ce faire, une analyse d'images MODIS prises entre 2000 et 2017 a été effectuée à l'aide de la méthode de seuils et du logiciel *Google Earth Engine* (GEE). Tout d'abord, les rivières à l'étude ont été séparées en tronçons. Par la suite, les pixels à classifier ont été sélectionnés grâce à un masque représentant les surfaces d'eau développé par Ressources Naturelles Canada. Deux classes ont été déterminées, soient eau libre et autres. Pour les images où les conditions étaient connues, les histogrammes de réflectance ont été générés pour déterminer les seuils séparant les deux classes. Pour tous les tronçons et toutes les dates des images de la rivière Albany, les seuils ont été calibrés en comparant les seuils obtenus automatiquement et ceux obtenus visuellement. Les seuils calibrés obtenus sur cette rivière ont été utilisés pour calculer les dates de débâcles des autres rivières. Pour déterminer la date de début et de fin de la débâcle, le pourcentage de pixel classé comme eau libre était calculé sur chaque image. Lorsqu'un certain pourcentage de pixel d'eau libre était atteint, les auteurs considéraient que la débâcle avait débuté. Il en va de même pour la fin de la débâcle. Les dates de début et de fin de débâcles obtenues grâce à la classification automatique ont été comparées à celles identifiées à partir des stations de jaugeage de Relevés hydrologiques du Canada. Le biais moyen se situait entre 2,0 et 6,7 jours et l'erreur absolue moyenne entre 3,4 jours et -6,9 jours pour l'ensemble des rivières. Les auteurs ont déterminé que la latitude et la distance par rapport à l'amont étaient les facteurs influençant principalement la date de la débâcle.


Certains auteurs ont également utilisé des RSOs pour l'étude de l'évolution du couvert de glace. Unterschultz *et al.* (2009) ont investigué le potentiel de l'utilisation des images du satellite RADARSAT-1 pour, entre autres, la caractérisation des débâcles et des embâcles. L'étude s'est conduite sur la rivière Athabasca en Alberta durant l'hiver 2003 et l'hiver 2004. Au total, treize images de différents types (F2, F2N, F3F, F5, S1 et S7) et angles d'incidence ( $39^\circ$  à  $42^\circ$ ,  $39^\circ$  à  $42^\circ$ ,  $41^\circ$  à  $44^\circ$ ,  $45^\circ$  à  $47^\circ$ ,  $24^\circ$  à  $31^\circ$  et  $39^\circ$  à  $42^\circ$ ) ont été utilisées. Le tronçon de la rivière à l'étude a été divisé en 18 zones. Le coefficient de rétrodiffusion moyen a été calculé pour chaque zone dans les treize images. Au printemps 2003 et 2004, il a été noté que la rétrodiffusion de la glace diminuait lorsqu'une débâcle thermique du couvert de glace se produisait. D'un autre côté, les auteurs ont observé une augmentation d'environ 5 dB lors de l'embâcle du 22 avril 2004. L'accumulation, au-dessus du niveau d'eau, des radeaux de glace drainés aurait une constante diélectrique moins élevée. De plus, les radeaux étaient orientés de manière aléatoire et ils étaient très poreux. Selon les auteurs, ces caractéristiques seraient la cause de l'augmentation du signal de retour reçu par le satellite.

Comment mentionné plus tôt, l'utilisation d'orthomosaïques conçues à l'aide d'images acquises par drone est peu documentée pour l'étude de l'étendue du couvert de glace fluviale, mais est prometteuse (Alfredsen *et al.*, 2018; Lin *et al.*, 2012). Pour concevoir les orthomosaïques, la zone à l'étude doit être quadrillée par le drone afin qu'un haut recouvrement (60% à 80%) soit présent entre les images capturées. Les images sont par la suite traitées avec une technique basée sur le principe de *Structure-from-Motion* (SfM). À partir des informations contenues dans les images, ce type de logiciel est en mesure de créer un modèle numérique terrain et des orthomosaïques.

#### **2.3.4 Vitesse de la glace fluviale**

La vitesse de la glace peut être calculée à partir de méthodes de traitement d'images provenant de satellites (Altena et Kääh, 2021), de caméras en rive (Daigle *et al.*, 2013) et de drones (Wang *et al.*, 2022). La vélocimétrie de suivi de particules (*Particle Tracking Velocimetry*, PTV) et la vélocimétrie par analyse de séquences d'images à grande échelle (*Large-Scale Particle Image Velocimetry*, LSPIV) sont deux techniques pouvant être utilisées pour calculer la vitesse de la glace de rivière (Daigle *et al.*, 2013; Wang *et al.*, 2022). Ces techniques sont également utilisées pour déterminer la vitesse d'écoulement et le débit en eau libre (Le Coz *et al.*, 2010, 2016).

Le principe du PTV et du LSPIV est de filmer ou de prendre une série d'images successives de l'écoulement d'une rivière. Certains traceurs (bois flottant, bulles d'air, plaques de glace, etc.) doivent être présents sur les images. Les techniques diffèrent toutefois sur quelques aspects (Figure 15). En PTV, la vitesse individuelle des traceurs présents dans l'eau est calculée en suivant ceux-ci à travers le temps et l'espace. Un vecteur de vitesse est créé pour chacun des traceurs. Cette technique a donc une approche lagrangienne. Elle est mieux adaptée pour générer des vitesses pour un endroit et un moment précis. La méthode LSPIV mesure plutôt la vitesse de l'écoulement à partir d'une grille. La vitesse moyenne du groupe de particules présent dans une fenêtre précise est calculée, produisant alors un vecteur de vitesse pour chacun des carrés de la grille. C'est l'approche eulérienne qui permet de générer des vitesses sur une plus grande superficie et une plus grande période. La technique LSPIV nécessite une bonne densité de traceurs pour obtenir des résultats intéressants (Jolley *et al.*, 2021).



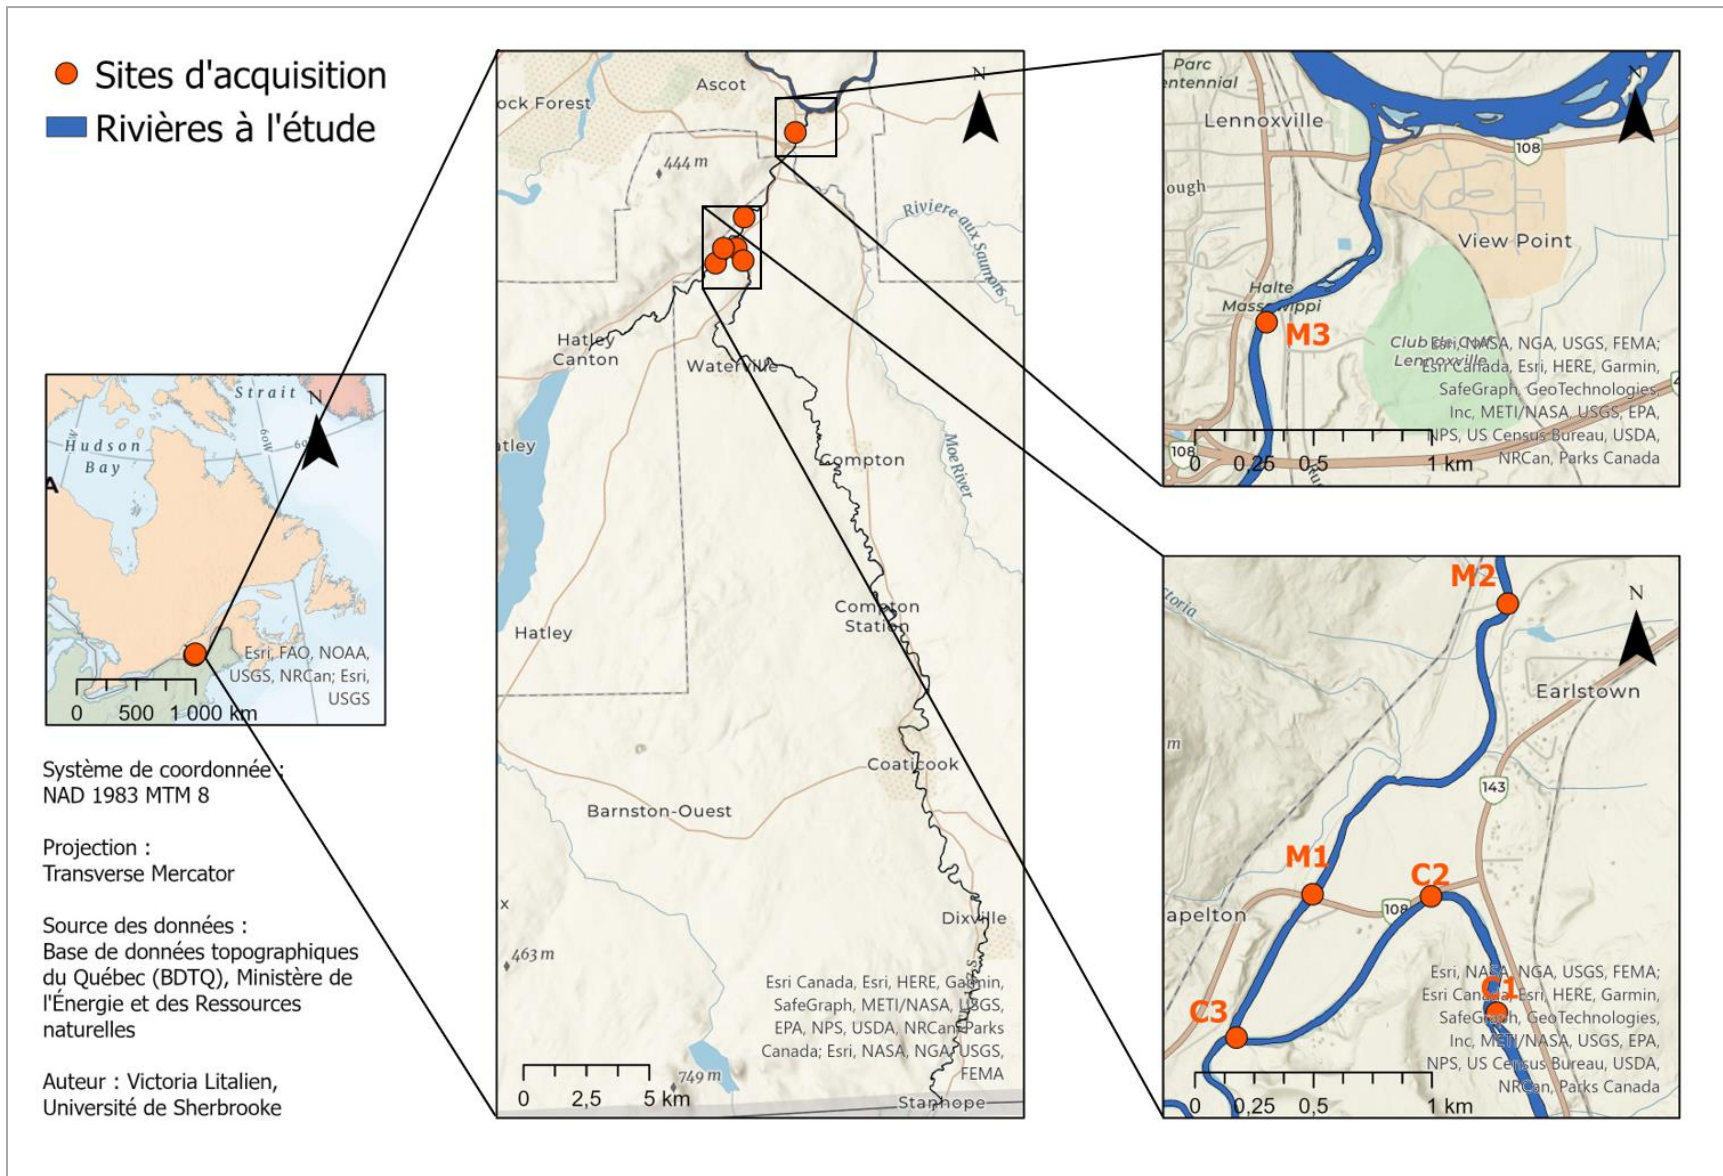
**Figure 15** : Comparaison de (a) la vélocimétrie par analyse de séquences d’images à grande échelle (Large-Scale Particle Image Velocimetry, LSPIV) et de (b) la vélocimétrie de suivi de particules (Particle Tracking Velocimetry, PTV) (traduite de Jolley *et al.*, 2021).

### 3 Présentation des sites à l’étude

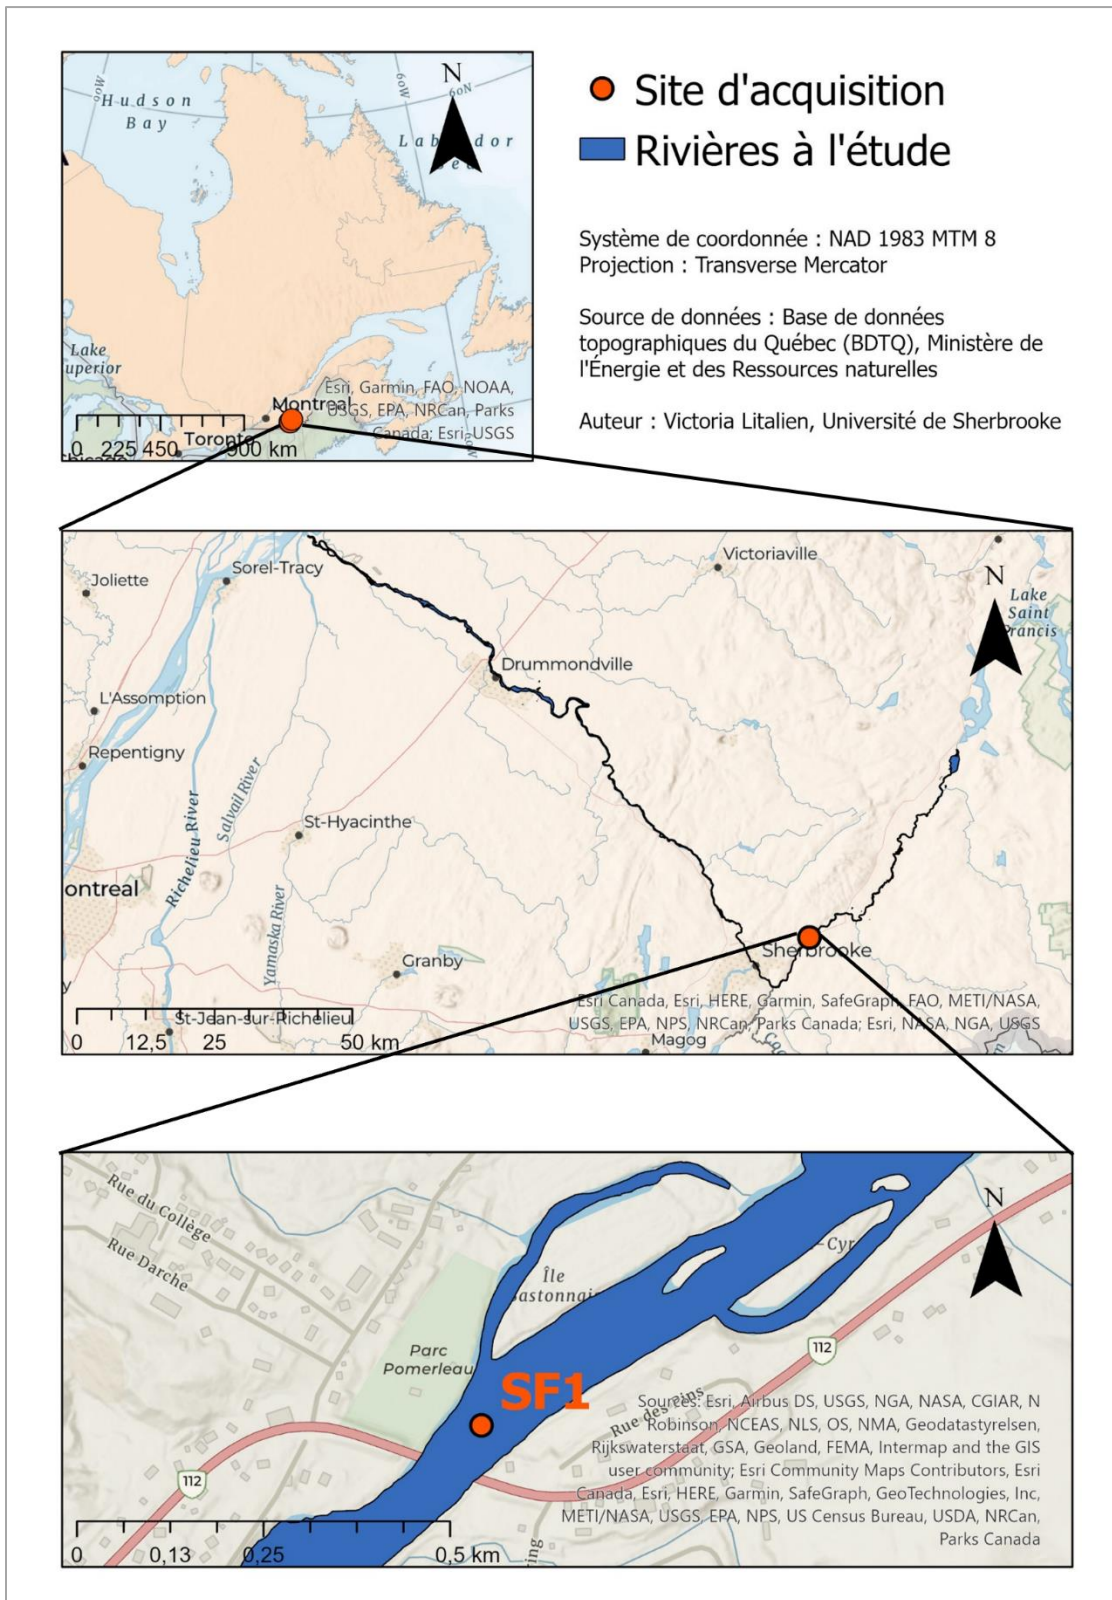
Trois rivières sont à l’étude, soient les rivières Coaticook, Massawippi et Saint-François (Figure 16 et Figure 17). Ces trois rivières sont situées en Estrie. La rivière Coaticook traverse la frontière canado-américaine et se déverse dans la rivière Massawippi. Cette dernière débute au lac Massawippi et se déverse dans la rivière Saint-François. Pour sa part, la rivière Saint-François débute au Grand lac Saint-François et termine au lac Saint-Pierre.

Sur la rivière Coaticook, les données ont été acquises à trois endroits différents. La largeur de la rivière à ces endroits varie entre 30 et 45 mètres. Sur la rivière Massawippi, les données ont également été acquises à trois endroits différents. La largeur de la rivière à ces endroits est dans le même ordre de grandeur. Finalement, un site d’acquisition est situé sur la rivière Saint-François. La largeur de la rivière est d’environ 90 mètres.





**Figure 16 :** Emplacement des sites d'acquisition des données sur les rivières Coaticook (C) et Massawippi (M).



**Figure 17 :** Emplacement du site d'acquisition des données sur la rivière Saint-François (SF).



## 4 Matériel et méthode

La méthode est divisée en quatre sections principales présentant les grandes étapes accomplies dans cet essai. Ces étapes sont illustrées à la Figure 18. La première étape consiste en l'acquisition des données. Les journées d'acquisition des données ont été déterminées en fonction des températures journalières et des aperçus fournis en temps quasi réel par les caméras installées en rive. Les deux étapes suivantes traitent de l'entraînement du modèle pour le calcul de l'étendue de la glace statique et de l'entraînement des modèles pour le calcul de la concentration de la glace en mouvement. Lors de ces étapes, des images ont été extraites des vidéos acquises, elles ont été annotées selon la stratégie choisie et elles ont été utilisées pour entraîner les modèles. Finalement, la dernière étape consiste en l'inférence effectuée sur les données acquises à l'aide des modèles générés. Les images classifiées et les cartes de concentration obtenues à cette étape ont permis de générer des étendues de glace statique et des concentrations de frasil. La cohérence de ces résultats a été validée à l'aide de données externes. Plus de détails sur les étapes réalisées, comme les divers logiciels, plateformes et bibliothèques utilisés sont présentés dans les sections qui suivent.

### 4.1 Acquisition des données

L'acquisition des données s'est étalée du mois de décembre 2022 au mois de février 2023. Le but de la campagne terrain était d'acquérir des images optiques de la glace de rivière par drone. Les données météorologiques et les caméras en rive installées en bordure des rivières ont permis de déterminer les journées de prises des vidéos. Puisque les images capturées par les caméras en rive étaient accessibles à distance en temps quasi réel, il était possible d'avoir une idée des conditions de la rivière avant de se déplacer sur le site. Des températures froides, inférieures à  $-5^{\circ}\text{C}$ , étaient idéales. Les journées sans ou avec faibles précipitations et avec un vent faible ont également été ciblées afin de ne pas brouiller les images. L'acquisition des données s'est produite le matin (majoritairement entre 8h00 et 11h00) puisqu'il s'agit du meilleur moment pour voir le frasil et la glace de fond. Des défis sont survenus lors des journées très froides environnant  $-20^{\circ}\text{C}$ . Les batteries se déchargeaient rapidement et parfois la caméra du drone restait bloquée en position horizontale. Une fois le drone réchauffé dans la voiture, toutes ces fonctions redevenaient fonctionnelles et la prise de données pouvait reprendre. Plusieurs batteries avaient aussi été amenées pour ne pas être limitées par cet aspect. Le drone Mavic 3 de la compagnie DJI a été utilisé (Figure 19). Les caractéristiques de la caméra de ce drone sont présentées à l'annexe 1.

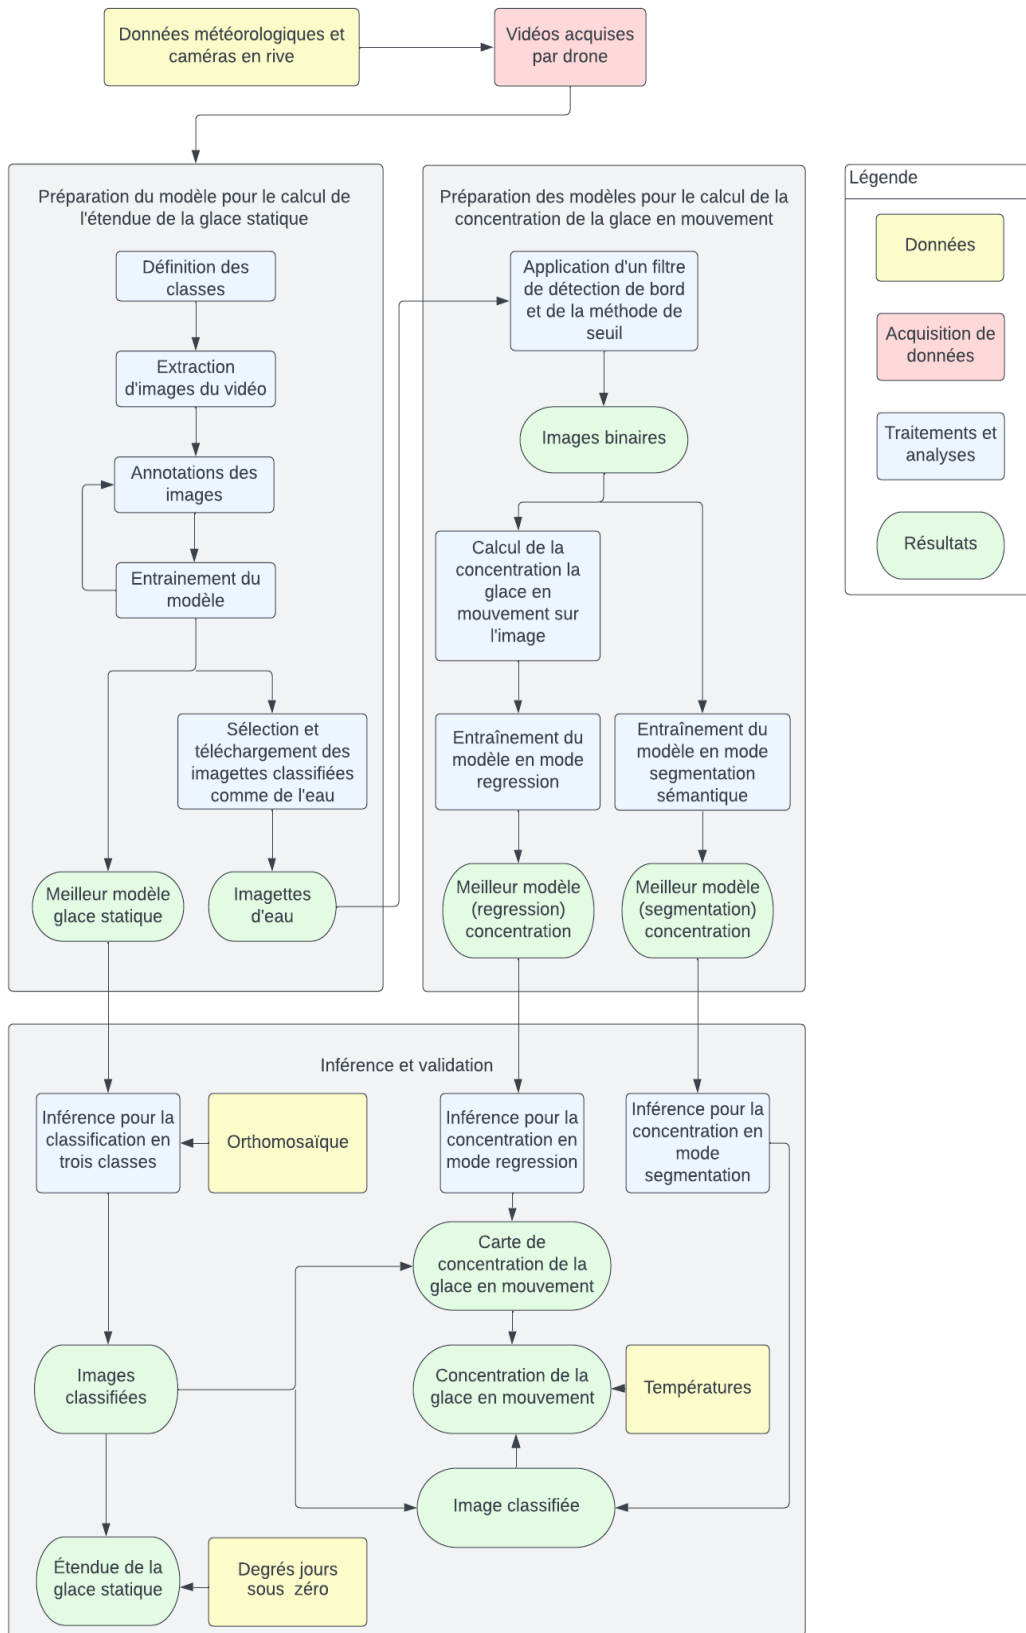



Figure 18 : Organigramme du projet.



**Figure 19 :** Matériel utilisé : (a) Deux cônes utilisés comme cibles, (b) un ruban à mesurer, (c) un drone Mavic 3, sa manette et son étui (photo prise par Victoria Litalien).

Les vols de drone se sont effectués de manière manuelle. Le drone a été positionné au centre de la rivière afin de capturer complètement la section de celle-ci. Afin de s'en assurer, un certain pourcentage des berges est inclus dans les images (environ 25% de l'image). Les vidéos ont été acquises avec une vue au nadir ( $90^\circ$  par rapport au plan d'eau). L'altitude est demeurée la plus constante possible pendant l'enregistrement des vidéos. La durée des vols stationnaires variait approximativement de 1 à 5 min en fonction de la capacité de la batterie. L'altitude a été déterminée en fonction de la largeur de la rivière. L'objectif était de voler à la plus basse altitude possible tout en capturant l'ensemble de la rivière. Deux cibles ont également été positionnées sur l'une des berges, le plus près de l'eau possible. La distance entre les deux cibles a été mesurée et prise en note afin de pouvoir faire la mise à l'échelle ultérieurement. Il n'a pas été nécessaire de géoréférencer les cônes puisque les images n'ont pas besoin d'être orthorectifiées grâce à la prise de vue au nadir. L'information requise pour les traitements est la résolution spatiale des pixels et la distance entre les deux cibles permet d'acquérir cette information. Les vidéos acquises lors de la campagne terrain sont présentées au Tableau 4. Les caractéristiques détaillées des vidéos sont présentées à l'annexe 2.

**Tableau 4 :** Vidéos acquises lors de la campagne terrain.

Site	Rivière	Date d'acquisition	Nombre de vidéos
C1	Coaticook	9, 10, 11, 12 et 17 janvier 2023	20
C2	Coaticook	14 décembre 2022, 9, 10, 11, 12 et 17 janvier 2023	31
C3	Coaticook	9, 10 et 11 janvier 2023	15
M1	Massawippi	10 janvier et 1 <sup>er</sup> février 2023	5
M2	Massawippi	1 <sup>er</sup> février 2023	6
M3	Massawippi	1 <sup>er</sup> février 2023	5
SF1	Saint-François	31 janvier 2023	2

## 4.2 Préparation du modèle pour le calcul de l'étendue de la glace statique

Le premier traitement a été d'entraîner un réseau de type SegNet à réaliser une segmentation sémantique selon trois classes : la glace statique, l'eau libre (incluant la glace en mouvement) et la classe « autres » qui regroupe tout le reste (rives, ponts, etc.). Des images ont tout d'abord été extraites des vidéos acquises lors de la campagne terrain et ont été annotées selon les trois classes. Par la suite, le modèle a pu être entraîné.

### 4.2.1 Préparation et annotation des images


Afin de généraliser le modèle, 14 vidéos (sur les 84 acquises) ayant des conditions différentes ont été sélectionnées. Tout d'abord, les vidéos ayant des problèmes de surexposition, de sous-exposition ou n'ayant aucune glace en mouvement ont été écartées. Par la suite, les vidéos ont été visionnées une à une. Au moins une vidéo par site a été sélectionnée. Si les conditions variaient d'une vidéo à l'autre pour le même site, les vidéos présentant des conditions nouvelles étaient ajoutées à la sélection. Certaines vidéos acquises n'ont donc pas été utilisées par souci d'éviter la redondance dans le choix d'images (spécialement considérant le temps nécessaire à l'annotation de celles-ci). Effectivement, les vidéos acquises lors d'une même journée terrain présentaient généralement les mêmes conditions puisqu'elles étaient acquises à quelques minutes d'intervalle. Par contre, au site C1 (Figure 16), plusieurs vidéos ont été sélectionnées pour une même journée puisqu'à certains moments, il était possible de visionner des morceaux de glace de fond en train de se détacher. Il a donc été jugé pertinent d'inclure ces images dans l'entraînement des modèles. Les caractéristiques des vidéos choisis sont présentées au Tableau 5.

**Tableau 5 :** Vidéos sélectionnées pour l'extraction d'images.

Site	Date d'acquisition	Nombre de vidéos	Durée (secondes)
C1	11 janvier 2023	4	71, 108, 229, 229
C2	14 décembre 2022, 10, 12 et 17 janvier 2023	4	49, 69, 183, 185
C3	10 janvier 2023	1	92
M1	1 février 2023	1	61
M2	1 février 2023	2	49 et 58
M3	1 février 2023	1	116
SF1	31 janvier 2023	1	45

Pour chacune de ces vidéos, une image a été extraite à toutes les secondes pour un total de 907 images. L'extraction a été réalisée grâce à la librairie *OpenCV* (Bradski, 2000). En tout, 24 images présentant des conditions et des types de glaces différents ont été choisies pour l'annotation afin d'éviter la redondance dans le choix des images. L'annotation a été effectuée avec la plateforme

*Segment.ai*<sup>1</sup> (Figure 20). Celle-ci possède un outil d'annotation *superpixels* qui facilite grandement le processus. L'algorithme *superpixels* segmente l'image d'entrée en regroupant les pixels d'une même région selon leur similarité. Pour déterminer la similarité des pixels, des critères de couleurs, de textures et de géométries peuvent par exemple être pris en compte. Les regroupements de pixels créés par l'algorithme sont alors désignés comme des *superpixels*. En bref, les *superpixels* réduisent la complexité de l'image en identifiant la redondance présente dans celle-ci (Achanta *et al.*, 2012). Les *superpixels* créés par l'algorithme ont été utilisés pour produire l'annotation. L'annotation créée pour chaque image, appelée ici masque, a été utilisée pour entraîner le modèle à reconnaître les différentes classes (section 4.2.2). C'est à l'aide de ces masques que le modèle apprend les caractéristiques de chaque classe et peut générer des prédictions sur de nouvelles images.



**Figure 20 :** Interface de *Segment.ai*. Les lignes blanches représentent les contours des *superpixels* générés par le logiciel. La taille des *superpixels* est ajustable avec l'outil (en haut à gauche). En cliquant sur un *superpixel*, il est alors possible d'indiquer la classe associée (polygone bleu). Des outils de type brosse et polygone sont aussi disponibles pour effectuer des ajustements.

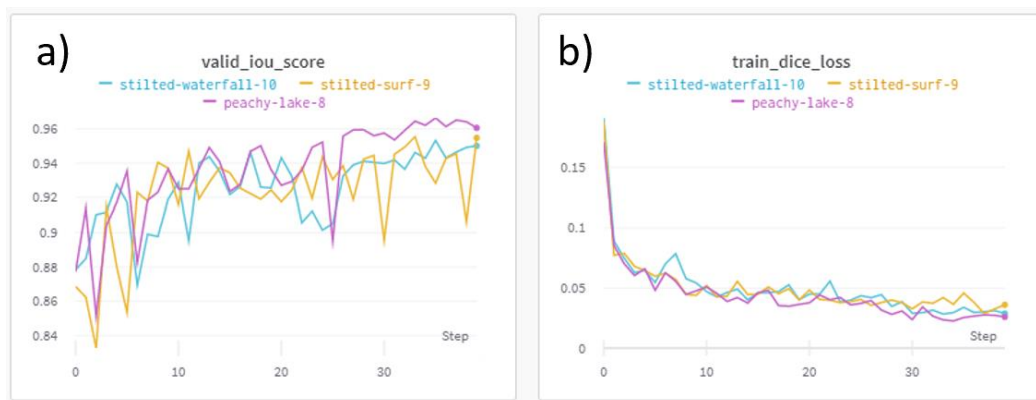
#### 4.2.2 Entraînement du modèle

Le modèle a été entraîné sur la plateforme *Google Colab*<sup>2</sup> avec la librairie *Segmentation Model PyTorch* (Lakubovskii, 2019). L'architecture Unet (Ronneberger *et al.*, 2015) a été utilisée. Les images ont été découpées en imagerie de 448 pixels par 448 pixels, pour un total de 2 295 imagerie. Le même procédé a été appliqué pour les masques. Une portion de ces imagerie (1 836) a été utilisée pour l'entraînement du modèle et le reste (459) a été conservé pour la validation du modèle. Afin d'augmenter le jeu de données et d'éviter le surentraînement, des techniques

<sup>1</sup> <https://segments.ai/>

<sup>2</sup> <https://colab.research.google.com/>

d'augmentation ont été appliquées (retournement horizontal, retournement vertical et rognage aléatoire) avec la librairie *Albumentations* (Buslaev *et al.*, 2020). Ensuite, le modèle a été entraîné. Ici, seulement la partie du décodeur a été entraînée puisque l'encodeur (Resnet-18) est resté gelé pendant l'entraînement. L'entraînement s'est effectué pendant 40 époques. Un modèle est généralement entraîné jusqu'à ce que les résultats soient satisfaisants et ne s'améliorent plus. Le nombre d'époques d'entraînement peut donc varier pour chaque cas. La plateforme *Weights and Biases*<sup>3</sup> a été utilisée afin de suivre les résultats de chacune des époques, dont l'IoU moyen et la fonction de perte (Figure 21). Le logiciel permet aussi d'enregistrer les paramètres utilisés pour chaque entraînement, ce qui permet de voir les effets d'une modification de ceux-ci sur les résultats. Une fois les 40 époques complétées, le meilleur modèle obtenu a été sauvegardé. Finalement, les imageries composées uniquement de la classe eau libre ont été téléchargées. Elles ont été utilisées ultérieurement pour le calcul de la concentration de la glace en mouvement (section 4.3).



**Figure 21** : Suivi des différentes métriques d'évaluation de l'entraînement du modèle sur le logiciel *Weights and Biase* : (a) l'*Intersection over Union* moyen et (b) la fonction de perte selon les époques. Les courbes de couleurs représentent chacune un entraînement différent.


### 4.3 Préparation des modèles pour le calcul de la concentration de la glace en mouvement

L'objectif du deuxième traitement était d'entraîner un CNN afin d'obtenir la concentration de glace en mouvement présente dans l'image. Un CNN a été entraîné selon deux approches différentes : la segmentation sémantique et la régression. Dans les deux cas, le CNN a été entraîné à partir des imageries classifiées comme de l'eau lors du traitement précédent (section 4.2.2). Ces imageries ont dû être annotées au préalable.

<sup>3</sup> <https://wandb.ai/site>

### 4.3.1 Préparation des imagerie

45 imagerie classifiées comme de l'eau (section 4.2.2) ont été traitées dans *GIMP*<sup>4</sup>, un logiciel de traitement d'image gratuit. Une fois l'imagerie (Figure 22a) téléchargée dans le logiciel, un filtre de détection de bord *Sobel* a été appliqué sur celle-ci afin de faire ressortir les contours de la glace (Figure 22b). Par la suite, la méthode de seuil (section 2.3.1) a été appliquée sur chaque image manuellement afin de créer une image binaire (Figure 22c) la plus représentative de l'image de base (Figure 22a). En d'autres mots, le seuil séparant les niveaux de gris de l'imagerie (Figure 22b) a été déterminé visuellement en l'ajustant jusqu'à l'obtention du résultat désiré (Figure 22c). De cette manière, la segmentation de l'image se faisait relativement rapidement. L'algorithme *superpixel* de la plateforme *Segment.ai* utilisée précédemment (section 4.2.1) ne parvenait pas à détecter les contours du frazil.



**Figure 22 :** Traitements appliqués sur (a) une imagerie classifiée comme de l'eau par le premier modèle : (b) filtre Sobel de détection de contours et (c) méthode de seuil manuelle.

Pour calculer la concentration de glace dans une imagerie, le ratio du nombre de pixels blancs par rapport au nombre de pixels noir a été effectué à l'aide de l'histogramme et de l'outil *Sélection par couleur* de *GIMP*. La concentration de glace présente sur chaque imagerie a été inscrite dans un fichier Excel.

### 4.3.2 Entraînement du modèle en mode segmentation sémantique

L'entraînement du modèle de type segmentation sémantique pour calculer la concentration de la glace est semblable à l'entraînement effectué à la section 4.2.2. L'architecture Unet a également été utilisée. Les images binaires sont les annotations des imagerie, donc les masques. Comme

---

<sup>4</sup> <https://www.gimp.org/>



mentionné plus tôt, les masques permettent au modèle de reconnaître les caractéristiques de chaque classe et donc de faire des prédictions sur de nouvelles images. Une portion des imagerie (34) a été utilisée pour l'entraînement du modèle et le reste (9) a été conservé pour la validation du modèle. Par la suite, des techniques d'augmentation de données ont été appliquées (retournement horizontal, retournement vertical et rognage aléatoire) avec la librairie *Albumentations*. Le modèle a par la suite été entraîné durant 40 époques et les métriques d'évaluation ont été obtenues à l'aide du logiciel *wandb.ai*. À la suite de l'entraînement, le meilleur modèle obtenu en validation a été téléchargé.

### **4.3.3 Entraînement du modèle en mode régression**

En mode régression, le CNN (ResNet-18 ici) est entraîné pour prédire une valeur numérique pour chacune des images présentées. Contrairement à la segmentation sémantique qui produit une image classifiée eau/glace, la régression produit directement la valeur de concentration de glace présente sur l'image. Le modèle a donc été entraîné à l'aide des images et de leur valeur de concentration associée (calculée à la section 4.3.1). Une portion des imagerie (34) a été utilisée pour l'entraînement du modèle et le reste (9) a été conservé pour la validation du modèle. La fonction de coût est la distance L1 entre la concentration estimée et la concentration cible. Le modèle a été entraîné pendant 200 époques et les métriques d'évaluation ont été obtenues à l'aide du logiciel *wandb.ai*. À la suite de l'entraînement, le meilleur modèle obtenu en validation a été téléchargé.

## **4.4 Inférence**

Six images ont été sélectionnées pour former le jeu de données de test, dont 4 acquises sur la rivière Coaticook (site C2), une acquise sur la rivière Massawippi (site M3) et une sur la rivière Saint-François (site SF1). Les images de la Coaticook ont été acquises les 10, 11, 12 et 17 janvier 2023. L'image de la Saint-François a été acquise le 31 janvier 2023 et celle de la Massawippi a été acquise le 1<sup>er</sup> février 2023. Les images sélectionnées pour l'inférence n'ont pas été utilisées ni pour l'entraînement ni pour la validation des modèles. Par contre, elles peuvent provenir des mêmes vidéos que les images utilisées pour ces deux étapes. C'est sur ces six images que l'inférence a été effectuée en trois temps. Premièrement, pour calculer l'étendue de la glace statique, le premier modèle prenait les images extraites des vidéos en entrée et les classifiait en trois classes (glace statique, eau libre et autres). Par la suite, pour calculer la concentration de glace en mouvement dans l'eau, l'inférence s'est faite à partir du modèle entraîné en mode régression et du modèle



entraîné en mode segmentation sémantique. Seulement les pixels classifiés dans la catégorie eau libre par le premier modèle ont été pris en compte pour ces deux dernières étapes.

#### **4.4.1 Quantification de l'étendue du couvert de glace**

L'inférence pour la quantification de l'étendue du couvert de glace a d'abord été effectuée sur les images du jeu de données tests. Par la suite, l'inférence a été tentée sur une orthomosaique acquise au site C2 le 1<sup>er</sup> février dans le cadre d'un autre projet. L'orthomosaique a été acquise et traitée par Jason Duguay (Responsable de recherche, Université de Sherbrooke). Les images ont été acquises avec le même drone qu'utilisé pour les vidéos, soit le Mavic 3 de la compagnie DJI (spécificités techniques à l'annexe 1). Contrairement au drone Mavic 3 Entreprise, le modèle spécifique de drone utilisé ne possède pas l'option de programmer un plan de vol. Le vol a été effectué de manière manuelle. Le drone a fait un aller-retour sur les rives en volant à 100 m d'altitude à une vitesse de 5 m/s. Une image a été acquise à chaque 2 secondes pour un total de 85 images. Pour réaliser l'orthomosaique, les images ont été traitées dans le logiciel *OpenDroneMap*<sup>5</sup>.

Une technique d'inférence en imagerie multiples a été utilisée. C'est-à-dire que l'image complète a été divisée en plusieurs imagerie, puis les imagerie ont été segmentées individuellement par le réseau. Les imagerie ont par la suite été combinées pour afficher le résultat final. Une fois l'image classifiée, le nombre de pixels attribués à chaque catégorie peut être obtenu. Le nombre de pixels classifiés comme étant de la glace statique combiné à la résolution spatiale de l'image a permis de calculer l'étendue de la glace statique. La résolution spatiale de l'image a été obtenue grâce à la mesure de distance entre les deux cônes présents sur les images et l'outil de mise à l'échelle du logiciel *Fudaa-LSPIV*<sup>6</sup>. Afin de valider la cohérence des résultats, l'évolution de l'étendue de la glace statique a également été comparée aux degrés-jours sous zéro. Comme le mentionne Prowse et Beltaos (2007), la croissance de la glace fluviale est largement influencée par les changements de la température de l'air. En combinant la loi de Stefan et les degrés-jours sous zéros cumulés, il est d'ailleurs possible d'estimer l'épaisseur de la glace. C'est pour cela qu'il a été jugé pertinent de valider les résultats en les comparant aux degrés-jours sous zéros cumulés. Ceux-ci ont été obtenus à partir des données climatiques du ministère de l'Environnement, de la Lutte contre les changements climatiques, de la Faune et des Parcs. Les données de la station Coaticook (No.

---

<sup>5</sup> <https://opendronemap.org/>

<sup>6</sup> <https://forge.irstea.fr/projects/fudaa-lspiv/news>

7021840) ont été utilisées. À partir du 14 novembre 2023 (première journée ayant une température moyenne sous zéro), les températures moyennes ont été additionnées afin d'obtenir les degrés-jours sous zéros des dates de la série temporelle. Une carte du score du réseau pour chaque image classifiée a aussi été générée.

#### **4.4.2 Concentration totale de la glace en mouvement**

La concentration totale de la glace en mouvement a été calculée à l'aide des deux modèles générés (segmentation/régression). Seulement les pixels classifiés comme de l'eau par le premier modèle sont pris en compte dans ces étapes. Les inférences en imagerie multiples ont été effectuées sur les mêmes images qu'utilisées à la section 4.4.1.


En ce qui concerne la segmentation sémantique, une fois l'inférence réalisée, on obtient une image classifiée en deux catégories : eau et glace en mouvement. Par la suite, le nombre de pixels associé à la classe glace en mouvement a été obtenu. Le ratio entre ce nombre et le nombre total de pixels (eau et glace en mouvement) a été effectué afin d'obtenir la concentration de la glace en mouvement. Quant à l'approche par régression, on obtient une carte de concentration. La carte de concentration fournit un pourcentage de concentration pour chacune des sections de l'image. Pour obtenir la concentration totale de l'image, et non de chacune des sections, la somme des concentrations de toutes les sections est obtenue. Par la suite, cette somme est multipliée par le pourcentage d'occupation de chaque section. De cette manière, le pourcentage total de glace en mouvement présente sur l'image est obtenu. Par la suite, les résultats des concentrations issues des deux méthodes ont été comparés aux températures minimales de la nuit ou du matin précédant l'acquisition et aux températures au moment de l'acquisition. Les données de températures proviennent de la station météorologique de Sherbrooke d'Environnement et Changement Climatique Canada.

## **5 Résultats**

### **5.1 Étendues du couvert de glace**

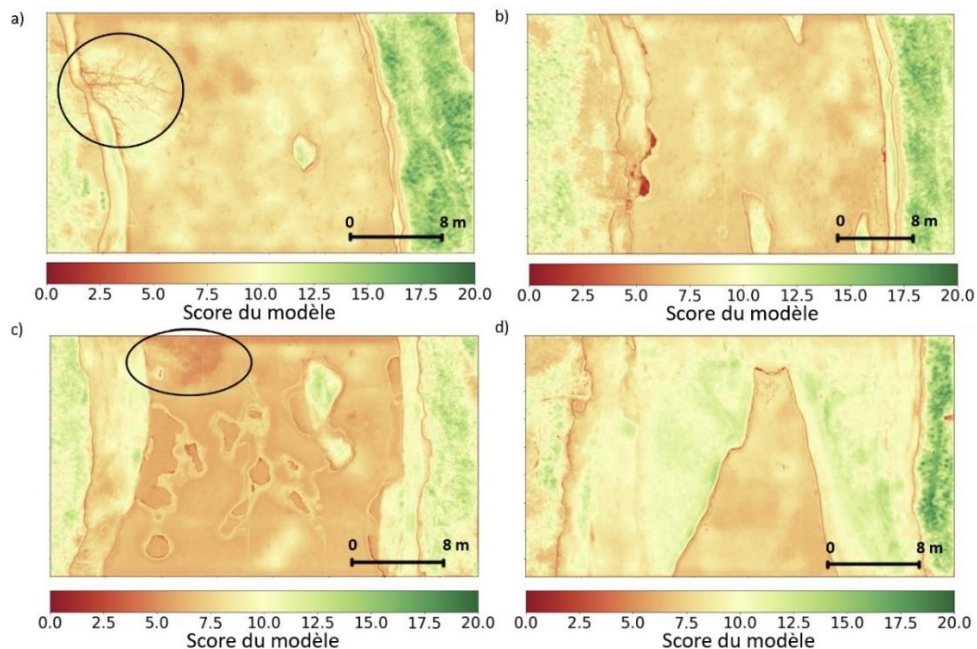
Le premier modèle entraîné est celui permettant de segmenter les images en trois catégories : l'eau libre (incluant la glace en mouvement), la glace statique et tous les autres éléments. Le meilleur modèle a obtenu un IoU moyen de 96% lors de l'étape de validation.

À la Figure 23, la classification des quatre images de la série temporelle acquises sur la rivière Coaticook est présentée. En ayant la segmentation superposée en transparence à l'image originale, il est possible de visuellement identifier les erreurs du modèle. Sur l'image du 10 janvier (Figure 23a), dans le coin supérieur droit, une partie de la rive enneigée a faussement été classifiée comme de la glace statique. La neige est présente sur les rives et sur le couvert de glace. Cette similarité peut expliquer la confusion entre les deux classes. Sur l'image du 12 janvier (Figure 23c), de l'eau libre a faussement été classifiée comme de la glace statique. La confusion entre la classe eau libre et glace statique pourrait être expliquée par la présence de glace en mouvement dans l'écoulement. L'étendue de la glace statique sur l'image du 10 janvier et l'image du 12 janvier sera alors surestimée. Sur l'image du 11 janvier (Figure 23b), il existe une zone de confusion entre la glace statique et la rive. À cet endroit, le couvert de glace près de la rive est enneigé. Sur l'image du 17 janvier (Figure 23d) quelques pixels de glace statique ont été classifiés comme de l'eau libre. L'étendue de la glace statique sur ces deux images sera alors légèrement sous-estimée.



**Figure 23 :** Résultats de la segmentation sémantique effectuée par le modèle (inférence en imagerie multiples) superposés en transparence au jeu de données de test. Les images ont été acquises sur la rivière Coaticook au site C2 (a) le 10 janvier 2023, (b) le 11 janvier 2023, (c) le 12 janvier 2023 et le (d) 17 janvier 2023. Les zones jaunes ont été classifiées dans la catégorie autres, les zones turquoise ont été classifiées comme de la glace statique et les zones bleues ont été classifiées comme de l'eau libre (incluant la glace en mouvement). Les pixels noirs n'ont pas été classifiés par le modèle. Les zones encerclées en rouge indiquent des erreurs de classification.

À la Figure 24, la confiance du réseau vis-à-vis des segmentations produites est présentée sous forme de cartes de scores. Ces cartes sont obtenues à l'aide de la fonction *logit* de la librairie *Pytorch* appelée logarithme de la confiance (Pytorch, s.d.). Cette fonction retourne des valeurs entre -infini et +infini indiquant le score du réseau. Plus la valeur est élevée, plus le modèle est confiant face à la segmentation réalisée. Il est possible de remarquer que les zones les plus critiques des images sont les frontières entre les classes. À ces endroits, le score du réseau est à son plus faible. L'arbre en surplomb de la rivière, présent sur la Figure 24a, pose également problème. Lors de l'entraînement, des images d'arbres ont été incluses dans les trois classes. Comme on peut le voir à la Figure 23a, l'arbre commence sur la rive et ses branches passent au-dessus de la glace statique et finissent au-dessus de l'eau libre. Puisque le modèle a appris à associer les caractéristiques des arbres aux trois classes, il semble normal qu'il ne soit pas confiant dans sa classification. Le score associé à l'ombre produite par l'arbre sur la Figure 24c est également faible. Le modèle est assez confiant par rapport à la classification des rives puisqu'elles tirent généralement vers le vert (score élevé). Les zones d'eau libre semblent plus problématiques, possiblement puisqu'elles incluent la glace en mouvement qui peut être confondue avec la glace statique.



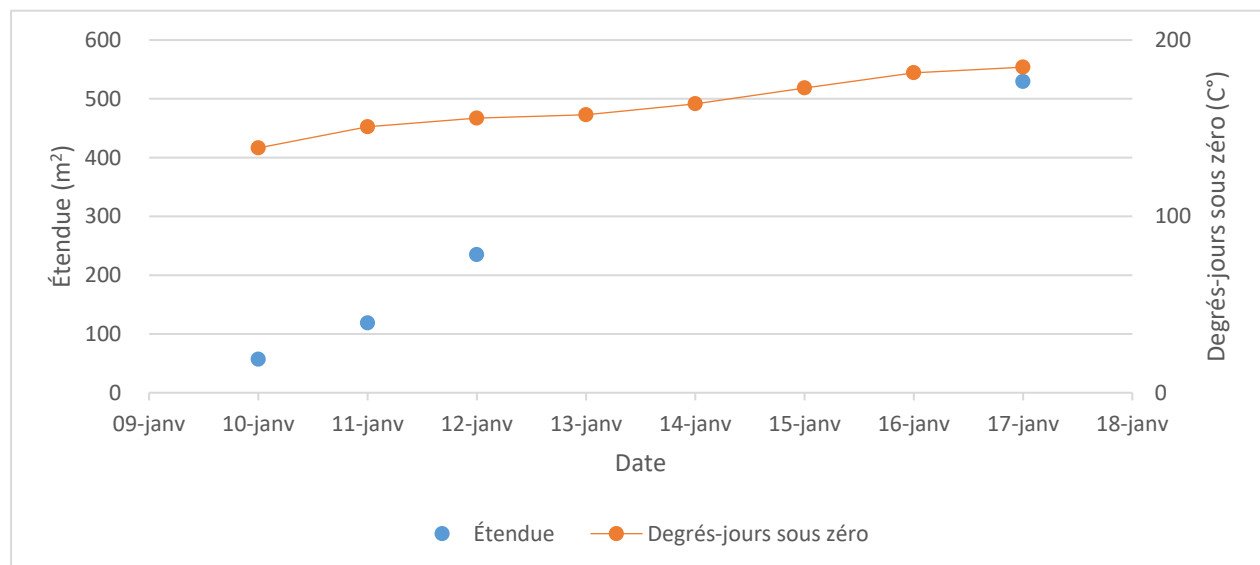
**Figure 24 :** Cartes de scores des segmentations obtenues lors de l'inférence (imagerie multiples) des images acquises (jeu de données de test) sur la rivière Coaticook au site C2 (a) le 10 janvier 2023, (b) 11 janvier 2023, (c) 12 janvier 2023 et (d) 17 janvier 2023. Les zones encerclées en noir indiquent l'emplacement d'arbre ou d'ombre projetée par un arbre.

À l'aide du nombre de pixels attribués à chaque classe ainsi que la résolution de l'image, l'étendue du couvert de glace pour chaque image de la série temporelle a été obtenue (Tableau 6). On peut y voir que l'étendue de glace augmente d'une date à l'autre en passant de 56,81 m<sup>2</sup> à 529,44 m<sup>2</sup> entre le 10 et le 17 janvier 2023 respectivement.

**Tableau 6 :** Nombre de pixels par classes et résultats du calcul de l'étendue du couvert de glace selon l'image de la série temporelle acquise sur la rivière Coaticook au site C2.

Site	Date	Non classifié (nb pixels)	Eau libre (nb pixels)	Glace statique (nb pixels)	Autres (nb pixels)	Résolution de l'image (cm)	Étendue de la glace statique (m <sup>2</sup> )
C2	10 janvier 2023	8 161	5 247 061	603 829	2 435 349	0,97	56,81
C2	11 janvier 2023	9 560	4 474 997	866 967	2 942 876	1,17	118,68
C2	12 janvier 2023	8 158	4 253 783	2 257 996	1 774 463	1,02	234,72
C2	17 janvier 2023	12 210	1 520 455	5 190 064	1 571 671	1,01	529,44

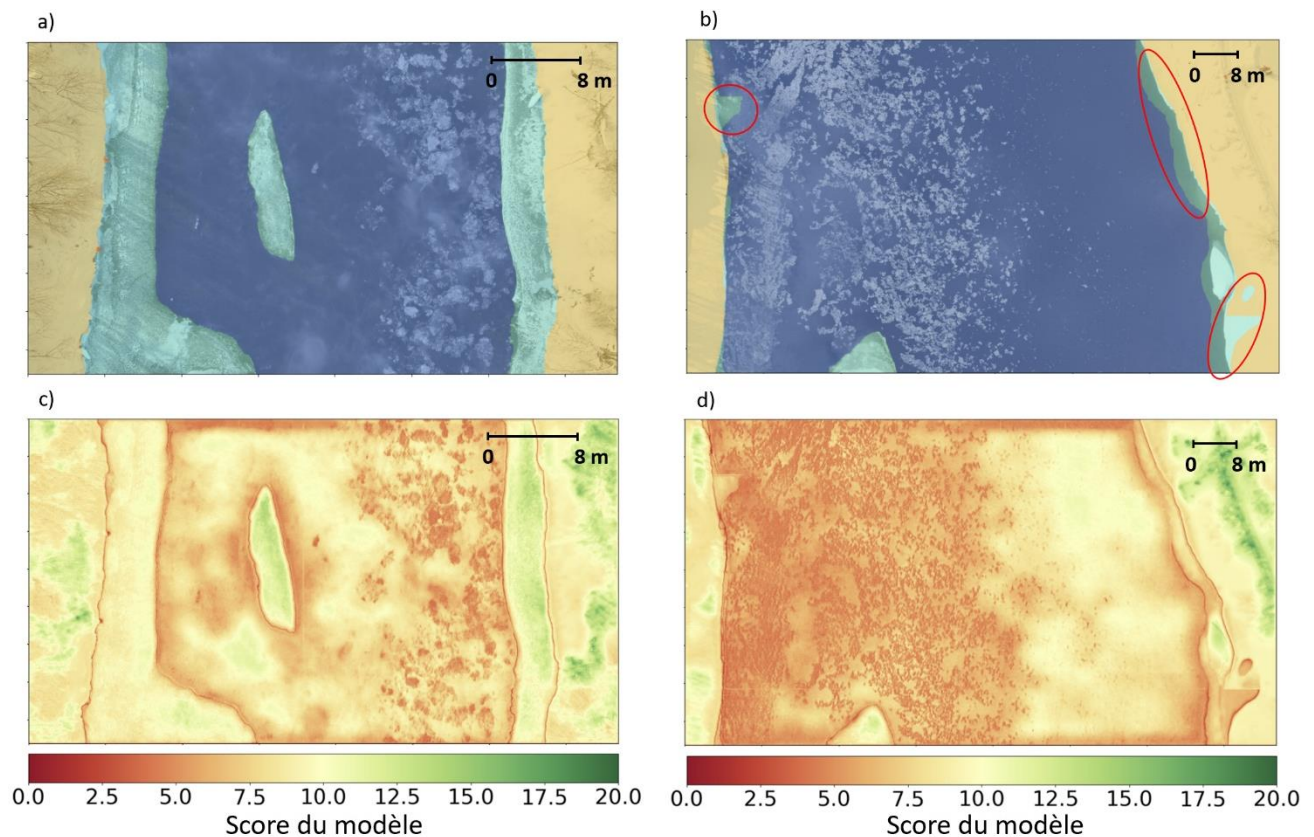
En comparant les résultats d'étendue de glace avec les degrés-jours sous zéro cumulés, on constate une relation entre les deux (Figure 25).



**Figure 25 :** Comparaison de l'évolution de l'étendue du couvert de glace entre le 10 et 17 janvier 2023 au site C1 avec les degrés-jours sous zéros cumulés.



Une image acquise sur la rivière Massawippi (site M3) et une image acquise sur la rivière Saint-François (site SF1) ont été segmentées afin de tester la généralisation du modèle sur d'autres rivières. Sur l'image de la rivière Massawippi (Figure 26a), on ne retrouve aucune erreur majeure alors que sur l'image de la rivière Saint-François (Figure 26b), certaines zones sont classifiées comme de la glace statique alors qu'elles devraient l'être comme de l'eau ou des rives. En observant les cartes de scores (Figure 26c et Figure 26d), on note que le modèle possède un bas niveau de confiance concernant la segmentation de la glace en mouvement (inclut dans la classe eau libre). De plus, tout comme pour la segmentation de la série temporelle, le score du modèle est plus faible aux frontières des classes. Le score du réseau quant à la glace statique et la classe autres semble plus élevé que pour la classe eau libre.



**Figure 26 :** Résultats de la segmentation effectuée par le modèle (inférence en imagerie multiple) superposés en transparence au jeu de données de test. Les images ont été acquises (a) sur la rivière Massawippi au site M3 le 1<sup>er</sup> février 2023 et (b) sur la rivière Saint-François au site SF1 le 31 janvier 2023. Les zones jaunes ont été classifiées dans la catégorie autres, les zones turquoise ont été classifiées comme de la glace statique et les zones bleues ont été classifiées comme de l'eau libre (incluant la glace en mouvement). Les pixels noirs n'ont pas été classifiés par le modèle. Les zones encadrées en rouge indiquent des erreurs de classification. Cartes de scores (c) du résultat de la rivière Massawippi et (d) du résultat de la rivière Saint-François.

À la suite de la segmentation des images, le nombre de pixels par classe a pu être obtenu. En fonction de ces valeurs et de la résolution de l'image, l'étendue de glace statique a été calculée (Tableau 7). On note que la résolution de l'image prise sur la rivière Massawippi est plus élevée que celle de l'image prise sur la rivière Saint-François. En effet, puisque la rivière Saint-François est plus large que la rivière Massawippi, le vol de drone a dû s'effectuer à une altitude plus élevée pour capter l'ensemble de la rivière. L'étendue de la glace statique obtenue pour l'image acquise sur la rivière Massawippi s'élève à 321,40 m<sup>2</sup>. Celle obtenue pour l'image acquise sur la rivière Saint-François s'élève à 334,97 m<sup>2</sup>.


**Tableau 7 :** Nombre de pixels par classes et résultats du calcul de l'étendue du couvert de glace pour l'image acquise sur la rivière Massawippi au site M3 et l'image acquise sur la rivière Saint-François au site SF1.

Site	Date	Non classifié (nb pixels)	Eau libre (nb pixels)	Glace statique (nb pixels)	Autres (nb pixels)	Résolution de l'image (cm)	Étendue de la glace statique (m <sup>2</sup> )
M3	1 <sup>er</sup> février 2023	8 160	4 450 6315	1 789 949	1 989 976	1,34	321,40
SF1	31 janvier 2023	8 187	6 348 490	415 306	1 522 417	2,84	334,97

Ensuite, l'inférence a été tentée sur une orthomosaïque prise sur la rivière Coaticook (site C2) dans le cadre d'un autre projet. L'inférence sur une orthomosaïque présentait des défis puisque le format et la résolution ne sont pas les mêmes que les images utilisées pour l'entraînement du modèle. De plus, plusieurs éléments (ombrage, route, couvert de glace enneigé) présents sur l'orthomosaïque (Figure 27) n'étaient pas ou peu représentés dans le jeu de données utilisées pour l'entraînement du modèle.

On observe beaucoup de confusion entre les différentes classes, particulièrement entre la glace statique et les rives (Figure 27). Les ombrages, les champs agricoles et la neige recouvrant entièrement le couvert de glace peuvent poser problème puisqu'il n'y a pas ou peu d'exemple dans le jeu de données d'entraînement. La zone d'eau libre sur l'image est celle ayant été la mieux délimitée. Il serait donc tout de même possible d'utiliser le modèle pour délimiter le front de glace et caractériser son évolution. La route, par contre, a été faussement classifiée comme de l'eau. Encore une fois, une telle infrastructure n'a pas été incluse dans le jeu de données d'entraînement,

ce qui peut expliquer l'erreur. Puisque la segmentation s'est avérée infructueuse, aucune donnée d'étendue du couvert de glace n'a été calculée.




**Figure 27** : Résultats de la segmentation effectuée par le modèle (inférence en imagerie multiples) superposés en transparence à une orthomosaïque acquise sur la rivière Coaticook (C2) dans le cadre d'un autre projet. Les zones jaunes ont été classifiées dans la catégorie autres, les zones turquoise ont été classifiées comme de la glace statique et les zones bleues ont été classifiées comme de l'eau libre (incluant la glace en mouvement). Les pixels noirs n'ont pas été classifiés par le modèle. Les cercles rouges identifient les erreurs de classification importantes.

## 5.2 Concentration totale de la glace en mouvement

Pour générer la concentration totale de la glace en mouvement, deux modèles ont été entraînés et comparés. Le modèle généré pour segmenter l'eau de la glace en mouvement a obtenu un IoU moyen de 82% lors de l'étape de la validation. Pour sa part, lors de l'étape de la validation, le modèle entraîné en mode régression pour produire une valeur de concentration a obtenu une distance L1 (différence entre la prédiction et la vraie valeur) de 2%. Selon ces chiffres, le modèle entraîné par régression fournirait des mesures de concentration de glace en mouvement plus précises que le modèle entraîné en segmentation sémantique.




Pour le calcul de la concentration de la glace en mouvement, l'inférence a été effectuée selon les deux approches. Les mêmes images qu'à l'étape du calcul de l'étendue de la glace statique ont été utilisées (section 5.1). La Figure 28 illustre la segmentation eau/glace en mouvement des images de la série temporelle acquise sur la rivière Coaticook (site C2). Comme il est possible de le voir à la Figure 28a et Figure 28c, la présence d'arbres surplombant la rivière ou d'ombres projetées par ceux-ci est problématique. En effet, le modèle classe ces éléments comme de la glace en mouvement. La concentration calculée à partir de la segmentation semble donc surestimée. Il est intéressant de noter que le frazil présent sur les images de la rivière Coaticook est principalement sous forme de *slush* tandis que le frazil présent sur les rivières Massawippi et Saint-François est plutôt sous forme de radeaux. La rivière Coaticook serait donc une zone de production de frazil tandis que les deux autres rivières seraient des zones de transports de frazil. Les segmentations sémantiques des images acquises sur la rivière Massawippi et la rivière Saint-François sont illustrées à la Figure 29.



**Figure 28** : Segmentation sémantique (inférence en imagerie multiple) pour le calcul de la concentration de la glace en mouvement de la série temporelle (jeu de données de test) acquise sur la rivière Coaticook (site C2) (a) le 10 janvier 2023, (b) 11 janvier 2023, (c) le 12 janvier 2023 et (d) le 17 janvier 2023. Les pixels classifiés comme de l'eau sont en bleu et les pixels classifiés comme de la glace en mouvement sont en rouge. Les zones encadrées en blanc indiquent les arbres surplombant la rivière ou les ombres créées par ceux-ci ayant été classifiées comme de la glace en mouvement.

À la Figure 29, il est possible de remarquer que l'eau située entre les radeaux de frazil peut être classifiée comme de la glace en mouvement. De plus, la surface des segments de la classe glace en mouvement déborde légèrement des frontières réelles des radeaux de frazil. Les concentrations obtenues à partir de ces images seront alors aussi probablement surestimées. Par contre, il est intéressant de remarquer que le modèle ne confond pas la glace statique avec la vapeur d'eau présente sur l'image acquise sur la rivière Massawippi (Figure 29a). La vapeur d'eau est répartie sur l'ensemble de la Figure 29a et se distingue par sa couleur bleue plus pâle. La superficie obtenue selon les classes pour les six images segmentées est présentée au Tableau 8.



**Figure 29** : Segmentation sémantique (inférence en imagerie multiple) pour le calcul de la concentration de la glace en mouvement sur un jeu de données de test. (a) Image acquise sur la rivière Massawippi (site M3) et (b) image acquise sur la rivière Saint-François (site SF1). Les pixels classifiés comme de l'eau sont en bleu et les pixels classifiés comme de la glace en mouvement sont en rouge.

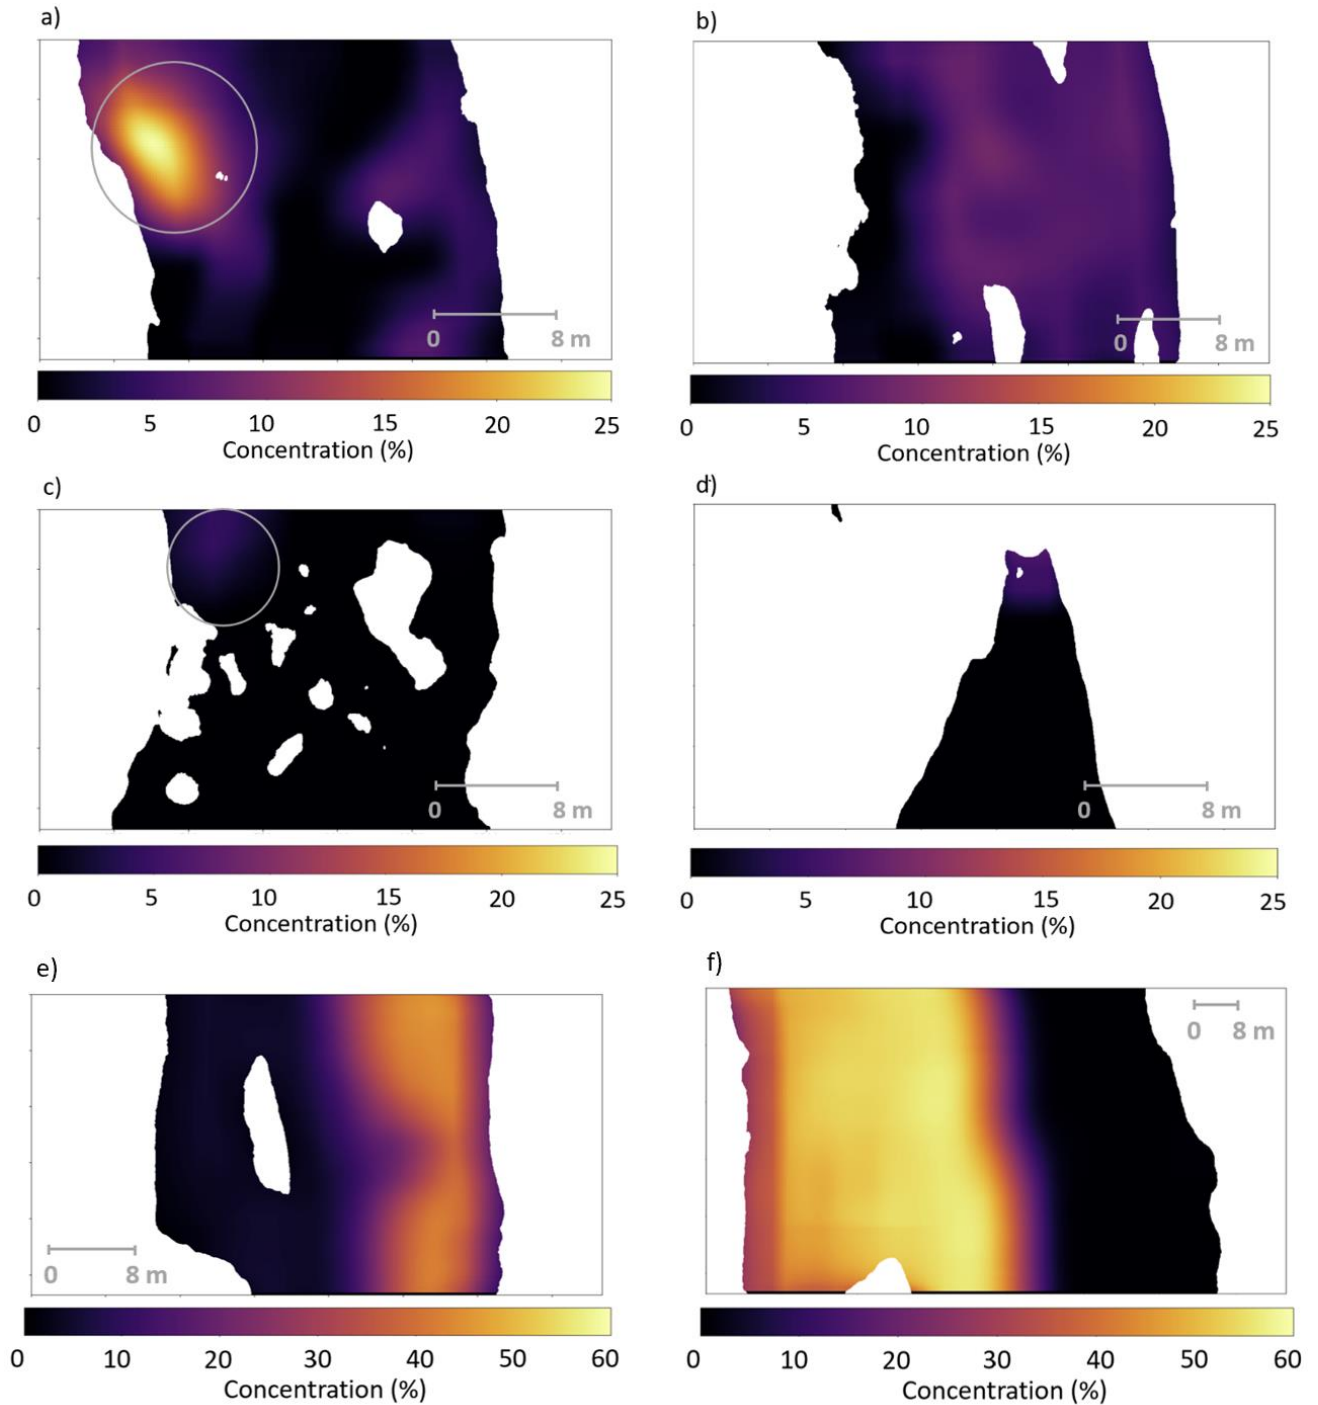
Les images du site SF1 et M3 sont celles ayant la plus grande superficie de glace en mouvement (Tableau 8).

**Tableau 8** : Superficie (m<sup>2</sup>) par classes selon l'image inférée.

Site	Date	Eau (m <sup>2</sup> )	Glace en mouvement (m <sup>2</sup> )	Non classifié (m <sup>2</sup> )
C2	10 janvier 2023	432,58	60,80	287,04
C2	11 janvier 2023	587,28	26,01	522,13
C2	12 janvier 2023	402,45	14,13	446,38
C2	17 janvier 2023	147,34	9,95	688,82
SF1	31 janvier 2023	3 002,76	2 128,33	1 558,84
M3	1 <sup>er</sup> février 2023	545,62	264,10	679,62

La deuxième approche utilisée pour calculer la concentration de la glace en mouvement est celle de la régression. Ici, à la place d'une image segmentée, on obtient une carte de concentration. Les cartes de concentration obtenues pour les différentes images acquises sur la rivière Coaticook (site C2), la rivière Massawippi et la rivière Saint-François sont illustrées à la Figure 30. Sur l'ensemble des cartes de concentration de la rivière Coaticook, la concentration n'est pas élevée. Cela est logique puisque le frasil était présent à seulement quelques endroits sous forme de *slush*. La présence d'arbre surplombant la rivière est encore une fois problématique. Effectivement à la Figure 30a, la concentration est élevée à l'endroit où se situe l'arbre de même qu'à l'endroit où se situe l'ombrage produit par l'arbre (Figure 29c). Sur les cartes de concentration des images acquises sur les rivières Massawippi et Saint-François (Figure 30e et Figure 30f) les niveaux de concentration sont beaucoup plus élevés. Les zones de concentrations élevées sur les Figure 30e et Figure 30f correspondent aux endroits où on retrouve une grande quantité de radeaux de frasil sur les images de base.

Pour chacune des deux approches (segmentation sémantique et régression), les valeurs de concentration totale de chaque image ont pu être obtenues. Ces valeurs sont illustrées et comparées au Tableau 9. Les concentrations obtenues à l'aide des deux méthodes ont des différences importantes. Effectivement, la différence entre les résultats des deux méthodes varie de 0,78% à 15,21% selon l'image traitée. Puisque le modèle de segmentation a obtenu un IoU de 82% et que le modèle de segmentation une distance L1 de 2% sur le jeu de données de test, les résultats issus de la régression paraissent plus fiables. De plus, puisque l'eau située entre plusieurs radeaux de frasil est parfois classifiée comme de la glace en mouvement et que le contour des segments semble déborder des contours réels des radeaux, la concentration issue de cette technique peut être surestimée. D'ailleurs, les images ayant les plus fortes concentrations de glace en mouvement sont celles ayant les différences de valeurs entre les deux méthodes les plus élevées.



**Figure 30 :** Cartes de concentration (inférence en imagerie multiple) des différentes images (jeu de données de test) acquise sur les trois rivières à l'étude. Cartes de concentration de la rivière Coaticook (site C2) (a) le 10 janvier 2023, (b) 11 janvier 2023, (c) le 12 janvier 2023 et (d) le 17 janvier 2023. (d) Carte de concentration de la rivière Massawippi (site M3) le 1<sup>er</sup> février 2023. (e) Carte de concentration de la rivière Saint-François (site SF1) le 31 janvier 2023. Les zones encerclées en gris indiquent les endroits où il y a un arbre ou une ombre créée par un arbre.

**Tableau 9 :** Concentrations de glace en mouvement obtenues selon la méthode de régression et la méthode de segmentation.

Site	Date	Concentration régression (%)	Concentration segmentation (%)	Différence (±%)
C2	10 janvier 2023	4,59	12,32	7,73
C2	11 janvier 2023	5,02	4,24	0,78
C2	12 janvier 2023	0,32	3,39	3,07
C2	17 janvier 2023	0,4	6,33	5,93
SF1	31 janvier 2023	29,57	41,48	11,91
M3	1 <sup>er</sup> février 2023	17,41	32,62	15,21

Les concentrations obtenues pour la série temporelle du site C2 ont été comparées aux valeurs de températures minimales de la nuit ou du matin précédant l’acquisition des données (Tableau 10). Plus précisément, la température minimale entre minuit et 1h00 avant le moment d’acquisition a été sélectionnée. La comparaison est aussi effectuée avec les valeurs de températures au moment de l’acquisition des données. Puisque le frasil se forme dans des conditions très froides, plus la température est basse, plus la concentration de frasil devrait être élevée. Cette comparaison permet de valider la cohérence des résultats. Par contre, en sachant que les concentrations du 10 janvier et du 12 janvier sont surestimées à cause de la présence d’arbres ou d’ombres surplombant la rivière, il est difficile de tirer des conclusions. Logiquement, la journée ayant la concentration de frasil la plus élevée devrait être celle du 11 janvier, puisqu’il s’agit de la journée la plus froide. C’est ce qu’indiquent les résultats issus de la méthode de la régression, mais pas celle de la segmentation. En fait, les résultats de la segmentation ne sont pas cohérents avec les températures.

**Tableau 10 :** Comparaison des concentrations avec les températures minimales précédant l’acquisition des données et avec les températures au moment de l’acquisition.

Site	Date	Concentration régression (%)	Concentration segmentation (%)	Température minimale (entre minuit et 1h00 avant l’acquisition) (°C)	Température au moment de l’acquisition (°C)
C2	10 janvier 2023*	4,59	12,32	-5,4	-5,7
C2	11 janvier 2023	5,02	4,24	-19,9	-20,1
C2	12 janvier 2023*	0,32	3,39	-11,6	-9,4
C2	17 janvier 2023	0,4	6,33	-6,9	-6,4

\*Images présentant un arbre surplombant la rivière ou une ombre créée par celui-ci.

## 6 Interprétation et discussions des résultats

### 6.1 Évaluation de l'atteinte des objectifs de l'essai

L'objectif principal de l'essai était de développer une méthode d'acquisition et de traitement d'images optiques de la glace fluviale acquises par drone afin de générer des données d'étendue et de concentration de glace fluviale utiles à la génération des paramètres d'entrées, au calage et à la validation des modèles hydrodynamiques de glace. L'objectif est jugé atteint.

Le premier objectif spécifique était de développer une méthode d'acquisition. Dans ce sens, des paramètres ont été déterminés au cours de l'essai afin d'élaborer un protocole d'acquisition des données. Avant d'aller sur le terrain, il est possible de s'assurer de la présence de frazil en installant des caméras en rive et en consultant les images à distance. C'est durant la période matinale que le plus de frazil/glace de fond a été observé. Il est donc recommandé de se rendre sur le terrain durant cette période lors des journées sans ou avec peu de précipitation et avec un vent faible. Ces éléments peuvent venir brouiller les images. Les températures en dessous de  $-5\text{ }^{\circ}\text{C}$  sont idéales. Par contre, lors des journées très froides, il est important de prévoir plusieurs batteries et de l'équipement permettant de les tenir au chaud afin qu'elles ne se déchargent pas trop vite. Tenir le drone au chaud le plus longtemps possible est aussi important puisque des fonctions peuvent être limitées par le froid (ex : rotation de la caméra). Une fois rendu sur le site, le pilote effectue manuellement des vols stationnaires de quelques minutes (1 à 5 minutes). La durée du vol peut varier en fonction de la capacité de la batterie et de ce que l'on observe sur le terrain. La caméra doit avoir une vue au nadir afin d'éviter les déformations sur les images et ainsi pouvoir produire des résultats quantifiables (Zhang *et al.*, 2021). Pour s'assurer d'avoir l'entièreté de la largeur de la rivière sur l'image, les deux berges doivent occuper approximativement 25% de l'image. De plus, deux cibles doivent être disposées sur la rive, le plus près de l'eau possible. La distance entre ces cibles doit être prise en note pour servir à la mise à l'échelle de l'image. Il s'agit de la même méthode d'acquisition des données utilisées pour les traitements LSPIV (section 2.3.4). Ces traitements permettent, entre autres, de déterminer la vitesse de surface des cours d'eau à l'aide de traceurs naturels sur la rivière. Éventuellement, il serait donc aussi possible d'utiliser les données acquises pour obtenir la vitesse de la glace fluviale.

Le deuxième objectif spécifique était de développer une méthode de traitement des images afin d'obtenir une étendue de glace statique et une concentration de glace en mouvement. Pour atteindre

cet objectif, trois CNNs ont été développés. Le premier CNN a été entraîné à segmenter les images en trois classes : la glace statique, l'eau libre (incluant la glace en mouvement) et la classe autres. En obtenant le nombre de pixels classifiés comme de la glace statique et la résolution de l'image, il est possible d'obtenir l'étendue de la glace statique. Pour l'obtention de la concentration de la glace en mouvement, deux méthodes de traitement ont été développées : la régression et la segmentation. Le CNN entraîné en mode régression génère une carte de concentration à partir de laquelle il est possible de calculer la concentration totale de glace en mouvement. Le CNN entraîné en mode segmentation génère une image classifiée (eau/glace en mouvement). En obtenant le nombre de pixels de chacune des classes, il est possible de calculer la concentration de la glace en mouvement. Le CNN entraîné en mode régression semble mieux fonctionner.

Le troisième objectif spécifique était de quantifier l'étendue du couvert de glace et la concentration de la glace en mouvement à partir des images acquises lors de la campagne terrain. Des données d'étendues de glace statique et de concentrations de glace en mouvement ont été générées pour 6 des images acquises. En analysant les résultats obtenus lors de cette étape, il a été conclu qu'en améliorant quelques aspects de la méthode de traitements développée, les données pourront être utilisées dans le cadre de la modélisation de la glace de rivière.

## **6.2 Évaluation des résultats et limites de l'essai**

Différentes étapes ont permis d'atteindre les objectifs de l'essai : l'acquisition des données, la préparation des images, le calcul de l'étendue de la glace statique et le calcul de la concentration de glace en mouvement. Chacune de ces étapes présente cependant des limites. Dans cette section, ces étapes sont évaluées et leurs limites sont discutées.


### **6.2.1 Évaluation de l'acquisition des données**

La première étape a été d'acquérir les données sur les sites à l'étude. Les rivières Coaticook et Massawippi sont des petites rivières. La largeur des sites d'études varie entre 30 et 45 mètres. La largeur du site de la rivière Saint-François s'élevait à environ 90 mètres. Les études présentées dans la section 2.3.1, ont pour leur part utilisé des données acquises sur des rivières beaucoup plus larges, de l'ordre de centaines de mètres (Ansari *et al.*, 2017, 2021; Singh *et al.*, 2020; Sola et Scott, 2022; Zhang *et al.*, 2020, 2021). Les vols de drone ont donc dû s'effectuer à des altitudes beaucoup plus élevées et les radeaux de frasil devaient être d'une taille plus importante. D'ailleurs, l'*Alberta river ice segmentation dataset* est majoritairement composé de radeaux de frasil, tandis que les données



acquises dans le cadre de cet essai sont majoritairement composées de frasil sous forme de *slush* (Figure 31). Il est plus difficile de détecter et de délimiter les contours de la *slush*. Les données acquises dans le cadre de l'essai présentaient donc des défis supplémentaires.

Les études consultées ont acquis leurs données sur quelques hivers. Singh *et al.* (2020) ont acquis leurs données au cours de 2 hivers, Ansari *et al.* (2020) au cours de 3 hivers et Zhang *et al.* (Zhang *et al.*, 2021) au cours de 5 hivers. Dans le cadre de cet essai, les données ont été acquises de décembre 2022 à février 2023. La période est donc plus courte, mais l'acquisition des données pourra être poursuivie au cours des prochaines années. Acquérir des données sur plusieurs hivers permet d'avoir des conditions plus variées dans les images et ainsi faire un entraînement plus robuste. L'hiver 2022-2023 a été plutôt doux en Estrie. Un hiver plus froid permettrait, entre autres, d'avoir plus d'images de radeaux de frasil.




**Figure 31 :** Comparaison d'une (a) imagerie utilisée pour l'entraînement des modèles dans le cadre de l'étude de Singh *et al.* (2020) représentant majoritairement du frasil sous forme de radeaux et (b) d'une imagerie utilisée pour l'entraînement des modèles dans le cadre de l'essai représentant majoritairement du frasil sous forme de *slush*.

Les données utilisées dans le cadre de l'essai ont principalement été acquises sur la rivière Coaticook. Idéalement, plus de données auraient été acquises sur les rivières Massawippi et Saint-François afin d'avoir une plus grande diversité de conditions. Un manque de données a été constaté pour ces sites ce qui se traduit en une faible quantité d'images de radeaux de frasil. La présence de frasil sur la rivière Massawippi était rare. Du frasil a été aperçu en bonne quantité seulement lors des journées très froides (-20°C). Puisque cette rivière prend sa source dans un lac, son eau est plus



chaude, ce qui pourrait expliquer l'absence de frasil. À la confluence des rivières Coaticook et Massawippi (site C3), il était possible de voir le frasil de la rivière Coaticook se déverser dans la rivière Massawippi (Figure 32). Cependant, plus en aval sur la Massawippi (site M1), il n'y avait presque plus de frasil. Celui-ci avait probablement fondu. Peu de données ont été acquises sur la rivière Saint-François puisqu'elle a été rajoutée en cours de projet. La rivière Saint-François traverse la ville de Sherbrooke, mais il est plus compliqué d'effectuer des vols de drone sur les terrains publics de cette ville à cause du règlement municipal (Ville de Sherbrooke, 2023). C'est pour cette raison que le site de la Saint-François est situé à Ascot Corner.

La rivière Coaticook semble être une zone de production de frasil, tandis que les rivières Massawippi et Saint-François semblent des zones de transports de frasil. Cela explique pourquoi le frasil est principalement sous forme de *slush* sur la Coaticook et sous forme de radeaux sur les rivières Massawippi et Saint-François. Au cours des prochains hivers, des données pour ces deux rivières pourraient être ajoutées. D'autres rivières pourraient également être incluses au projet.



**Figure 32 :** Confluence de la rivière Coaticook et de la rivière Massawippi. Le frasil provenant de la rivière Coaticook se déverse dans la rivière Massawippi. Aucun frasil ne provient de celle-ci (photo prise par Victoria Litalien).

### 6.2.2 Évaluation de l'annotation des images

Une autre étape a été de préparer les images pour entraîner les différents modèles. La méthode utilisée diverge sur plusieurs aspects comparativement à celles utilisées dans les études consultées. En effet, la technique d'annotation, le nombre d'images annotées et les classes ne sont pas identiques. Dans le cadre de ces études, les images ont été annotées en utilisant la technique de la

segmentation sémantique (Ansari *et al.*, 2017, 2021; Singh *et al.*, 2020; Sola et Scott, 2022; Zhang *et al.*, 2020, 2021). Plusieurs ont d'ailleurs noté les défis liés à cette tâche, dont la difficulté à délimiter les contours de la glace en mouvement (Ansari *et al.*, 2021; Singh *et al.*, 2020; Zhang *et al.*, 2020, 2021). Ce même défi a été rencontré ici. La délimitation manuelle du frazil a été tentée, mais s'est avérée très longue et imprécise. C'est pour cette raison que la méthode de seuil a été utilisée pour segmenter les images de glace en mouvement. C'est également pour cette raison que l'annotation de la glace en mouvement en mode régression a été tentée et comparée à la segmentation. L'annotation par segmentation a été conservée pour la glace statique puisque la délimitation de ces contours se fait facilement.

24 images (2 295 imageries) ont été annotées pour le calcul de la glace statique. Cela est jugé comme suffisant, surtout en observant l'IoU moyen du modèle. Seulement 45 imageries ont été annotées pour le calcul de la concentration de glace. Un nombre d'images annotées plus grand aiderait à stabiliser les prédictions de concentrations de glace. De leur côté, les auteurs des articles consultés ont annoté entre 50 et 1 525 images ou imageries (Ansari *et al.*, 2017, 2021; Singh *et al.*, 2020; Sola et Scott, 2022; Zhang *et al.*, 2020, 2021).

En ce qui concerne les classes, en combinant les deux jeux d'images annotées, 4 classes ont été définies dans le cadre de l'essai (eau, glace statique, glace en mouvement et autres). Il s'agit presque des mêmes classes que celles utilisées par Zhang *et al.* (2021) (eau, glace de rive, glace en mouvement, autres) qui ont obtenu un IoU moyen de 89% pour le jeu de données de tests. Ansari *et al.* (2020) ont également défini 4 classes. Contrairement à ce qui a été fait ici, ils ont distingué le frazil sous forme de *slush* du frazil sous forme de radeaux tout en obtenant un IoU élevé, soit de 97% (jeu de données non spécifié). D'autres auteurs, tels que Zhang *et al.* (2020), ont seulement défini 3 classes et ont obtenu un IoU de 88% pour le jeu de données de test. Singh *et al.* (2020) et Sola et Scott (2022) ont également défini 3 classes. Par contre, ils ont différencié la glace de fond du frazil lors de leur annotation, ce qui n'a pas été fait dans ce travail. Comparativement aux autres études consultées, l'IoU obtenu pour le jeu de données de test est moins élevé pour ces deux équipes de chercheurs. Il varie entre 66 % et 77% pour Singh *et al.* (2020) et entre 64% et 72% pour Sola et Scott (2022). Finalement, Ansari *et al.* (2021) sont les auteurs ayant défini le plus de classes (glace de rive, glace détachée, frazil sous forme de *slush* et frazil sous forme de radeaux, couvert de glace et eau) tout en obtenant un IoU élevé (91%) pour le jeu de données de test. Bref, plusieurs

classes possibles n'ont pas été incluses dans ce travail, mais pourraient l'être éventuellement. Évidemment, l'ajout de ces classes viendrait avec des défis supplémentaires, tel que la reconnaissance visuelle des différents types de glace. Comme abordé à la section 2.3.1, la distinction des différents types de glace, même pour les experts, n'est pas une tâche facile et peut entraîner des erreurs lors de l'utilisation des modèles (Ansari *et al.*, 2021; Singh *et al.*, 2020).

### **6.2.3 Évaluation du calcul de l'étendue du couvert de glace**

Pour calculer l'étendue du couvert de glace sur les images, un CNN a été entraîné avec des images annotées par segmentation sémantique selon trois classes (eau, glace statique et autres). L'IoU moyen de ce modèle s'élève à 96% pour le jeu de validation. Parmi les études ayant utilisé des CNNs, malgré leurs nombreuses classes, Ansari *et al.* (2020) ont obtenu une précision de 97% (jeu de données non spécifié) alors que l'IoU moyen le moins élevé a été obtenu par Sola et Scott, soit 64% pour leur jeu de données de test.

Une inférence en imagerie multiples a été effectuée sur un jeu de données de test. Ce jeu de données était composé d'images qui n'avaient ni servi à l'entraînement ni servi à la validation du modèle. Par contre, certaines des images du jeu de données de test provenaient des mêmes vidéos que les images des jeux de données d'entraînement et de validation. C'est le cas pour les images du site C2 prises le 10 et 17 janvier, pour l'image du site M3 prise le 1<sup>er</sup> février et pour l'image du SF1 prise le 31 janvier. Des images provenant des mêmes vidéos ont été utilisées afin de pouvoir compléter une série temporelle sur le site C2 et afin d'inclure les sites M3 et SF1 malgré le peu de données pour ces sites. Puisque le vol est stationnaire, les caractéristiques du couvert de glace ne changent pas vraiment au cours des vidéos prises lors d'une même journée. Idéalement, le jeu de données de test aurait été formé d'images provenant de vidéos qui n'avaient pas été utilisés pour l'entraînement ou pour la validation.

Une inférence en imagerie multiples a aussi été tentée sur une orthomosaique. À notre connaissance, aucune étude n'a tenté d'inférer sur ce type de donnée dans le but de classifier la glace de rivière. Beaucoup de confusion a été repérée entre les classes, donc le résultat ne permet pas de générer une étendue du couvert de glace. Il faudrait revoir la construction du jeu d'entraînement en ajoutant de nouveaux échantillons jusqu'à l'obtention de résultats intéressants. À l'état actuel, le modèle semble tout de même être en mesure d'identifier le front de glace sur l'orthomosaique.

En plus de l'IoU moyen du modèle, d'autres méthodes de validation ont été utilisées pour évaluer les résultats de l'inférence sur le jeu de données de test. Les cartes de scores et les superpositions visuelles des segmentations aux images de base ont aidé à déterminer les éléments plus difficiles à classifier. La cohérence entre le processus physique et les résultats a aussi été évaluée en utilisant les degrés-jours sous zéro. Bref, plusieurs méthodes de validation indirecte ont été utilisées. Par contre, aucune segmentation manuelle n'a été effectuée pour comparer les étendues du couvert de glace générées, tel qu'ont fait Ansari *et al.* (2017) dans le cadre de leur étude.

#### **6.2.4 Évaluation du calcul de la concentration de la glace en mouvement**

Pour le calcul de la glace en mouvement, le modèle entraîné en mode segmentation sémantique (eau, glace) a obtenu un IoU moyen de 82% pour le jeu de données de validation. Ce résultat pourrait être amélioré, par exemple, en augmentant le nombre d'images dans le jeu d'entraînement. Zhang *et al.* (2020) ont des classes semblables (eau, glace, autres) et ont obtenu un IoU moyen de 88% pour le jeu de données de test. Par contre, leurs images ont été acquises sur une seule rivière. Le modèle entraîné en mode régression a obtenu une mesure de validation plus précise. La distance L1 du modèle est de 2% pour le jeu de donnée de validation. À notre connaissance, aucun article n'aborde le calcul de la concentration de la glace de rivière à l'aide d'un modèle entraîné par régression, il n'est donc pas possible de comparer le résultat à la littérature. Également, le modèle en mode régression a été entraîné pendant un plus grand nombre d'époques (200) que le modèle en mode segmentation sémantique (40). Il pourrait être intéressant d'appliquer le même nombre d'époques (200) lors de l'entraînement du modèle en mode sémantique afin de voir l'effet sur les résultats. Cependant, selon l'état actuel des modèles générés, le calcul par régression semble plus approprié.

L'inférence a été effectuée sur le jeu de donnée test avec les deux modèles. Ici, le fait que les imagerie du jeu de données de test soient extraites des mêmes vidéos que celles utilisées pour l'entraînement ou la validation du modèle n'est pas un enjeu. En effet, la concentration et l'aspect de la glace en mouvement peuvent changer à même une vidéo. L'inférence a révélé la difficulté qu'avaient les deux modèles à classifier les arbres surplombant la rivière ou les ombres projetées par ceux-ci. Ces éléments sont classifiés comme de la glace en mouvement, ce qui vient fausser les mesures de concentration. Sur les rivières propices aux embâcles, la présence d'arbres surplombant la rivière est fréquente. L'érosion des berges causée par la présence de glace de rivière peut

entraîner l'affaiblissement des arbres (Vandermause *et al.*, 2021). L'arbre surplombant la rivière au site C2 n'est pas une exception, mais une situation commune. Il est donc important que le modèle soit en mesure de bien gérer cette situation. Dans les 45 imagerie utilisées pour l'entraînement, aucun arbre n'était présent. L'ajout d'imagerie avec des arbres lors de l'entraînement pourrait possiblement régler le problème. Sinon, une classe à part pour les arbres surplombant les rivières pourrait être ajoutée au modèle utilisé pour le calcul de la glace statique. Ces éléments seraient alors masqués lors du calcul de la concentration de la glace en mouvement.

Les concentrations de glace en mouvement obtenues pour les images de la série temporelle (site C2) ont été analysées en fonction des températures minimales dans les heures précédant l'acquisition et au moment de l'acquisition afin de valider la cohérence avec le processus physique de formation du frasil. Le frasil se forme dans des conditions très froides (Lindenschmidt, 2020). Plus la température est basse, plus la concentration du frasil devrait alors être élevée. Puisque les concentrations des images avec des arbres surplombant la rivière ou leur ombre sont surestimées (images du 10 et 12 janvier), il est difficile de tirer des conclusions de cette analyse. Il serait donc intéressant de la refaire lorsque ce problème sera réglé. À ce moment, il serait aussi intéressant d'analyser la précision du modèle en fonction de la concentration de la glace en mouvement. La précision du modèle varie-t-elle en fonction de la concentration de la glace? À premier abord, cela semble le cas pour la méthode de la segmentation sémantique. Comme expliqué à la section 5.2, lorsqu'une grande concentration de radeaux de glace est présente dans l'image, le modèle a de la difficulté à distinguer l'eau située entre ceux-ci.

Les cartes de concentration et de segmentation ont été visuellement examinées, les mesures de validations des modèles ont été obtenues et une analyse avec le processus physique a été effectuée, mais il est tout de même difficile de déterminer laquelle des deux méthodes de calcul (régression/segmentation) est la plus appropriée. Dans le cadre du projet financé par le MAMH (section 1.2), une équipe de recherche de l'Université de Sherbrooke a installé des SWIPs à proximité du site C2 et au site M3 (Duguay *et al.*, 2023). Lorsque les données des SWIPs auront été analysées au courant de l'été 2023, il serait intéressant de comparer les concentrations obtenues par ces instruments à celles obtenues dans ce projet. Éventuellement, les données pourront également être intégrées dans la modélisation hydrodynamique de glace et leur apport à la cartographie des zones inondables hivernales pourra être évalué.

### 6.3 Recommandations et suite des travaux

À la suite de l'analyse des résultats, il est recommandé d'améliorer quelques aspects de la méthode afin d'avoir de meilleures données à intégrer dans la modélisation hydrodynamique de glace. De nouvelles données pourraient être acquises au courant des prochains hivers. Pour la suite des acquisitions, il est d'ailleurs prévu d'utiliser un drone multispectral à positionnement GPS cinématique en temps réel (RTK, *Real-Time Kinematic*). Il sera intéressant d'évaluer si les données multispectrales permettent une meilleure distinction du frazil. Pour sa part, le RTK permettrait de faire la mise à l'échelle de l'image sans avoir installé les cibles à proximité de la rivière. La méthode serait alors plus sécuritaire et plus rapide.

Le modèle pour le calcul de l'étendue de la glace statique pourrait alors être entraîné avec un jeu de données plus large. En faisant plusieurs itérations sur le jeu de données, l'inférence réalisée sur les orthomosaïques donnerait de meilleurs résultats. De plus, il est recommandé de refaire l'annotation des images en ajoutant une classe pour les arbres surplombant la rivière et leur ombre afin d'éviter la confusion des modèles. La segmentation se ferait alors en 4 classes : glace statique, eau (incluant la glace en mouvement), arbre surplombant la rivière et autres.

Pour le calcul de la concentration de la glace en mouvement, il est recommandé d'entraîner à nouveau le modèle en mode segmentation sémantique avec plus d'images annotées et plus d'époques. Le modèle serait probablement plus stable. Plusieurs images non annotées sont déjà disponibles dans le jeu de donnée. L'acquisition de nouvelles données n'est donc pas essentielle à l'accomplissement de cette tâche. Il est aussi recommandé d'annoter les images selon le type de glace en mouvement (frazil sous forme de radeaux, frazil sous forme de *slush*, glace de fond, glace de rive détachée) et de voir l'impact que cela a sur la précision des résultats.

Pour la suite du projet, il est recommandé de comparer les résultats des deux méthodes de calcul de concentration de la glace en mouvement aux données de concentration de frazil produites à l'aide des SWIPs installés à proximité des sites d'étude. Il serait également intéressant d'étudier la variation de la concentration du frazil à différents endroits d'une même rivière pour une même journée. L'exploration d'indicateur de taille et d'agrégation des instances de frazil permettrait aussi une meilleure caractérisation du phénomène. Un autre élément intéressant à étudier serait la vitesse d'écoulement présente dans les vidéos acquises. Les vitesses pourraient être calculées à l'aide de la méthode LSPIV. Cela permettrait de valider les vitesses d'écoulement propice à la formation du

frasil (présentées au Tableau 1). Il serait également possible de comparer les concentrations de frasil obtenues dans le cadre de cet essai aux vitesses d'écoulement. Finalement, il est recommandé d'intégrer les données générées dans la modélisation hydrodynamique afin de faciliter la conception des cartes de zones inondables hivernales.

## **7 Conclusion**

L'objectif principal de l'essai était de développer une méthode d'acquisition et de traitement d'images optiques de la glace fluviale acquises par drone afin de générer des données d'étendue et de concentration de glace fluviale utiles à la génération des paramètres d'entrées, au calage et à la validation des modèles hydrodynamiques de glace. Pour y arriver, des données ont tout d'abord été acquises entre le mois de décembre 2022 et le mois de février 2023 sur 7 sites, répartis sur 3 rivières. À l'aide de ces données, un premier CNN a été entraînée afin de segmenter les images en trois classes, soit l'eau (incluant la glace en mouvement), la glace statique et la classe autres. De cette segmentation, des mesures d'étendues de glace ont pu être générées et analysées en fonction des degrés-jours sous zéro. Deux CNNs ont aussi été entraînés dans le but de générer des concentrations de glace en mouvement selon des méthodes différentes. Le modèle entraîné en mode régression permet de produire une carte de concentration tandis que le modèle entraîné en mode segmentation produit une image classifiée. Des mesures de concentration peuvent être calculées à partir de ces deux résultats. Ces mesures ont été analysées en fonction des températures minimales précédant l'acquisition et des températures au moment de l'acquisition. L'inférence réalisée sur des images des différentes rivières et sur une orthomosaique a permis d'identifier des pistes d'amélioration. En étoffant le jeu de données et en revoyant l'annotation des images, des résultats d'une plus grande précision pourraient être générés. Des données incluant des éléments comme des couverts de glace entièrement enneigés, des ombrages et des routes seraient à ajouter. Une classe spécifique pour les arbres devrait également être ajoutée aux classes déjà définies.

L'essai s'inscrivait dans le cadre d'un projet de plus grande envergure financé par le MAMH et un projet du programme Alliance du conseil de recherches en sciences naturelles et en génie (CRSNG-Alliance). L'objectif du projet est de caractériser les zones inondables causées par la présence de glace à l'aide de modèles hydrodynamiques de glace. Les données générées dans le cadre de cet essai pourront être intégrées dans ces modélisations. Pour la suite du projet, de nouvelles acquisitions et analyses sont prévues dans les hivers à venir.

## Références

- Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P. et Süsstrunk, S. (2012) SLIC Superpixels Compared to State-of-the-Art Superpixel Methods. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 34, n°11, p. 2274-2282.
- Alfredsen, K., Haas, C., Tuhtan, J. A. et Zinke, P. (2018) Brief Communication: Mapping river ice using drones and structure from motion. *Cryosphere*, vol. 12, n°2, p. 627-633.
- Altena, B. et Kääb, A. (2021) Quantifying river ice movement through a combination of European satellite monitoring services. *International Journal of Applied Earth Observation and Geoinformation*, vol. 98, n°102315.
- Andrishak, R. et Hicks, F. (2015) Working Safely on River Ice. *In Proceedings of the 18th Workshop on the Hydraulics of Ice Covered Rivers, Québec, 18-20 août 2015. Committee on River Ice Processes and the Environment.*
- Ansari, S., Rennie, C. D., Clark, S. P. et Seidou, O. (2020) Automated river ice freeze-up monitoring and characterization. p.823-828 *in River Flow 2020, Proceedings of the 10th Conference on Fluvial Hydraulics, Delft, 7-10 juillet 2020. International Conference on Fluvial Hydraulics.*
- Ansari, S., Rennie, C. D., Clark, S. P. et Seidou, O. (2021) IceMaskNet: River ice detection and characterization using deep learning algorithms applied to aerial photography. *Cold Regions Science and Technology*, vol. 189, n°103324.
- Ansari, S., Rennie, C. D., Seidou, O., Malenchak, J. et Zare, S. G. (2017) Automated monitoring of river ice processes using shore-based imagery. *Cold Regions Science and Technology*, vol. 142.
- Beaton, A., Whaley, R., Corston, K. et Kenny, F. (2019) Identifying historic river ice breakup timing using MODIS and Google Earth Engine in support of operational flood monitoring in Northern Ontario. *Remote Sensing of Environment*, vol. 224, p. 352-364.
- Bourgault, D. (2008) Shore-based photogrammetry of river ice. *Canadian Journal of Civil Engineering*, vol. 35, n°1, p. 80-86.
- Bradski, G. (2000) The OpenCV Library. *Dr. Dobb's Journal of Software Tools*, vol. 25, n°11, p. 122-125.
- Buermans, J., Fissel, D. B. et Kanwar, A. (2011) Seven Years of SWIPS Measurements, Applications and Development: Where, How and What Can the Technology Do for Us. *In Proceedings of the 16th Workshop on River Ice, Winnipeg, 18-22 septembre 2011. Committee on River Ice Processes and the Environment.*
- Buslaev, A., Iglovikov, V. I., Khvedchenya, E., Parinov, A., Druzhinin, M. et Kalinin, A. A. (2020) Albumentations: Fast and Flexible Image Augmentations. *Information*, vol. 11, n°2.
- Chaouch, N., Temimi, M., Romanov, P., Cabrera, R., Mckillop, G. et Khanbilvardi, R. (2014) An automated algorithm for river ice monitoring over the Susquehanna River using the MODIS data. *Hydrological Processes*, vol. 28, n°1, p.62-73.
- Chave, R. A. J., Lemon, D. D., Fissel, D. B., Dupuis, L. et Dumont, S. (2004) Real-time measurements of ice draft and velocity in the St. Lawrence River. p. 1629-1633 *in Oceans '04 MTS/IEEE Techno-Ocean '04*, vol. 3, Kobe, 9-12 novembre 2004. *Bridges across the Oceans.*
- Committee on River Ice Processes and the Environment (2023) Importance of river ice. *Committee on River Ice Processes and the Environment [En ligne]. <http://www.cripe.ca> (page consultée le 20 mars 2023).*



- Daigle, A., Bérubé, F., Bergeron, N. et Matte, P. (2013) A methodology based on Particle image velocimetry for river ice velocity measurement. *Cold Regions Science and Technology*, vol. 89, p. 36-47.
- Das, A., Sagin, J., Van der Sanden, J., Evans, E., McKay, H. et Lindenschmidt, K.-E. (2015) Monitoring the freeze-up and ice cover progression of the Slave River. *Canadian Journal of Civil Engineering*, vol. 42, n°9, p. 609-621.
- DJI (s.d.) DJI Mavic 3 Pro, Specs. *In* DJI, DJI Official [En ligne]. <https://www.dji.com/ca/mavic-3-pro/specs> (page consultée le 2 mai 2023).
- Dorkhah, M., Mashhadi, S. et Lo, S. (2023) Modélisation du contexte à l'aide de transformateurs : reconnaissance des aliments. *In* Statistique Canada, Centre de la science des données [En ligne]. <https://www.statcan.gc.ca/fr/science-donnees/reseau/reconnaissance-aliments> (page consultée le 3 mai 2023).
- Duguay, J., Trudel, M., Lacey, J., Biron, P. et Buffin-Bélanger, T. (2023) Rapport d'étape 1: Projet de recherche sur le développement d'une méthodologie de caractérisation, de cartographie et l'identification de mesures de résilience pour les communautés aux prises avec des inondations par embâcles de glace applicable à l'ensemble du Québec. Département de génie civile et de génie du bâtiment, Université de Sherbrooke, rapport au ministère des affaires municipales et de l'Habitation, 144 p.
- Fu, H., Liu, Z., Guo, X. et Cui, H. (2018) Double-frequency ground penetrating radar for measurement of ice thickness and water depth in rivers and canals: Development, verification and application. *Cold Regions Science and Technology*, vol. 154, p. 85-94.
- Goodfellow, I., Bengio, Y. et Courville, A. (2016) *Deep Learning*. MIT Press, Cambridge, 781 p.
- Hicks, F. et Beltaos, S. (2008) River Ice. Chap. 15, p.281-305 *in* Woo, M-K (éditeur). *Cold Region Atmospheric and Hydrologic Studies, The Mackenzie GEWEX Experience, Volume 2 : Hydrologic processes*. Springer, Berlin, 507 p.
- Jedrychowski, K. et Kujawski, A. (2014) Method of image analysis in the process of assessment of ice occurrences. *Scientific Journals of the Maritime University of Szczecin*, vol. 37, n°109, p. 45-49.
- Jolley, M. J., Russell, A. J., Quinn, P. F. et Perks, M. T. (2021) Considerations When Applying Large-Scale PIV and PTV for Determining River Flow Velocity. *Frontiers in Water*, vol. 3, n°709269.
- Kalke, H. et Loewen, M. (2018) Support vector machine learning applied to digital images of river ice conditions. *Cold Regions Science and Technology*, vol. 155, p. 225-236.
- Kalke, H., Loewen, M., McFarlane, V. et Jasek, M. (2015) Observations of Anchor Ice Formation and Rafting of Sediments. *In* Proceedings of the 18th Workshop on the Hydraulics of Ice Covered Rivers, Québec, 18-20 août 2015. Committee on River Ice Processes and the Environment.
- Kempema, E. W. et Ettema, R. (2011) Anchor ice rafting: Observations from the laramie river. *River Research and Applications*, vol. 27, n°9, p. 1126-1135.
- Khan, A., Sohail, A., Zahoor, U. et Qureshi, A. S. (2020) A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review*, vol. 53, n°8, p. 5455-5516.
- Kraatz, S., Khanbilvardi, R. et Romanov, P. (2016) River ice monitoring with MODIS: Application over Lower Susquehanna River. *Cold Regions Science and Technology*, vol. 131, p. 116-128.
- Lakubovskii, P. (2019) Segmentation Models Pytorch. *In* GitHub [En ligne]. [https://github.com/qubvel/segmentation\\_models.pytorch](https://github.com/qubvel/segmentation_models.pytorch) (page consultée le 3 mai 2023).

- Le Coz, J., Hauet, A., Pierrefeu, G., Dramais, G. et Camenen, B. (2010) Performance of image-based velocimetry (LSPIV) applied to flash-flood discharge measurements in Mediterranean rivers. *Journal of Hydrology*, vol. 394, n°1-2, p. 42-52.
- Le Coz, J., Patalano, A., Collins, D., Guillén, N. F., García, C. M., Smart, G. M., Bind, J., Chiaverini, A., Le Boursicaud, R., Dramais, G. et Braud, I. (2016) Crowdsourced data for flood hydrology: Feedback from recent citizen science projects in Argentina, France and New Zealand. *Journal of Hydrology*, vol. 541, Part B, p. 766-777.
- Lewis, Q. W., Lindroth, E. M. et Rhoads, B. L. (2018) Integrating unmanned aerial systems and LSPIV for rapid, cost-effective stream gauging. *Journal of Hydrology*, vol. 560, p. 230-246.
- Li, Haojie, Li, Hongyi, Wang, J. et Hao, X. (2020) Monitoring high-altitude river ice distribution at the basin scale in the northeastern Tibetan Plateau from a Landsat time-series spanning 1999–2018. *Remote Sensing of Environment*, vol. 247, n°111915.
- Li, Haojie, Li, Hongyi, Wang, J. et Hao, X. (2021) Identifying river ice on the Tibetan Plateau based on the relative difference in spectral bands. *Journal of Hydrology*, vol. 601, n° 126613.
- Li, Z. et Lindenschmidt, K.-E. (2018) Coherence of Radarsat-2, Sentinel-1, and ALOS-1 PALSAR for monitoring spatiotemporal variations of river ice covers. *Canadian Journal of Remote Sensing*, vol. 44, n°1, p. 11-25.
- Lin, J., Shu, L., Zuo, H. et Zhang, B. (2012) Experimental observation and assessment of ice conditions with a fixed-wing unmanned aerial vehicle over Yellow River, China. *Journal of Applied Remote Sensing*, vol. 6, n°1.
- Lindenschmidt, K.-E. (2017) RIVICE—A Non-Proprietary, Open-Source, One-Dimensional River-Ice Model. *Water*, vol. 9, n°5.
- Lindenschmidt, K.-E. (2020) *River Ice Processes and Ice Flood Forecasting: A Guide for Practitioners and Students*. Springer, Cham, 267 p.
- Lindenschmidt, K.-E. et Li, Z. (2018) Monitoring river ice cover development using the Freeman–Durden decomposition of quad-pol Radarsat-2 images. *Journal of Applied Remote Sensing*, vol. 12, n°2.
- Lindenschmidt, K.-E., Syrenne, G. et Harrison, R. (2010) Measuring Ice Thicknesses along the Red River in Canada Using RADARSAT-2 Satellite Imagery. *Journal of Water Resource and Protection*, vol. 2, n°11, p. 923-933.
- Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G. et Johnson, B. A. (2019) Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 152, p. 166-177.
- Mermoz, S., Allain-Bailhache, S., Bernier, M., Pottier, É., Van Der Sanden, J. et Chokmani, K. (2014) Retrieval of river ice thickness from C-band PolSAR data. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 52, n°6, p. 3052-3062.
- Okulski, M. et Lawryńczuk, M. (2022) A Small UAV Optimized for Efficient Long-Range and VTOL Missions: An Experimental Tandem-Wing Quadplane Drone. *Applied Sciences*, vol. 12, n°14.
- Prowse, T. D., Bonsal, B. R., Duguay, C. R. et Lacroix, M. P. (2007) River-ice break-up/freezing-up: a review of climatic drivers, historical trends and future predictions. *Annals of Glaciology*, vol. 46, p. 443-451.
- Pytorch (s.d.) TORCH.SPECIAL. *In* PyTorch documentation, Pytorch [En ligne]. <https://pytorch.org/docs/stable/special.html> (page consultée le 15 septembre 2023).

- Ren, H., Zhao, Y., Xiao, W. et Hu, Z. (2019) A review of UAV monitoring in mining areas: current status and future perspectives. *International Journal of Coal Science & Technology*, vol. 6, n°3, p. 320-333.
- River Ice Research Group (2023) Numerical Modelling. *In* River Ice Research Group, Department of Civil and Environmental Engineering, University of Alberta. [En ligne] <https://www.riverice.ca/modeling> (page consultée le 10 octobre 2023).
- Rogowska, J. (2009) Overview and Fundamentals of Medical Image Segmentation. Chap. 15, p. 73 -90 *in* Bankman, I. N. (dir.). *Handbook of Medical Image Processing and Analysis (Second Edition)*. Academic Press, Burlington, 983 p.
- Ronneberger, O., Fischer, P. et Brox, T. (2015) U-Net: Convolutional Networks for Biomedical Image Segmentation. p. 234-241 *in* *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015, Munich, 5-9 octobre 2015, MICCAI*, 708 p.
- Russ, J. C. (2011) *The image processing handbook (sixth edition)*. CRC press, Boca Raton, 867 p.
- Russell, S. J. et Norvig, P. (2010) *Artificial intelligence: a modern approach (third edition)*. Prentice Hall, New Jersey, 1132 p.
- Simoes, J. et Clark, S. P. (2020) Quantification of Border Ice Growth on the Assiniboine River. *Journal of Cold Regions Engineering*, vol. 34, n°1.
- Singh, A., Kalke, H., Loewen, M. et Ray, N. (2020) River Ice Segmentation with Deep Learning. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 58, n°11, p. 7570-7579.
- Sola, D. (2022) *River Ice Segmentation under a Limited Compute and Annotation Budget*. Mémoire de maîtrise, Université de Waterloo, 99 p.
- Sola, D. et Scott, K. A. (2022) Efficient Shallow Network for River Ice Segmentation. *Remote Sensing*, vol. 14, n°10.
- Stanford University. (s.d.) CS231n Convolutional Neural Networks for Visual Recognition. *In* CS231n: Deep Learning for Computer Vision, Stanford University. [En ligne]. <https://cs231n.github.io/convolutional-networks/> (page consultée le 29 janvier 2023).
- Tauro, F., Porfiri, M. et Grimaldi, S. (2014) Orienting the camera and firing lasers to enhance large scale particle image velocimetry for streamflow monitoring. *Water Resources Research*, vol. 50, n°9, p. 7470-7483.
- Thellman, A., Jankowski, K. J., Hayden, B., Yang, X., Dolan, W., Smits, A. P. et O’Sullivan, A. M. (2021) The Ecology of River Ice. *Journal of Geophysical Research: Biogeosciences*, vol. 126, n°9.
- Transport Canada (2021) Règlement de l’aviation canadien (DORS/96-433). *In* Transport Canada, Transport Canada [En ligne]. <https://tc.canada.ca/fr/services-generaux/lois-reglements/liste-reglements/reglement-aviation-canadien-dors-96-433> (page consultée le 23 février 2023).
- Turcotte, B., Alfredsen, K., Beltaos, S. et Burrell, B. C. (2017) Ice-Related Floods and Flood Delineation along Streams and Small Rivers. *In* *Proceedings of the 19th Workshop on the Hydraulics of Ice Covered Rivers, Whitehorse, 10-12 juillet 2017. Committee on River Ice Processes and the Environment*.
- Unterschultz, K. D., Van Der Sanden, J. et Hicks, F. E. (2009) Potential of RADARSAT-1 for the monitoring of river ice: Results of a case study on the Athabasca River at Fort McMurray, Canada. *Cold Regions Science and Technology*, vol. 55, n°2, p. 238-248.
- US Army Corps of Engineers (s.d.) HEC-RAS. *In* US Army Corps of Engineers, Hydrologic Engineering Center [En ligne]. <https://www.hec.usace.army.mil/software/hec-ras/> (page consultée le 16 mai 2023).

- Vaibhav, K., Prasad, J. et Singh, B. (2021) Convolutional Neural Network for Classification for Indian Jewellery. p. 363-369 *in* International Conference on Sustainable Computing in Science, Technology & Management (SUSCOM-2019), Jaipur, 26-28 février 2019. SUSCOM.
- Vandermause, R., Harvey, M., Zevenbergen, L. et Ettema, R. (2021) River-ice effects on bank erosion along the middle segment of the Susitna river, Alaska. *Cold Regions Science and Technology*, vol. 185, n°103239.
- Ville de Sherbrooke (2023) Règlement général de la Ville de Sherbrooke [document PDF]. 24 mai 2023, Ville de Sherbrooke, Sherbrooke, 685 p.
- Wang, E., Hu, S., Han, H., Li, Y., Ren, Z. et Du, S. (2022) Ice Velocity in Upstream of Heilongjiang Based on UAV Low-Altitude Remote Sensing and the SIFT Algorithm. *Water (Switzerland)*, vol. 14, n°12.
- Yao, H., Qin, R. et Chen, X. (2019) Unmanned Aerial Vehicle for Remote Sensing Applications—A Review. *Remote Sensing*, vol. 11, n°12.
- Zhang, F., Li, Z. et Lindenschmidt, K.-E. (2019) Potential of RADARSAT-2 to Improve Ice Thickness Calculations in Remote, Poorly Accessible Areas: A Case Study on the Slave River, Canada. *Canadian Journal of Remote Sensing*, vol. 45, n°2, p. 234-245.
- Zhang, X., Jin, J., Lan, Z., Li, C., Fan, M., Wang, Y., Yu, X. et Zhang, Y. (2020) ICENET: A Semantic Segmentation Deep Network for River Ice by Fusing Positional and Channel-Wise Attentive Features. *Remote Sensing*, vol. 12, n°2.
- Zhang, X., Zhou, Y., Jin, J., Wang, Y., Fan, M., Wang, N. et Zhang, Y. (2021) ICENETv2: A Fine-Grained River Ice Semantic Segmentation Network Based on UAV Images. *Remote Sensing*, vol. 13, n°4.
- Zhu, L., Xie, Z., Liu, L., Tao, B. et Tao, W. (2021) IoU-uniform R-CNN: Breaking through the limitations of RPN. *Pattern Recognition*, vol. 112, n°107816.

## Annexe 1 : Caractéristiques de la caméra du Mavic 3, DJI (tiré de DJI, s.d.)

Caractéristiques	Hasselblad Camera
Capteur	4/3 CMOS, Pixels effectifs : 20 MP
Vitesse d'obturation	Obturbateur électronique: 8-1/8000 s
Lentille	FOV : 84° Format équivalent : 24 mm Ouverture : f/2.8 à f/11 <i>Focus</i> : 1 m à ∞ (avec <i>autofocus</i> )
Plage ISO	Vidéo : 100-6400 Image fixe : 100-6400
Taille de l'image maximale	Unité principale : 5280×3956
Format des photos	JPEG/DNG (Brut)
Format des vidéos	MP4/MOV (MPEG-4 AVC/H.264, HEVC/H.265)
Mode de photographie fixe	Cliché unique : 20MP Photos Bracketing d'exposition automatique : 20 MP, 3/5 image encadrée à 0.7 EV Mode rafale : 20 MP, 3/5/7 Programmé : 20 MP, 2/3/5/7/10/15/20/30/60 s
Résolution des vidéos	H.264/H.265 4K: 3840×2160@24/25/30/48/50/60/120fps
Débit vidéo maximal	H.264/H.265 Bitrate : 200 Mbps Apple ProRes 422 HQ Bitrate : 3,772 Mbps Apple ProRes 422 Bitrate : 2,514 Mbps Apple ProRes 422 LT Bitrate : 1,750 Mbps
Format des fichiers pris en charge	exfat

## Annexe 2 : Listes des vidéos acquises sur les rivières à l'hiver 2022-2023

### Vidéos acquises sur la rivière Coaticook à l'hiver 2022-2023

Nom du fichier	Date	Site	Condition météo	Heure d'acquisition
DJI_0784 à DJI_0788	14-déc-22	C2	Nuageux	10h00 à 10h18
DJI_706, DJI_0794, DJI_0795	14-déc-22	C2	Nuageux	11h23 à 11h41
DJI_0002	09-janv-23	C2	Partiellement nuageux	11h24
DJI_0003 et DJI_0004	09-janv-23	C1	Partiellement nuageux	11h50, 12h03
DJI_0006	09-janv-23	C3	Partiellement nuageux	12h36
DJI_0018 et DJI_0028	10-janv-23	C2	Ensoleillé	9h19 à 9h26
DJI_0029 à DJI_0037	10-janv-23	C3	Partiellement nuageux	10h25, 10h32
DJI_0040 à DJI_0049	10-janv-23	C1	Ensoleillé	12h11, 12h25
DJI_0050 et DJI_0051	10-janv-23	C3	Ensoleillé	13h26, 13h28
DJI_0055 à DJI_0059	11-janv-23	C2	Ensoleillé	9h16 à 9h22
DJI_0060 et DJI_0061	11-janv-23	C1	Ensoleillé	9h29, 9h30
DJI_0062 à DJI_0064	11-janv-23	C3	Ensoleillé	9h55, 9h59
DJI_0079 et DJI_0080	12-janv-23	C2	Nuageux	9h36, 9h37
DJI_0082 et DJI_0083	12-janv-23	C1	Nuageux	9h47, 9h48
DJI_0084 à DJI_0086	12-janv-23	C2	Nuageux	8h52 à 9h57
DJI_0524 et DJI_0525	17-janv-23	C2	Ensoleillé	8h46
DJI_0526 et DJI_0527	17-janv-23	C1	Ensoleillé	8h51
DJI_0529 et DJI_0530	17-janv-23	C2	Ensoleillé	9h48
DJI_0532 et DJI_0533	17-janv-23	C1	Ensoleillé	9h55, 9h58

### Vidéos acquises sur la rivière Massawippi à l'hiver 2022-2023

Nom du fichier	Date	Site	Condition météo	Heure d'acquisition
DJI_0015 à DJI_0017	10-janv-23	M1	Ensoleillé	8h27 à 8h34
DJI_0469 à DJI_0476	01-févr-23	M2	Ensoleillé	8h04 à 8h16
DJI_0479 à DJI_0480	01-févr-23	M1	Ensoleillé	8h33 à 8h37
DJI_0568 à DJI_0572	01-févr-23	M3	Ensoleillé	9h47 à 10h01

### Vidéos acquises sur la rivière Saint-François à l'hiver 2022-2023

Nom du fichier	Date	Site	Condition météo	Heure d'acquisition
DJI_467 et DJI_468	10-janv-23	SF1	Ensoleillé	11h00