



**Département de géomatique appliquée**

Faculté des lettres et sciences humaines

Estimation des limites de vitesse sécuritaires pour les véhicules lourds  
par apprentissage profond et imagerie satellitaire

Par **Chad Marier**

Essai présenté à la Faculté des lettres et sciences humaines

en vue de l'obtention du grade de

**Maître ès sciences (M. Sc.) en géomatique appliquée et télédétection**

Mai 2025

© Chad Marier, 2025

## Jury d'évaluation

### Supervision de l'essai

Mickaël Germain

Département de géomatique appliquée

Université de Sherbrooke

### Cosupervision de l'essai

Samuel Foucher

Département de géomatique appliquée

Université de Sherbrooke

### Examineur interne

Yves Voirin

Département de géomatique appliquée

Université de Sherbrooke

**Dépôt initial le 21-01-2025**

**Dépôt final le 21-05-2025**

## Résumé

La sécurité routière constitue un enjeu collectif ayant bénéficié des avancées technologiques réalisées au cours des deux dernières décennies. C'est dans ce contexte que l'entreprise montréalaise E-SMART développe des systèmes embarqués pour le domaine du transport routier de marchandises en Amérique du Nord, visant à améliorer la sécurité des usagers ainsi que la protection des biens. Ces systèmes permettent, entre autres, d'immobiliser des véhicules à distance, de sécuriser les passages sous des hauteurs critiques et de respecter les limites de vitesse en temps réel grâce à un système connecté à l'ordinateur de bord du véhicule. Cependant, E-SMART fait face à des défis liés à la disponibilité et à l'exactitude des données utilisées dans le module qui permettant de contrôler la vitesse. En effet, les bases de données provenant de Here Maps et OpenStreetMap (OSM) présentent des limites, notamment des données manquantes, inexactes ou des mises à jour non systématiques. Ces lacunes impactent directement le système de limitation de vitesse, entraînant des restrictions non désirées. Il est donc impératif pour E-SMART d'améliorer la fiabilité des bases de données utilisées afin de garantir un fonctionnement optimal de ses systèmes et de répondre aux besoins de ses utilisateurs. Le présent projet a permis de tester une méthodologie dans le but d'extraire des limites de vitesse potentielles d'un réseau routier à partir d'imagerie satellite. D'après la littérature scientifique à propos de ce sujet, c'est la méthodologie élaborée lors du *SpaceNet 5 Challenge* qui a été retenue. Cette méthode consiste à utiliser un modèle de segmentation sémantique, soit le modèle CRESIV2, permettant d'extraire le réseau routier et de prédire les limites de vitesse associées. La méthode a été appliquée à quatre sites d'études en Amérique du Nord. Les limites de vitesse prédites ont été comparées à partir des données de réseaux routiers provenant de différentes sources en fonction des sites d'études (OSM, E-SMART et la Ville de Sherbrooke). En moyenne, 22 % des vitesses prédites se trouvent dans la bonne classe de vitesse. Les calculs de MAE et de RMSE ont montré que les vitesses prédites se trouvent généralement à plus ou moins une classe de vitesse d'être la classe véritable. La limitation principale de la méthodologie testée réside dans l'utilisation du modèle CRESIV2 qui a été entraîné à partir d'images satellites à travers le monde. Un modèle entraîné strictement en Amérique du Nord aurait un potentiel accru dans la prédiction des limites de vitesse.

**Mots-clés :** Apprentissage profond; télédétection; réseau routier; modèle de segmentation; imagerie satellitaire; sécurité routière

# Table des matières

Résumé .....	i
Table des matières .....	ii
Liste des tableaux .....	iii
Liste des figures .....	iv
Liste des sigles.....	v
Liste des unités de mesure .....	vi
Remerciements.....	vii
<b>1. Introduction .....</b>	<b>1</b>
1.1. Mise en contexte.....	1
1.2. Problématique.....	2
1.3. Objectifs .....	3
<b>2. Cadre théorique.....</b>	<b>3</b>
2.1. Données de limites de vitesse.....	3
2.1.1. Détermination des limites de vitesse .....	3
2.1.2. Champs d'application.....	6
2.1.3. Disponibilité de la donnée.....	6
2.2. L'intelligence artificielle.....	7
2.2.1. Généralités en apprentissage profond .....	8
2.2.2. Apprentissage profond en télédétection .....	10
2.3. Estimation des limites de vitesse .....	11
<b>3. Matériel et méthodes.....</b>	<b>14</b>
3.1. Territoire d'étude .....	14
3.2. Données .....	15
3.3. Méthodes d'analyse .....	18
3.3.1. Préparation des données .....	20
3.3.2. Extraction des routes et prédiction des limites de vitesse .....	20
3.3.3. Post-traitements et préparation à l'analyse.....	24
<b>4. Résultats.....</b>	<b>26</b>
4.1. Réseaux routiers extraits et limites de vitesse .....	26
4.2. Évaluation des estimations de limites de vitesse .....	31
<b>5. Interprétation et discussion des résultats.....</b>	<b>36</b>
5.1. Évaluation de l'atteinte des objectifs de l'essai .....	36
5.2. Limites et recommandations.....	37
<b>6. Conclusion.....</b>	<b>38</b>
<b>Bibliographie.....</b>	<b>40</b>

## Liste des tableaux

Tableau 1. Répartition de la charge des classes de routes au Québec .....	4
Tableau 2. Vitesses légales temporaires pour une voie de circulation restante .....	5
Tableau 3. États américains limitant la vitesse maximale des véhicules lourds .....	6
Tableau 4. Paramètres utilisés pour estimer la vitesse moyenne de déplacement .....	11
Tableau 5. Classification de limites de vitesse (mph) selon des attributs.....	13
Tableau 6. Comparaison des métriques de performances de CRESIV2 .....	13
Tableau 7. Comparaison des performances de CRESIV2 comparées à d'autres algorithmes.....	14
Tableau 8. Sources de données utilisées dans le projet .....	17
Tableau 9. Données utilisées à l'entraînement du modèle CRESIV2 .....	21
Tableau 10. Résultats des 5 meilleurs modèles lors du SpaceNet 5 Challenge .....	22
Tableau 11. Classification des limites de vitesse.....	26
Tableau 12. Répartition des routes prédites par classe de vitesse pour chaque site d'étude .....	30
Tableau 13. Répartition des prédictions de classes de vitesse en fonction du type de route à Montréal.....	32
Tableau 14. Répartition des prédictions de classes de vitesse en fonction du type de route à Sherbrooke .	33
Tableau 15. Répartition des prédictions de classes de vitesse en fonction du type de route à Akron .....	34
Tableau 16. Répartition des prédictions de classes de vitesse en fonction du type de route à Keasbey.....	35
Tableau 17. Résultats des métriques d'évaluation MAE et RMSE pour les différents sites d'études.....	35

## Liste des figures

Figure 1. Diagramme de Venn des différentes couches de l'IA à l'apprentissage profond .....	8
Figure 2. Comparaison d'un neurone biologique à neurone artificiel .....	9
Figure 3. Techniques d'apprentissage profond utilisées analyse d'image.....	11
Figure 4. Extraction des routes et inférences des classes de limites de vitesse à partir d'une image satellite par l'algorithme CRESIv2.....	12
Figure 5. Localisation des 4 sites à l'étude en Amérique du Nord.....	15
Figure 6. Réseaux routiers des sites d'études au Canada .....	17
Figure 7. Réseaux routiers des sites d'études aux États-Unis .....	18
Figure 8. Schéma méthodologique du projet.....	19
Figure 9. Mosaïque des tuiles d'images satellites 256 x 256 pixels et tuilage de la mosaïque en images de 1300 x 1300 pixels .....	20
Figure 10. Masques de segmentation en sortie du modèle CRESIv2.....	22
Figure 11. Segmentation des routes de l'image satellite à Akron en Ohio.....	23
Figure 12. Processus de raffinement du masque de segmentation en sortie du modèle CRESIv2.....	24
Figure 13. Processus de squelettisation du masque raffiné en sortie du modèle CRESIv2.....	24
Figure 14. Processus de transformation du Squelette du masque en graphe .....	25
Figure 15. Réseau routier extrait et limites de vitesse classifiées à Montréal .....	27
Figure 16. Réseau routier extrait et limites de vitesse classifiées à Sherbrooke .....	28
Figure 17. Réseau routier extrait et limites de vitesse classifiées à Akron.....	29
Figure 18. Réseau routier extrait et limites de vitesse classifiées à Keasbey .....	30
Figure 19. Répartition des prédictions de classe de vitesse en fonction des classes de vitesses réelles à Montréal .....	31
Figure 20. Répartition des prédictions de classe de vitesse en fonction des classes de vitesses réelles à Sherbrooke .....	32
Figure 21. Répartition des prédictions de classe de vitesse en fonction des classes de vitesses réelles à Akron.....	33
Figure 22. Répartition des prédictions de classe de vitesse en fonction des classes de vitesses réelles à Keasbey .....	34

## Liste des sigles

API	Interface de programmation d'application
CRESIV2	City-scale road extraction from satellite imagery v2
Geojson	Format d'encodage json incluant les informations géospatiales
MAE	Erreur absolue moyenne
OSM	OpenStreetMap
RMSE	Racine carrée de la moyenne des erreurs quadratiques
RNA	Réseau de neurones artificiels
SIG	Système d'information géographique.
SN5	SpaceNet 5 Challenge

## Liste des unités de mesure

km/h	Kilomètre par heure
km <sup>2</sup>	Kilomètre carré
mph	Mile par heure



## **Remerciements**

Merci à mon directeur Mickaël Germain ainsi qu'à mon codirecteur Samuel Foucher pour leur soutien tout au long de ce projet. Ce dernier n'a pas été de tout repos et a nécessité plusieurs essais et erreurs.

Merci à E-SMART pour la proposition du projet, et plus particulièrement à Raphaël Jean, directeur de la recherche et du développement, pour son aide technique et son soutien moral.

Merci à ma conjointe Gabrielle, qui m'a encouragé tout au long du processus.

Merci à ma famille, qui a toujours cru en moi.

Finalement, merci à tous mes amis pour leur soutien tout au long de ce parcours universitaire.

# 1. Introduction

## 1.1. Mise en contexte

La sécurité routière est un enjeu collectif dont les avancements bénéficient à tous. Les efforts déployés au cours des deux dernières décennies afin de rendre le réseau routier plus sûr montrent qu'il a été possible de réduire à la fois le risque d'accident et leur gravité. Au Canada, entre 2003 et 2022, le nombre de collisions rapportées au travers de rapports de police a réduit d'environ 40 % pour les accidents avec blessures et de 30 % pour les accidents mortels (Statistiques Canada, 2024). Pour la même période aux États-Unis, en tenant compte de la démographie, le nombre de décès dus aux accidents de la route a reculé d'environ 13 % (*Insurance Institute for Highway Safety*, 2022). Malgré ces diminutions importantes, pour certains facteurs de risque ou de gravité, il est impossible d'exercer un contrôle absolu, et ce même en accentuant les conséquences prévues par la loi. Il s'agit notamment de facteurs tels que la conduite avec facultés affaiblies (drogues, alcool et fatigue) et le respect des limites de vitesse (OMS, 2004). Toujours selon les chiffres rapportés par Statistiques Canada, les décès survenus lors d'accidents de la route en 2022 ayant pour facteurs contributifs les facultés affaiblies (drogues et alcool) sont établis à 23 % alors que pour la vitesse on retrouve 21,9 % (Statistiques Canada, 2024).

Néanmoins, les progrès technologiques actuels et en voie de développement offrent de nouvelles perspectives en proposant une assistance à la conduite, voire une conduite autonome à différents niveaux (Badue *et al.*, 2021). L'automatisation d'un véhicule est définie en cinq niveaux par la *Society of Automotive Engineers* (SAE). Le niveau 0 correspond à la situation où le conducteur doit entièrement gérer la conduite tandis que le niveau 1 offre une aide à la conduite comme l'alignement du véhicule dans la voie et le contrôle adaptatif du régulateur de vitesse. L'automatisation véritable de la conduite débute au niveau 3 et c'est au niveau 5 que la conduite est entièrement prise en charge par le système du véhicule (SAE International, 2021).

Dans ce contexte, l'entreprise E-SMART située à Montréal, œuvre dans la conception et la commercialisation d'outils technologiques. Ces outils sont actuellement intégrés dans le domaine du transport routier de marchandises en Amérique du Nord. Les solutions proposées par l'entreprise favorisent la sécurité routière et la protection des marchandises. Plus spécifiquement, les systèmes actuels permettent entre autres d'immobiliser un véhicule lourd à distance, de sécuriser le véhicule

à l'approche de hauteurs libres comportant un risque de collision et le respect des limites de vitesse en temps réel.

Cet essai, réalisé en collaboration avec des membres du corps professoral de l'Université de Sherbrooke et le directeur de recherche et développement de E-SMART, vise à proposer une solution technique en lien avec le système intégré de limitation de vitesse. Ce système, connecté à la pédale d'accélérateur, limite la vitesse en fonction de la position en temps réel du véhicule et du réseau routier parcouru. Pour que cette fonctionnalité soit opérable, il est primordial pour E-SMART d'intégrer des données fiables concernant les limites de vitesse du réseau routier afin de ne pas impacter négativement la conduite de ses utilisateurs.

## **1.2. Problématique**

La problématique rencontrée par l'entreprise E-SMART réside dans la disponibilité et l'exactitude des intrants utilisés au sein du système de gestion des limites de vitesse. Les bases de données utilisées dans le système permettant de restreindre la vitesse maximale des véhicules lourds proviennent de l'entreprise Here Maps et de l'organisme sans but lucratif OpenStreetMap (OSM). Here Maps propose diverses solutions payantes en lien avec la cartographie routière. Cependant, cette solution ne permet pas à elle seule de couvrir l'étendue de l'Amérique du Nord en ce qui a trait aux données de limites de vitesse d'autant plus que certaines données ne sont pas exactes. C'est la raison pour laquelle OSM a été intégrée, soit pour permettre d'élargir la base de données et en permettant une comparaison d'attributs. Bien qu'OSM consiste en une base de données massive de données vectorielles, telles que les empreintes de bâtiments, les espaces verts et les routes, l'utilisation de ces données à grande échelle présente certaines lacunes. En effet, l'attribut de limites de vitesse rattaché aux routes comporte fréquemment une valeur non renseignée. De plus, certaines routes peuvent être manquantes ou non représentatives de la réalité du fait des mises à jour non systématiques. Le caractère collaboratif d'OSM implique également un risque d'erreur en raison de la qualité variable des contributions. Ainsi, lorsque ces données sont manquantes ou erronées, le système développé par E-SMART en est directement impacté, conduisant à des restrictions de vitesse maximale non désirées. Il est donc essentiel pour l'entreprise de remédier aux lacunes rencontrées par l'utilisation de ces bases de données afin de bénéficier d'une base de données cohérente avec le réseau routier actuel.

### **1.3. Objectifs**

L'objectif principal de cet essai vise à établir une preuve de concept mettant en œuvre une méthode automatisée d'estimation des limites de vitesse d'un réseau routier à partir d'images satellites.

Les sous objectifs permettant de réaliser l'objectif principal sont :

1. Déterminer une méthode reproductible;
2. Appliquer la méthodologie sur des cas concrets en Amérique du Nord;
3. Évaluer la précision des limites de vitesse prédites.

## **2. Cadre théorique**

Cette revue de littérature vise à brosser un portrait global des données relatives aux limites de vitesse afin de mieux cerner la problématique énoncée. La section 2.1 présente le contexte entourant les limites de vitesse, de leur détermination à leur accessibilité, en passant par leurs champs d'application. La section 2.2 aborde l'intelligence artificielle, en mettant l'accent sur l'apprentissage profond et son utilisation dans le traitement d'images satellites. Enfin, la section 2.3 expose différentes approches existantes pour l'estimation des limites de vitesse à partir des données routières.

### **2.1. Données de limites de vitesse**

À priori, les limites de vitesse indiquées au sein du réseau routier semblent instinctives. En réalité, le réseau routier comporte une complexité étroitement liée au contexte géographique et politique, ce qui rend la généralisation des limites de vitesse excessivement ardue, voire impossible pour une région aussi étendue que l'Amérique du Nord. C'est l'une des raisons qui pourraient expliquer l'absence de couverture des données de limites de vitesse à travers des bases de données ouvertes. Pourtant, ces données sont une plus-value dans un contexte où les champs d'applications se multiplient et s'affinent au fil des ans.

#### **2.1.1. Détermination des limites de vitesse**

Plusieurs éléments entrent en jeu dans la définition des limitations de vitesse des routes. Cela est fortement influencé par l'emplacement géographique. D'une part, les limites de vitesse diffèrent d'un pays à un autre, mais aussi entre les divisions administratives législatives qui les composent

comme les États ou les provinces. D'autre part, il s'agit de règles basées en fonction de la classe de route et de la sécurité routière.

Au Québec, le réseau routier est principalement composé de trois classes fonctionnelles: le réseau supérieur, le réseau local et le réseau d'accès aux ressources (MTMDET, 2025 -a). Pour chacune de ces classes fonctionnelles, des classes de route y sont associées quels que soient l'endroit et où une entité administrative gouvernementale est chargée de déterminer les limites de vitesse. Les deux principales entités administratives sont le ministère des Transports et de la Mobilité durable (MTMDET) et les municipalités (tableau 1) (MTMDET, 2025 -a).

**Tableau 1. Répartition de la charge des classes de routes au Québec**

Classe	Définition
<b>Routes à la charge du ministère des Transports du Québec</b>	
<b>Autoroutes</b>	Voie à accès limitée à circulation à haute vitesse ne comportant pas, sauf exception, d'intersection à niveau.
<b>Routes nationales</b>	Principaux axes routiers autres que les autoroutes, reliant les agglomérations urbaines importantes OU routes touristiques et d'accès à des infrastructures d'envergure nationale ou internationale (aéroports, traverses maritimes, etc.).
<b>Routes régionales</b>	Ces routes relient les agglomérations urbaines secondaires entre elles et entre celles-ci et les villes principales. Elles permettent également l'accès aux infrastructures d'envergure régionale.
<b>Routes collectrices</b>	Routes liant les agglomérations rurales entre elles et avec les centres urbains à proximité, ou encore les liaisons secondaires entre petites agglomérations urbaines.
<b>Routes d'accès aux ressources</b>	Ce sont des routes qui permettent l'accès à des ressources forestières, minières ou à des ouvrages hydroélectriques dans les régions isolées.
<b>Routes à la charge des municipalités</b>	
<b>Routes locales de niveau 1</b>	Elles relient les centres ruraux entre eux.
<b>Routes locales de niveau 2</b>	Elles donnent accès aux propriétés rurales habitées en permanence.
<b>Routes locales de niveau 3</b>	Elles donnent accès à des propriétés non habitées à l'année. Les rues résidentielles des villes font également partie de cette classe.

Tableau tiré du MTMDET (2025 -a).

Sur le plan de la sécurité, la présence de risque est prise en considération autant pour le conducteur que pour les autres usagers de la route ainsi que les individus vulnérables. C'est pourquoi la limite permise se voit à la baisse lorsqu'il y a un partage de la route avec des usagers tels que les cyclistes et les piétons, dans une zone de réduction de la distance de visibilité et au sein des zones scolaires (MTMDET, 2025 -b).

Les limites de vitesse ne sont pas toujours statiques dans le temps. En effet, elles peuvent être modifiées dans le cas d'accidents récurrents dans certaines zones ou lorsqu'un ajout routier nécessite une révision des limites de vitesse. Aussi, certaines limites de vitesse sont variables soit pour une période de l'année ou un horaire journalier comme c'est le cas pour les zones scolaires (MTMDET, 2023). Un autre élément à prendre en considération, fluctuant temporellement, est la modification de la limite de vitesse en présence de chantiers qui affectent le réseau routier. Cela est dû au fait que ces zones temporaires comportent un lot de risque élevé pour les ouvriers, mais aussi pour les utilisateurs du réseau routier (CNESST, 2022). Par exemple, lorsqu'une autoroute à plusieurs voies se voit restreinte à une seule voie carrossable, la limite de vitesse fixée dépend de facteurs comme la largeur de la voie, du nombre d'accotements et la présence d'éléments comme des glissières, d'éléments visuels, etc (tableau 2). De plus, la présence ou non d'une aire sécurisée au chantier peut impacter la détermination de la limite de vitesse temporaire (ministère des Transports du Québec, 2021).

**Tableau 2. Vitesses légales temporaires pour une voie de circulation restante**

Largeur de voie (m)	Cas applicable							
	1.A.1 1.A.2 1.A.3 1.A.4 1.A.5 1.A.6 1.A.7 1.A.8 1.A.9	1.B.1 1.B.2 1.B.3	1.C.1	1.A.10	1.B.4 1.B.5 1.B.6 1.B.7 1.B.8	1.C.2	1.C.3	
	3,7	90 km/h			80 km/h		80 km/h	80 km/h
	3,6							
	3,5							
	3,4							
	3,3	90 km/h			80 km/h		70 km/h	70 km/h
	3,2							
	3,1							
	3,0							

Tableau tiré du ministère des Transports du Québec (2021).

Les limites de vitesse peuvent aussi varier selon le type d'utilisateur de la route. C'est particulièrement le cas pour les véhicules lourds aux États-Unis où certains États comme la Californie peuvent réduire la limite de vitesse permise de 15 mph comparativement à celle des automobiles (tableau 3) (National Motorists Association, 2024). Au Québec, depuis 2009, les véhicules lourds sont soumis à une restriction active de 105 km/h, et ce même pour les véhicules provenant de l'extérieur de la province (MTMDET, 2025 -c).

**Tableau 3. États américains limitant la vitesse maximale des véhicules lourds**

États (É-U)	Véhicule (mph)	Véhicule lourd (mph)
Arkansas	75	70
Californie	70	55
Idaho	75-80	70
Indiana	70	65
Michigan	70-75	65
Montana	80	70
Oregon	65-70	65
Washington	70	60

Tableau tiré de National Motorists Association (2024).

### 2.1.2. Champs d'application

Utilisées de concert avec le réseau routier ou sans, les limites de vitesse offrent une multitude de champs d'application. C'est particulièrement le cas avec certains organismes gouvernementaux qui en bénéficient dans des contextes d'analyse du réseau routier et de mises à jour d'autant plus qu'ils ont la possibilité tenir des bases de données internes à jour. En termes de sécurité routière, les limites de vitesse sont une partie intégrante des études d'aménagement du territoire (ministère des Transports du Québec, 2015). De plus, les données peuvent servir à simuler le réseau routier pour évaluer les trajets des utilisateurs, les temps des courses des véhicules d'urgences et les impacts environnementaux associés (Bonhomme *et al.*, 2016; Othman, 2021).

Les entreprises peuvent aussi tirer profit de cette donnée. En effet, comme les limites de vitesse ne sont pas totalement renseignées via des bases de données ouvertes, il y a une l'opportunité quant à les inventorier et d'en faire la commercialisation. L'application principale se trouve dans les services de cartographie en ligne comme Google Maps et Here Maps fortement utilisés par les automobilistes. Il peut aussi être question d'application dans les systèmes d'aide à la conduite comme celui proposé par E-SMART permettant de limiter la vitesse en temps réel. De plus, comme mentionnés en introduction, les systèmes au sein de véhicules autonomes nécessitent d'intégrer les données de limites de vitesse afin d'être en mesure de les respecter.

### 2.1.3. Disponibilité de la donnée

L'attribut de limite de vitesse fait partie intégrante de la donnée du réseau routier puisqu'il est nécessaire de relier la limite de vitesse à une position géographique ou à un segment de route. Bien que de nombreuses organisations gouvernementales, à différents niveaux, mettent à disposition des

données actualisées sur le réseau routier, l'attribut de limite de vitesse demeure majoritairement absent.

Lorsque l'attribut de limite de vitesse est présent et peut être obtenu en téléchargeant un fichier de format géospatial, c'est bien souvent pour une très fine portion du territoire comme c'est le cas de la ville de Sherbrooke via un portail Web (Ville de Sherbrooke, 2024)

Certains distributeurs privés offrent la possibilité d'accéder aux données. C'est le cas de Google, via une interface de programmation d'application (API), qui permet de lancer des requêtes accédant aux métadonnées du réseau routier. Des coûts sont reliés aux requêtes et il n'est pas possible de télécharger le réseau routier entièrement (Google, 2024). Le même type de solution est proposé par l'entreprise Here Maps.

Une solution existe pour pallier les coûts et obtenir le réseau routier avec les données de limites de vitesse, soit l'utilisation OpenStreetMap (OSM). OSM est une base de données cartographique collaborative gratuite créée en 2004 (OSM, 2024). Celle-ci permet aux utilisateurs du monde entier d'éditer la carte numérique afin d'intégrer des éléments comme le réseau de transport ainsi que des métadonnées associées. Les sources de données sont constituées de traces GPS, d'imageries aériennes et satellites et de données publiques. La limitation principale quant à l'utilisation des données d'OSM est qu'elle est incomplète. De plus, les mises à jour ne sont pas systématiques et les données peuvent comporter des erreurs dues au caractère collaboratif. Les données d'OpenStreetMap sont accessibles via divers moyens. La manière la plus simple d'accéder aux données est d'utiliser directement la cartographie Web qui permet l'exportation de données selon une zone définie manuellement. Une autre façon d'acquérir les données est de passer par une API comme OSM API, OSMnx ou Nominatim API. Certains logiciels permettent l'extraction des données d'OSM comme QGIS en utilisant l'extension QuickOSM dans QGIS (Wiki OSM, 2024).

## **2.2. L'intelligence artificielle**

Afin de comprendre l'apport de l'intégration de l'intelligence artificielle (IA) dans la prédiction des limites de vitesse des routes dans une image, il est approprié de fournir une brève définition des concepts clés en la matière. D'abord, le dictionnaire Larousse définit l'intelligence artificielle comme : « l'ensemble de théories et de techniques mises en œuvre en vue de réaliser des machines capables de simuler l'intelligence » (Larousse, 2024). L'IA décrit le domaine global et comprend des sous-domaines, soit l'apprentissage automatique et l'apprentissage profond. L'apprentissage



automatique (Machine Learning) est défini par la capacité d'un système à acquérir de l'expérience afin d'améliorer ses performances lors de l'exécution d'une tâche, et ce à partir de données brutes et sans intervention humaine (Goodfellow *et al.*, 2016). Dans le cas de l'apprentissage profond (Deep Learning), cette technique est une sous-catégorie de l'apprentissage automatique. La spécificité technique de l'apprentissage profond est l'intégration d'un réseau de neurones artificiel permettant d'accomplir des tâches plus complexes. Pour bien synthétiser ces concepts, on peut les représenter sous forme de schéma, avec plusieurs niveaux, où le niveau englobant correspond à l'IA et le niveau le plus profond à l'apprentissage profond (figure 1).

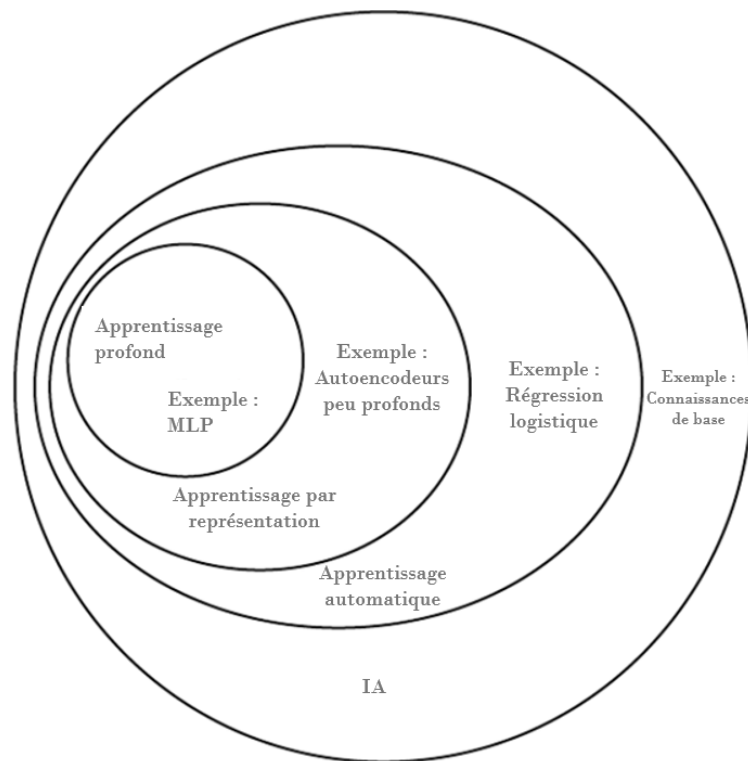


Figure tirée de Goodfellow *et al.*, (2016).

**Figure 1. Diagramme de Venn des différentes couches de l'IA à l'apprentissage profond**

### 2.2.1. Généralités en apprentissage profond

Tout d'abord, l'apprentissage profond est une technique largement utilisée dans diverses disciplines, notamment pour effectuer des prédictions, traiter le langage ou analyser des images en vision par ordinateur (Bai, 2022). Ainsi, grâce à sa démocratisation, une large variété de modèles est disponible et ceux-ci sont adaptés à tous types de données et selon les objectifs. Par exemple,

les réseaux convolutifs (CNN) sont particulièrement adaptés à l'analyse des images, permettant d'extraire automatiquement des caractéristiques visuelles complexes pour des tâches comme la reconnaissance d'objets ou la segmentation d'images. De leur côté, les réseaux récurrents (RNN) et leurs variantes modernes, comme les réseaux de type transformer, sont conçus pour traiter des données séquentielles telles que le texte ou les séries temporelles, ce qui en fait des aides révolutionnaires en traduction automatique ou en prévision de données. Le choix du modèle est donc une étape importante afin de maximiser le potentiel de cette technique.

Plusieurs concepts font partie de l'apprentissage profond de sa composition fondamentale aux diverses étapes d'utilisation. Le premier élément à considérer pour comprendre cette technique, sans doute la pierre angulaire, est le réseau de neurones artificiels (RNA). Souvent comparé au fonctionnement du cerveau humain pour tenter de faciliter sa compréhension, le RNA comprend des neurones artificiels organisés en couches. On peut représenter la composition globale d'un réseau de neurones en 3 grandes étapes orchestrées dans des couches distinctes : la couche d'entrée, les couches cachées et la couche de sortie (figure 2). La couche d'entrée reçoit les données qui seront utilisées pour l'entraînement du modèle. Par exemple, pour une image, l'entrée serait les pixels et leur valeur (Hadi *et al.*, 2023; Sarker, 2021).




Figure tirée de Hadi *et al.*, (2023).

**Figure 2. Comparaison d'un de neurone biologique à neurone artificiel**

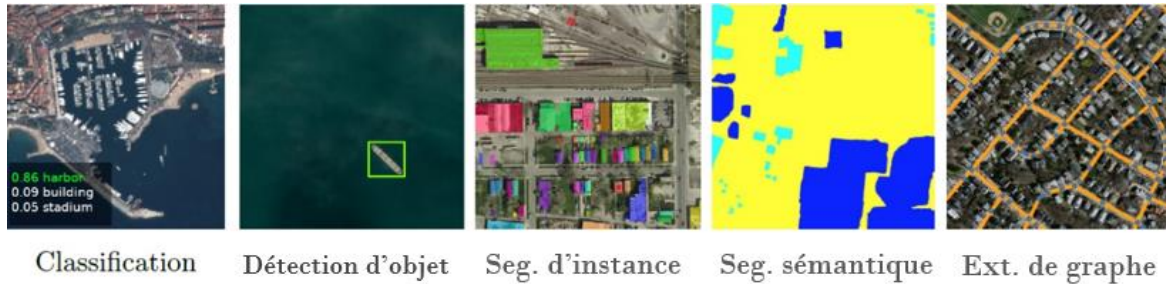
Les neurones des couches cachées ont pour rôle d'extraire des informations pertinentes (caractéristiques) en appliquant des pondérations aux valeurs des données en entrée pour en calculer la somme pondérée qui passe à travers une fonction d'activation. La sortie de la fonction d'activation est envoyée sous forme de signal (information) vers un autre neurone d'une autre couche s'il y en a d'autres. D'ailleurs, plus le modèle contient de couches de neurones, plus celui-

ci sera en mesure d'être performant lors de problématiques complexes comme la détection d'objet. Une fois que la dernière couche des couches cachées est atteinte, la couche de sortie pourra fournir un résultat qui est comparé à la valeur attendue (vérité terrain) à l'aide d'une fonction de perte ce qui permet d'obtenir l'erreur de la prédiction du modèle. Pour qu'il y ait un apprentissage, ces étapes sont répétées maintes fois afin d'optimiser les poids des connexions selon l'erreur obtenue et grâce à des algorithmes d'optimisation. Pour qu'un modèle soit en mesure de prédire adéquatement, celui-ci a besoin d'une certaine quantité d'exemples diversifiés pour augmenter le degré de confiance des prédictions produites (Sarker, 2021).

### 2.2.2. Apprentissage profond en télédétection

Le nombre croissant d'appareils d'acquisition d'images à distance permettent de recueillir de grandes quantités de données. Cela offre donc de nouvelles perspectives dans de nombreux champs d'application reliés au domaine de la télédétection. La quantité et la complexité des données rendent l'intelligence artificielle un atout de taille dans les traitements et les analyses. En effet, les réseaux de neurones exploités à partir d'ordinateurs performants permettent l'automatisation des tâches anciennement effectuées à la main ou à l'œil, en plus de permettre d'effectuer ces tâches à grande échelle. Plus spécifiquement, dans le domaine de l'analyse d'images aéroportées (drone, aéronef ou satellite), les principales techniques d'apprentissage profond couramment utilisées concernent la classification d'images, la détection d'objet, la segmentation d'instance, la segmentation sémantique ainsi que l'extraction de graphes (Bahl, 2022) (figure 3). Chacune de ces techniques comporte des spécificités :

- Classification d'objet : Détermination de la classe d'une image (ce qui est le plus représenté);
- Détection d'objet : Classifier un ou plusieurs objets d'intérêts et déterminer la position de chacun dans l'image en établissant une boîte englobante;
- Segmentation d'instance : Classifier chaque pixel d'un objet, où l'objet est une entité unique et séparée des autres d'une même classe;
- Segmentation sémantique : Classifier chaque pixel de l'image sans nécessairement différencier les classes;
- Extraction de graphes : Détermination d'un réseau composé de sommets et d'arêtes



Comparaison entre la classification, la détection d'objet, la segmentation d'instance et sémantique et l'extraction de graphes. Figure tirée de Bahl (2022).

**Figure 3. Techniques d'apprentissage profond utilisées analyse d'image**

### 2.3. Estimation des limites de vitesse

Tout d'abord, étant donné que la limite de vitesse dépend en majeure partie du contexte, certains exemples dans la littérature montrent qu'il est possible de s'appuyer sur cet élément pour calculer une limite de vitesse probable. Ce contexte peut donc être représenté à partir de paramètres qualitatifs et quantitatifs. C'est ce qui est présenté dans l'article de Beere (2016), celui-ci estime le temps d'un trajet donné en estimant la vitesse moyenne de déplacement en réunissant des paramètres comme le nombre de voies, le type de surface et le type de route (tableau 4). Les données associées aux paramètres utilisés dans cet article proviennent de trois sources de données : d'OSM, d'une couche de données du territoire de la Nouvelle-Zélande ainsi que la *New Zealand Open GPS Maps Project* (Beere, 2016). Les résultats présentés montrent qu'il a été possible d'estimer le temps de déplacement avec une marge d'erreur moyenne d'environ 6,41 % (Beere, 2016).

**Tableau 4. Paramètres utilisés pour estimer la vitesse moyenne de déplacement**

Type de route	Vitesse moyenne estimée
Autoroute urbaine	80km/h
Non-urbain, <=deux voies, scellée, routes droites (<1.2 ratio)	80km/h
Non-urbain, une voie, scellée, routes droites (<1.2 ratio)	70km/h
Non-urbain, >= deux voies, scellée, routes sinueuses (>=1.2 ratio)	60km/h
Routes droites métallisées	50km/h
Non-urbain, une voie, scellée, routes sinueuses (>=1.2 ratio)	40km/h
Route urbaine scellée	30km/h
Routes sinueuses métallisées (>=1.2 ratio)	30km/h

Tableau tiré de Beere (2016).

Lors de la compétition organisée par le *SpaceNet 5 Challenge* (SN5) en 2019, une méthode a été développée dans le but de déterminer le chemin le plus court dans un contexte de déplacement d'urgence. La méthodologie y est présentée par Adam Van Etten dans l'article intitulé : *City-Scale Road Extraction from Satellite Imagery v2: Road Speeds and Travel Times*. Plus spécifiquement, la méthode surnommée CRESIV2 permet de tracer le réseau routier et d'y estimer les limites de vitesse. Cette méthode repose sur l'extraction automatique du réseau routier à partir d'images satellites haute résolution. L'extraction y est réalisée à l'aide d'un modèle d'apprentissage profond préentraîné, qui effectue une segmentation sémantique permettant de prédire la classe de limite de vitesse pour chaque segment de route extrait (Etten, 2020) (figure 4).




Figure tirée de Etten (2020).

**Figure 4. Extraction des routes et inférences des classes de limites de vitesse à partir d'une image satellite par l'algorithme CRESIV2**

Les données qui ont servi à entraîner le modèle sont constituées du réseau routier en format vectoriel et d'images satellites à haute résolution. Le jeu d'entraînement du réseau routier comprend les segments de route étiquetés selon des attributs de la taxonomie d'OSM. Il s'agit du type de route, du type de surface, du nombre de voies et de la présence de ponts (Etten, 2020). Une limite de vitesse a été associée pour chaque type de route en fonction de la table des vitesses des États-Unis retrouvée sur OSM (tableau 5). Ensuite, un facteur est appliqué à la limite de vitesse en fonction de la valeur de certains attributs. Par exemple, si la route n'est pas pavée, la vitesse est multipliée par 0,75 afin de réduire la vitesse maximale.

**Tableau 5. Classification de limites de vitesse (mph) selon des attributs**

Type de route	1 Voie	2 Voies	3+ Voies
Autoroute	55	55	65
Primaire	45	45	55
Secondaire	35	35	45
Tertiaire	30	30	35
Résidentielle	25	25	30
Sans classe	20	20	20
Piste de course	20	20	20

Tableau tiré de Etten (2020).

Les métriques utilisées pour évaluer la performance de l'algorithme dans l'article sont l'*Average Path Length Similarity* (APLS) et la *map topology* (TOPO). L'APLS et le TOPO permettent de comparer le réseau résultant du modèle à un réseau faisant office de vérité terrain à partir d'un calcul déterminant une valeur variant entre 0 (aucune similarité) et 1 (très similaire). Dans le cas de l'APLS, la métrique sert principalement à évaluer les chemins optimaux entre deux nœuds tandis que la métrique TOPO sert à évaluer la similarité locale à un endroit précis dans le réseau. Selon Etten, ces métriques permettent d'évaluer plus efficacement 2 graphes entre eux que les métriques traditionnelles telles que l'*intersection over union* (IOU) ou le *F1 score*.

Les résultats présentés par Etten montrent que l'algorithme développé est capable d'atteindre un score de TOPO de 0,63 et d'APLS en fonction de la longueur des segments de routes de 0,81 et en fonction du temps de trajet de 0,79 à Las Vegas. Cependant, lorsqu'on observe la moyenne en prenant en compte les différentes villes testées, le TOPO se trouve à 0,51, l'APLS<sub>longueur</sub> à 0,67 et l'APLS<sub>temps</sub> à 0,64 (tableau 6) (Etten, 2020). Tout de même, l'algorithme CRESiv2 comparé à d'autres algorithmes du même type montre qu'il est plus performant en TOPO et en APLS (tableau 7).

**Tableau 6. Comparaison des métriques de performances de CRESiv2**

Région d'essai	TOPO	APLS <sub>length</sub>	APLS <sub>time</sub>
Khartoum	0.53 ± 0.09	0.64 ± 0.10	0.61 ± 0.05
Las Vegas	0.63 ± 0.02	0.81 ± 0.04	0.79 ± 0.02
Paris	0.43 ± 0.01	0.66 ± 0.04	0.65 ± 0.02
Shanghai	0.45 ± 0.03	0.55 ± 0.13	0.51 ± 0.11
Total	0.51 ± 0.02	0.67 ± 0.04	0.64 ± 0.03

Tableau tiré de Etten (2020).

**Tableau 7. Comparaison des performances de CRESiv2 comparées à d'autres algorithmes**

Algorithme	Google / OSM (TOPO)	SpaceNet (APLS <sub>length</sub> )
DeepRoadMapper [18]	0.37	0.51 <sup>1</sup>
RoadTracer [3]	0.43	0.58 <sup>1</sup>
OrientationLearning [4]	-	0.64
CRESiv2 (Ours)	<b>0.53</b>	<b>0.67</b>

Tableau tiré de Etten (2020).

Dans cet essai, il sera question de reprendre la méthodologie élaborée lors du *SpaceNet 5 Challenge*. D'une part, cette méthode est reproductible par la disponibilité du code de programmation Python ainsi que le modèle préentraîné à partir du site GitHub et du site Web de la compétition. D'autre part, la méthodologie semble prometteuse afin de répondre aux objectifs fixés.

### 3. Matériel et méthodes

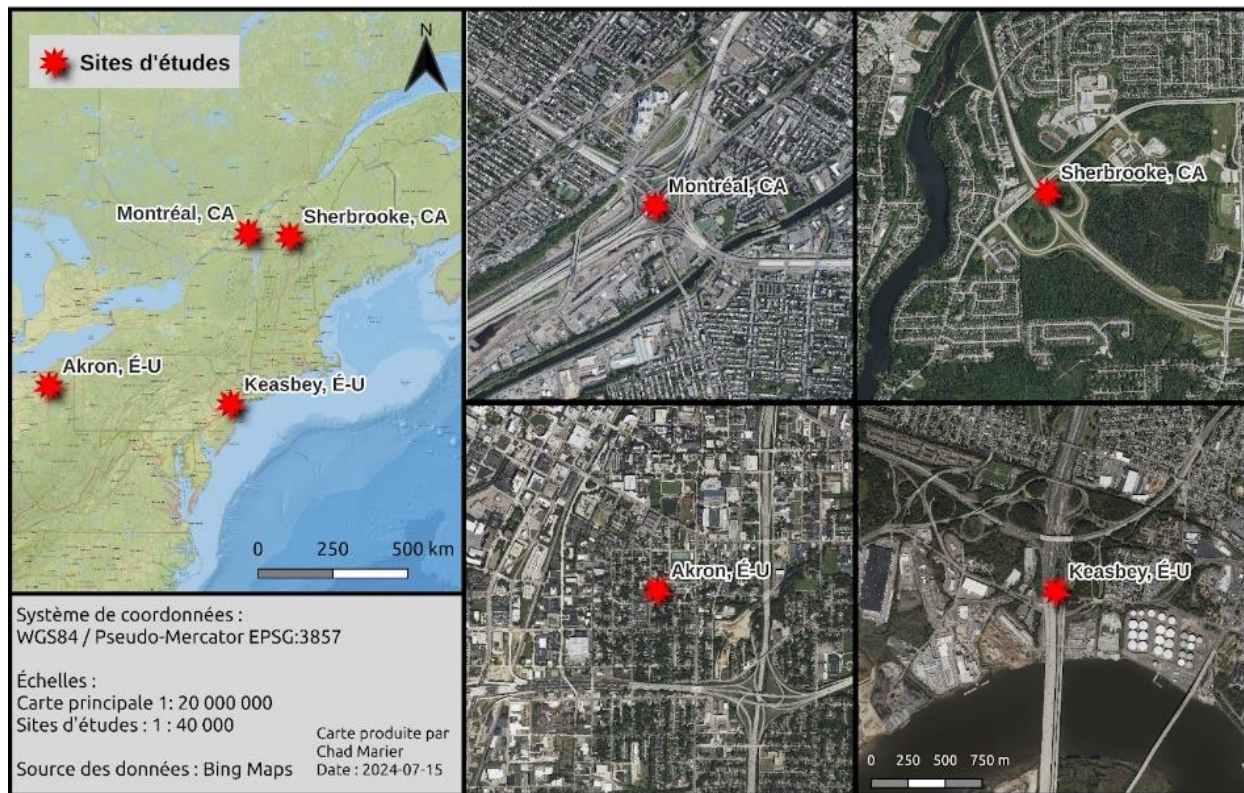
Dans la première section de ce chapitre sont présentés les différents sites d'études et dans la seconde section, les données utilisées dans le cadre de l'essai. Dans la troisième section, la méthodologie est détaillée à l'aide d'un schéma méthodologique et de sections spécifiques aux étapes de la méthode.

#### 3.1. Territoire d'étude

Les quatre sites d'études où la méthodologie élaborée dans le *SpaceNet 5 Challenge* est reproduite se situent en Amérique du Nord (figure 5). Les deux premiers sites se trouvent au Canada dans la province de Québec, soit dans la ville de Montréal et de Sherbrooke. Ces deux sites d'études ont été sélectionnés en raison de la disponibilité des données de limites de vitesse. Pour les deux sites d'étude suivants, ils sont localisés aux États-Unis, dans deux États distincts : à Keasbey, dans le New Jersey, et à Akron, dans l'Ohio. Ces villes ont été déterminées par l'entreprise E-SMART comme étant dans lieux problématiques du fait de l'absence de limitations de vitesse sur une vaste partie du réseau routier. Chaque site d'étude possède une superficie de 12 km<sup>2</sup> mis à part le site d'étude à Sherbrooke où la superficie est de 14,5 km<sup>2</sup> puisque la densité de routes y est plus faible.



La sélection de ces sites s'appuie sur la présence de certains ouvrages routiers d'intérêts. Ainsi, ces sites partagent la particularité d'être composés d'infrastructures routières diversifiées (échangeurs, ponts et/ou viaducs) ce qui permettra une comparaison plus précise. D'autre part, les types de classes de routes les plus fréquentées par les véhicules lourds sont présents dans chacun des sites : autoroutes, bretelles d'autoroute, routes principales et secondaires. Dans les villes telles que Montréal et Akron, le réseau routier y est plus important dues à la densité de bâtiment plus élevée. En somme, l'intérêt de cette sélection de sites est d'observer le comportement du modèle au travers de villes en Amérique du Nord.



**Figure 5. Localisation des 4 sites à l'étude en Amérique du Nord**

### 3.2. Données

L'estimation de limites de vitesse pour les 4 sites d'études en Amérique du Nord nécessite l'utilisation de types de données variées. Il s'agit d'abord de données matricielles, soit de tuiles d'images satellites de 256 x 256 pixels couvrant les zones d'études (tableau 8). Les tuiles ont été obtenues à partir de l'API de Microsoft Bing et datent de 2020 à 2023. Ces tuiles possèdent 3



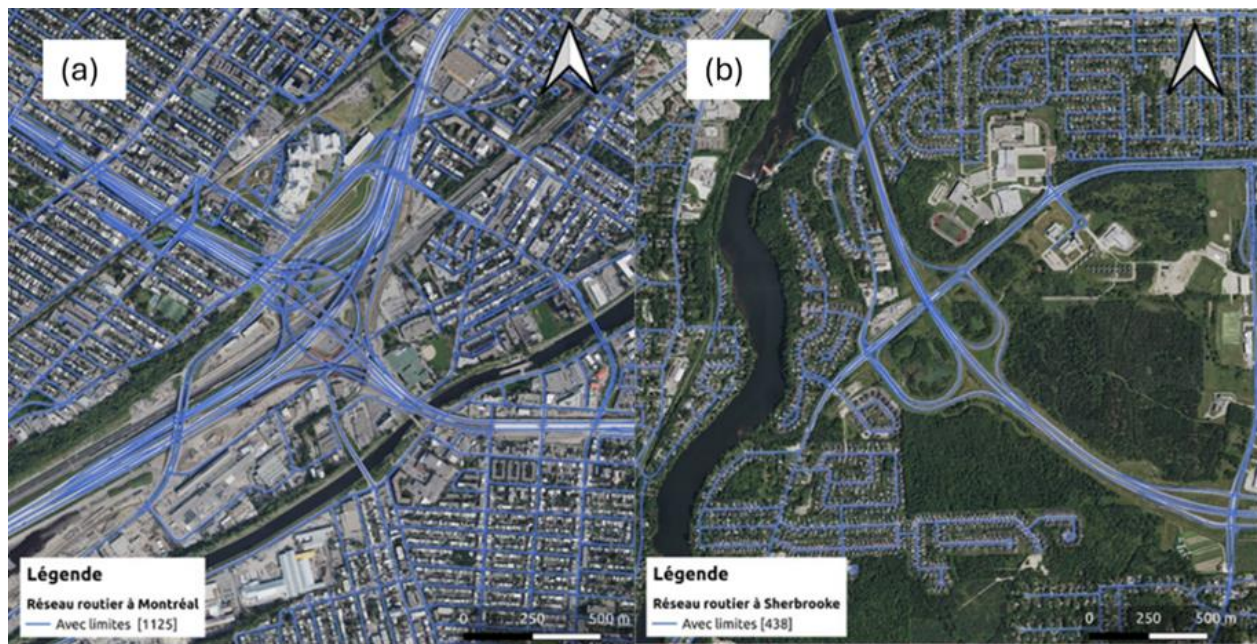
bandes spectrales (RVB) à très haute résolution, soit de 30 centimètres par pixel. Elles ont une profondeur de 8 bits et l'angle de prise de vue est au Nadir. Ces tuiles serviront d'intrants au modèle pour procéder à l'extraction du réseau routier et à la prédiction des limites de vitesse associées.

D'autre part, des données vectorielles sont nécessaires pour des fins de comparaison avec la sortie du modèle de prédictions de limites de vitesse. Il s'agit donc des différents réseaux routiers correspondant aux sites d'étude et possédant un attribut de limite de vitesse et de type de classe de route pour chacun des segments de route. Ces données ont été rassemblées à partir de trois sources différentes en fonction du site d'étude (tableau 8). Pour le site d'étude à Montréal, les données d'OpenStreetMap ont été téléchargées à partir de l'extension QuickOSM disponible dans QGIS (figure 6). Pour Sherbrooke, la ville dispose d'un portail Web permettant d'y télécharger différentes couches de données, dont le réseau routier comprenant les limites de vitesse pour chaque segment (figure 6). En ce qui concerne les villes aux États-Unis (Akron et Keasbey), les données proviennent de l'entreprise E-SMART dont la source est aussi OpenStreetMap. Comme mentionné précédemment, pour certains segments de route dans les données de E-SMART, la limite de vitesse est manquante. À Keasbey, 34 % des routes présentes dans le jeu de données vectorielles ne disposent pas de limite de vitesse, tandis qu'à Akron, ce pourcentage est de 27 % (figure 7).

Une donnée nécessaire à la reproduction de la méthode CRESIv2 élaborée lors du *SpaceNet 5 Challenge* est le modèle de segmentation final. Ceux-ci ont mis à disposition le modèle discuté dans l'article sous format pth à partir d'un service AWS d'Amazon. Ce modèle a été préentraîné à partir d'images satellites et de réseaux routiers vectoriels étiquetés. Les sites d'études visées dans l'article concernaient 4 villes à travers le monde. Les images qui ont été utilisées proviennent du satellite WorldView-3 à une résolution spatiale de 30 cm par pixel (tableau 8).

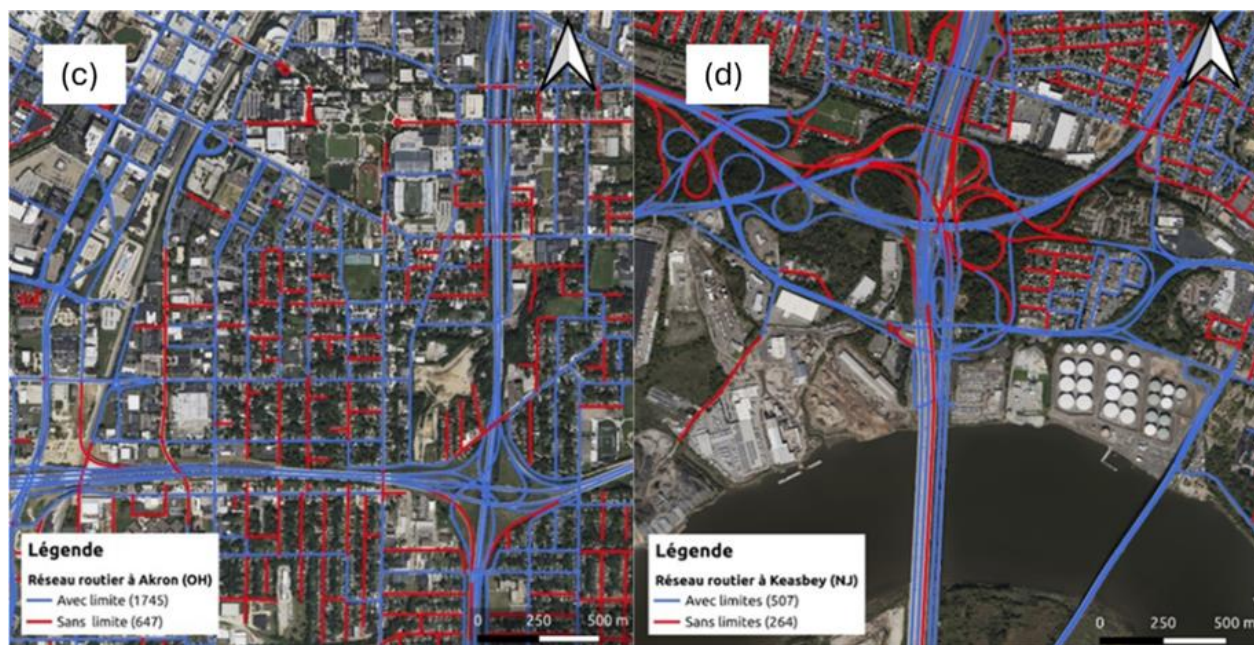
**Tableau 8. Sources de données utilisées dans le projet**

Données	Fournisseur	Description	Date
Images satellites	Bing (Maxar)	Tuiles d'images satellites provenant de Microsoft Bing à une résolution de 30 cm par pixel	2020-2023
Modèle de segmentation	SpaceNet 5 Challenge	Modèle de segmentation entraîné au format pth	2019
Réseau routier	E-SMART	Vecteur de routes du site d'étude à Akron et Keasbey	2024
Réseau routier	OpenStreetMap	Vecteur de routes du site d'étude à Montréal	2024
Réseau routier	Ville de Sherbrooke	Vecteur de routes du site d'étude à Sherbrooke	2024



Données du réseau routier pour les Sites d'étude au Canada, à Montréal (a) et à Sherbrooke (b).

**Figure 6. Réseaux routiers des sites d'études au Canada**



Données du réseau routier pour les Sites d'étude aux États-Unis, à Akron (c) et à Keasbey (d).

**Figure 7. Réseaux routiers des sites d'études aux États-Unis**

### 3.3. Méthodes d'analyse

Dans ce projet, la méthodologie se divise en quatre phases : le prétraitement des données, les traitements principaux et leurs post-traitements, l'analyse des prédictions des limites de vitesse, ainsi que les recommandations et limites du projet (figure 8). Les étapes techniques en lien avec la méthode CRESIV2 s'effectuent dans un espace Docker, en langage de programmation Python. En ce qui a trait à la jointure entre les réseaux routiers réels et ceux produits par la méthodologie ainsi qu'aux calculs des statistiques menant aux résultats, ces étapes ont été réalisées dans un logiciel SIG, soit avec QGIS.

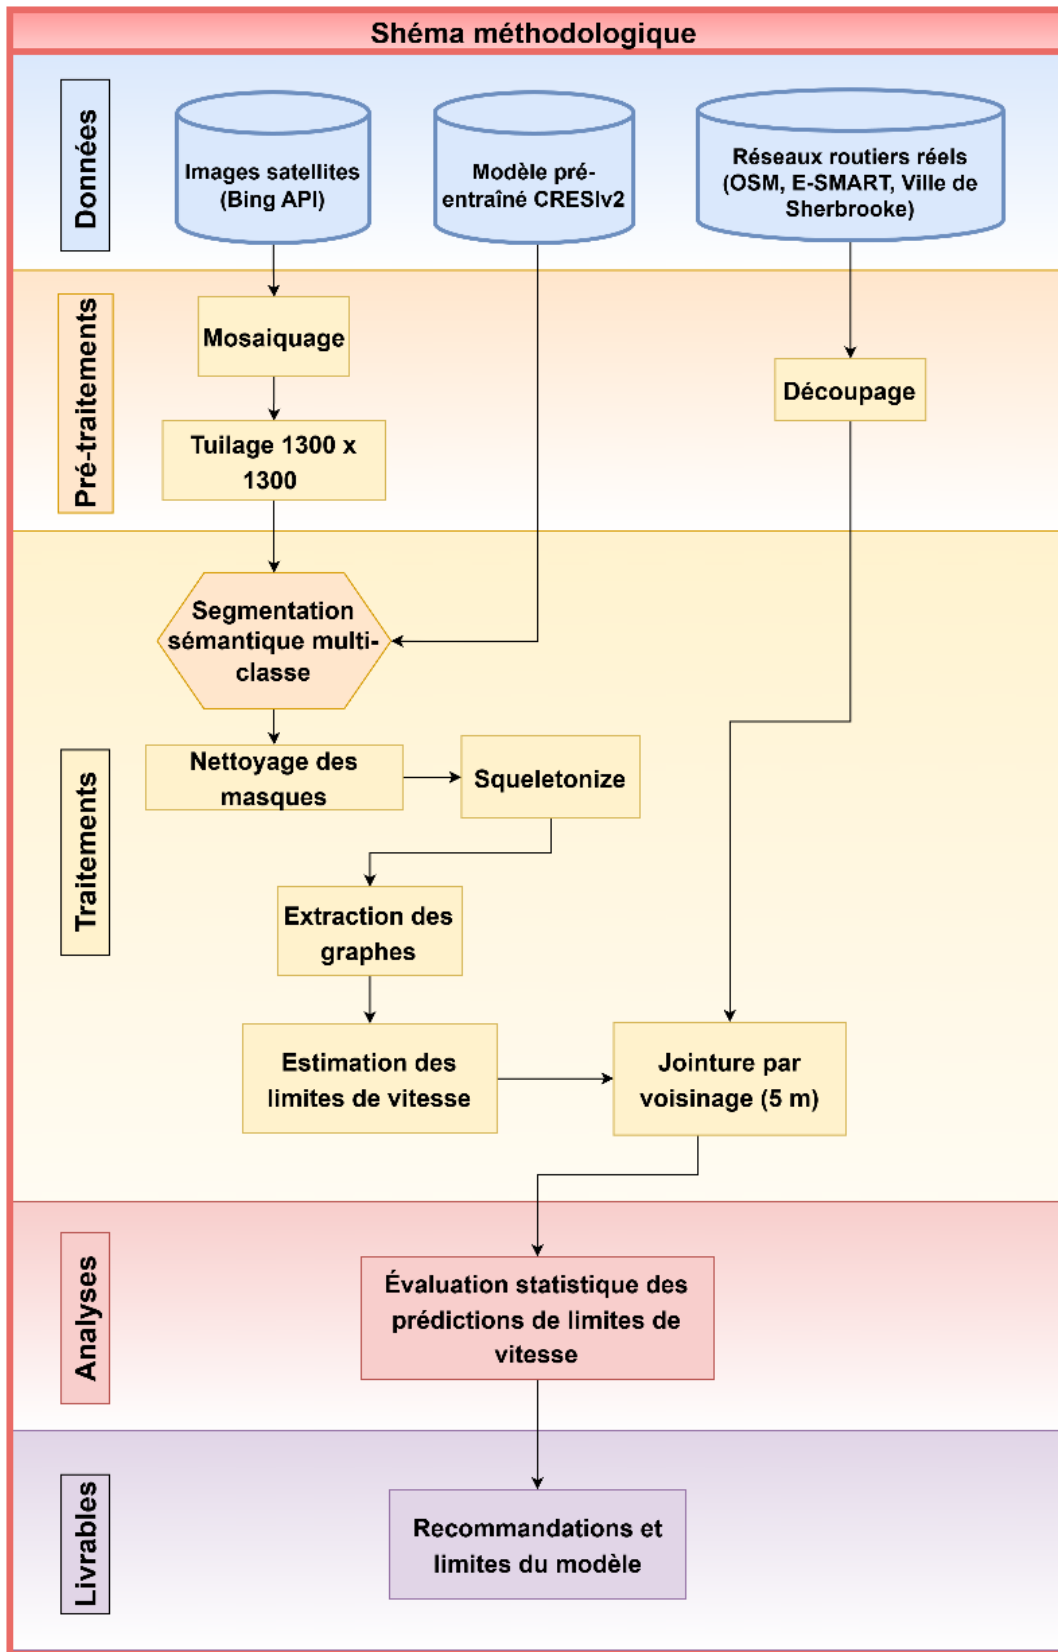
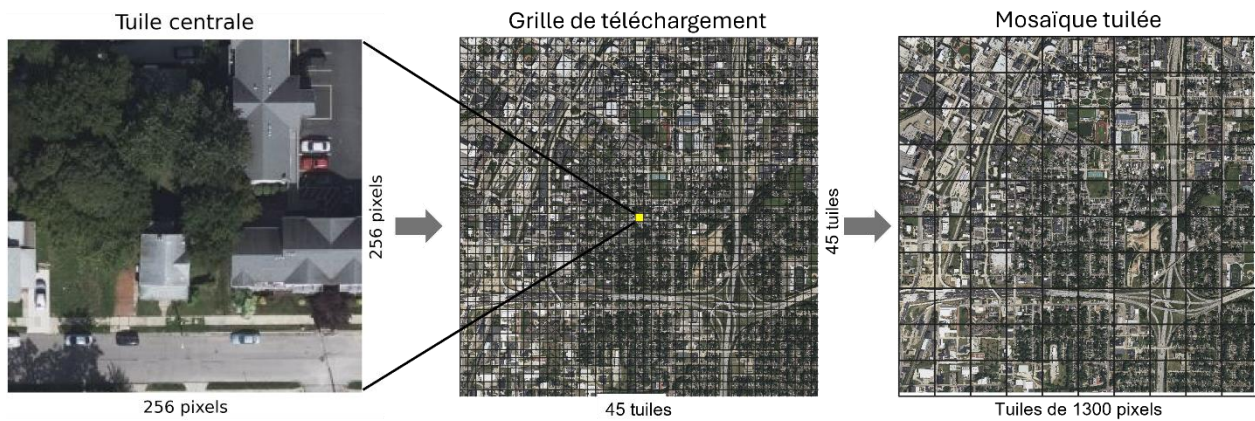


Figure 8. Schéma méthodologique du projet



### 3.3.1. Préparation des données

Tel que mentionné, les imagerie satellites utilisées proviennent de l'API de Bing Maps sous forme de tuile de 256 x 256 pixels à un agrandissement de niveau 19 ce qui permet d'obtenir une résolution par pixel de 30 cm (Microsoft, 2019). Pour chaque site d'étude, une coordonnée géographique est d'abord utilisée afin de télécharger une tuile centrale. Ensuite, les tuiles environnantes sont acquises en fournissant un nombre équivalent de tuiles en x et en y. Par exemple, la zone d'étude à Akron en Ohio possède 45 tuiles de largeur et de hauteur. Les tuiles sont regroupées en une mosaïque pour former l'image couvrant la zone d'étude. Afin de retrouver une taille équivalente à celle utilisée pour l'entraînement du modèle CRESI, la mosaïque est segmentée en tuiles de 1300 x 1300 pixels (Etten, 2019) (figure 9).



**Figure 9. Mosaïque des tuiles d'images satellites 256 x 256 pixels et tuilage de la mosaïque en images de 1300 x 1300 pixels**

À partir de l'étendue des images satellites mosaïquées, les différents réseaux routiers peuvent être découpés. De plus, un nettoyage des données vectorielles est effectué. En effet, les différents réseaux routiers contiennent des données autres que des routes ainsi que des types de classe de route non pertinente au projet tel que des pistes cyclables, voies piétonnes, des stationnements, etc. Ces entités ont été supprimées puisqu'elles ne serviront pas à la comparaison finale avec la sortie du modèle.

### 3.3.2. Extraction des routes et prédiction des limites de vitesse

La méthode employée dans le *SpaceNet 5 Challenge* permet d'extraire le réseau routier d'une image satellitaire en plus de déterminer une classe de vitesse pour chacun des segments de route. Pour ce faire, une segmentation sémantique est effectuée en utilisant un réseau neuronal convolutif (CNN), soit le modèle CRESIv2 préentraîné. Ce modèle a été entraîné à partir d'images satellites

et de réseaux routiers vectoriels de 4 villes à travers le monde, soit Moscou, Mumbai, San Juan et Dar es Salam (tableau 9). Les images proviennent du satellite WorldView-3 à différents angles hors nadir en fonction de la ville. Les images possèdent 8 bandes spectrales de 16 bits, mais seulement les canaux RVB à 30 cm de résolution spatiale sont retenus. De plus, les images ont été converties en 8 bits et segmentées en tuiles de 1300 x 1300 pixels (Etten, 2020).

**Tableau 9. Données utilisées à l'entraînement du modèle CRESIv2**

Ville	Date	Routes (km)	Aire des images (km <sup>2</sup> )	Angle nadir (degré)
Moscou (Russie)	13-02-2018	3,066	1,353	22.4
Mumbai (Inde)	06-01-2018	1,951	1,021	8.6
San Juan (Porto Rico)	05-04-2017	1,139	285	8.4
Dar es Salam (Tanzanie)	-	-	-	-

Tableau tiré de Etten (2020).

Les réseaux routiers utilisés pour l'entraînement ont été étiquetés par l'équipe du SN5, et ce à partir d'attributs qualitatifs, soit la classe de route, le type de chaussé, le nombre de voies, le type de division d'autoroute et la présence ou non de pont. En fonction des valeurs affectées pour chacun de ces attributs, une classe de limite de vitesse a été déterminée (Etten, 2020).


Dans le contexte de la compétition, une série d'essais visant à maximiser les performances a mené vers la détermination d'une architecture et de paramètres optimaux pour la conception du modèle. Pour ces tests, le score  $APLS_{time}$  maximal atteint est de 48.11, obtenu avec un ensemble de 8 modèles : 4 utilisant l'architecture ResNet50 couplée à un encodeur/décodeur UNet et 4 autres utilisant SE-ResNeXt50 avec un encodeur/décodeur UNet. L'inconvénient de cette composition d'architectures réside en un temps d'inférence relativement lent de 1,53 km<sup>2</sup>/min. Le meilleur compromis entre un score  $APLS_{time}$  élevé et le temps d'inférence le plus rapide consiste en l'utilisation du modèle de base de CRESI, qui utilise l'architecture ResNet34 combinée à un encodeur/décodeur U-Net. Ce modèle permet d'obtenir un score d' $APLS_{time}$  de 45.35 et un temps d'inférence de 9.44 km<sup>2</sup> / min (tableau 10) (Etten, 2020). Plus spécifiquement, un saut de connexion est effectué à chaque couche du réseau et un optimisateur Adam est utilisé pour minimiser la fonction de perte. De plus, la fonction de perte utilisée combine la perte focalisée et le coefficient de Dice avec une pondération de 75 % pour la perte focalisée et 25 % pour le coefficient de Dice (Etten, 2020). Dans le cadre de cet essai, le modèle de CRESI a été retenu pour sa précision lors de l'inférence et sa rapidité d'exécution.

**Tableau 10. Résultats des 5 meilleurs modèles lors du SpaceNet 5 Challenge**

	Classement	# Modèles	Modèles de Segmentation	APL <sub>time</sub> Score (x 100)	Temps d'inférence (km <sup>2</sup> / min)
<b>CRESI (baseline)</b>	N/A	1	1 × ResNet34 + UNet	45.35	9.44
<b>XD-XD</b>	1	8	4 × ResNet50 + UNet 4 × SE-ResNeXt50 + UNet	48.11	1.53
<b>cannab</b>	2	12	4 × SE-ResNeXt50 + UNet 4 × DPN92 + UNet 4 × ResNet34 + UNet	48.03	0.61
<b>selim_sef</b>	3	12	6 × InceptionResNetV2 + UNet 6 × DPN92 + UNet	46.82	0.72
<b>ikibardin</b>	4	15	6 × ResNeXt101 + UNet 6 × ResNet50 + FPN 3 × SE-ResNeXt50 + UNet	45.77	0.62
<b>schapke</b>	5	4	4 × ResNet34 + UNet	45.41	3.72


Tableau tiré de Etten (2020).

Une fois les tuiles d'images satellites de 1300 x 1300 pixels intégrés au sein du modèle, celui-ci génère un masque de segmentation comportant 8 canaux. Les 7 premiers canaux représentent une classe d'intervalle de limite de vitesse en mph à l'exception du dernier canal qui contient l'agrégation des 7 canaux (figure 10). Le masque 0 contient la classe des routes prédites de 1 à 17,5 mph et le masque 6, les vitesses de 61 à 70 mph. Ensuite, le dernier canal de chacune des tuiles est regroupé et normalisé afin de correspondre à la taille initiale du site d'étude (figure 11).



Les 8 masques de segmentation en sortie du modèle CRESI pour une tuile à Akron en Ohio. Les 7 premiers masques représentent les classes d'intervalle de limites de vitesse alors que le dernier est l'agrégation de ces masques.

**Figure 10. Masques de segmentation en sortie du modèle CRESIv2**




**Figure 11. Segmentation des routes de l'image satellite à Akron en Ohio.**

L'estimation des limites de vitesse est générée lors des prédictions de routes générées par le modèle. En effet, lorsque le modèle détecte une route à partir des images satellites, une valeur de confiance de route est attribuée à chacun des pixels de cette route. Une fois le graphe créé, pour chacun des centroïdes des arêtes, une fenêtre de 8 x 8 pixels est analysée pour retrouver le masque d'intervalle de vitesse qui contient la majorité de pixels de confiance de route. La vitesse est alors assignée au graphe en prenant la valeur centrale de l'intervalle de vitesse du masque. Par exemple, si la majorité des pixels de la fenêtre se trouve dans le masque 6 (61-70 mph), la limite de vitesse assignée sera 65 mph (Etten, 2020).




### 3.3.3. Post-traitements et préparation à l'analyse

L'inférence, dans le cas de la prédiction des routes, a tendance à occasionner des variations abruptes et du bruit dans les masques générés. De plus, les frontières y sont parfois irrégulières. Afin de pallier ces problèmes, un lissage par filtre gaussien avec un noyau de 2 mètres est appliqué, soit par fenêtre d'environ 7 x 7 pixels. De plus, un lissage est appliqué permettant d'éliminer la présence de trous et de petits objets de moins de 30 m<sup>2</sup> (figure 12). Le masque raffiné est ensuite transformé afin que le réseau routier soit sous forme squelettique. Cette forme squelettique réduit le réseau routier à une taille d'un pixel. De plus, l'image est binarisée de sorte que les valeurs nulles ou aberrantes soient considérées comme de l'arrière-plan (figure 13). Cette étape est nécessaire pour la construction du graphe, permettant de stocker les attributs en lien avec le réseau routier.



Le masque de segmentation en sortie du modèle (a) et le raffinement appliqué (b). Figure tirée de Etten (2020).

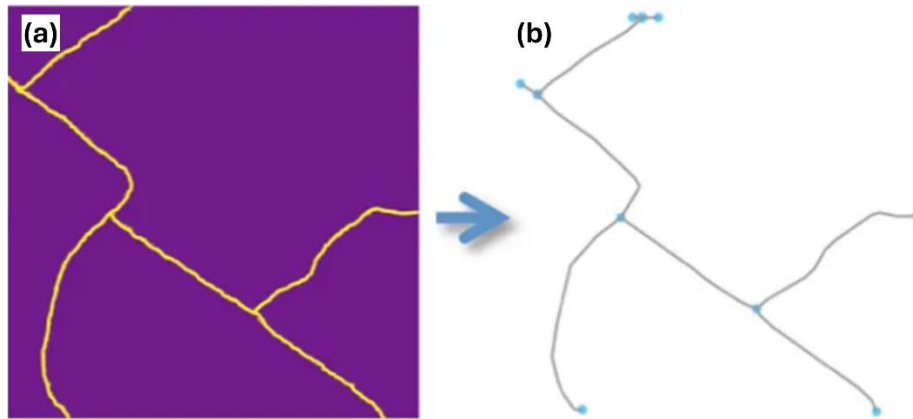
**Figure 12. Processus de raffinement du masque de segmentation en sortie du modèle CRESIv2**



Le masque raffiné (a) et la squelettisation du masque (b). Figure tirée de Etten (2020).

**Figure 13. Processus de squelettisation du masque raffiné en sortie du modèle CRESIv2**

Le graphe produit à partir du squelette du réseau routier s'effectue avec la librairie sknw ce qui génère une structure graphique NetworkX (figure 14). Cette structure permet la création de sommets entre les arêtes, soit la segmentation du réseau routier. Un nettoyage est effectué afin de retirer les petites arêtes non connectées ainsi que les sous-graphes.



Squelette du masque (a) et transformé en graphe (b). Figure tirée de Etten (2020).

**Figure 14. Processus de transformation du Squelette du masque en graphe**

Afin de permettre la comparaison des graphes produits par le modèle aux différents réseaux routiers des sites d'études possédant les limites de vitesse réelles, les graphes ont été transformés en un format de données permettant une visualisation géoréférencée dans un SIG, soit en format Geojson. Ensuite, pour chaque segment du graphe, une recherche par proximité à une distance maximale de 5 m est effectuée avec le réseau routier du site d'étude correspondant. Ainsi, cela permet de retrouver une correspondance entre les deux couches de données et d'y joindre l'attribut de la vraie vitesse provenant des différentes sources de données. Lorsqu'il n'y a pas de correspondance ou lorsqu'il n'y a pas de vitesse disponible dans les données réelles, les segments du graphe sont tout simplement retirés. De plus, une vérification manuelle est effectuée lorsqu'un segment du graphe a plusieurs voisins provenant du réseau routier véritable. Cela permet d'éviter les jointures multiples et de fausser les résultats.

Dans la couche de données issue de la jointure des deux réseaux routiers, une transformation des limites de vitesse est effectuée. En effet, comme les limites de vitesse produites par le modèle sont définies en 6 classes distinctes, il est nécessaire de convertir les limites de vitesse des réseaux routiers véritables afin de les rendre compatibles aux classes de vitesses obtenues en sortie du modèle (tableau 11).

**Tableau 11. Classification des limites de vitesse**

<b>Limites de vitesse (km/h)</b>	<b>Limites de vitesse (mph)</b>	<b>Classe de limites de vitesse du modèle (mph)</b>
< 33	< 21	17,5
33-48	21-30	25
49-64	31-40	35
65-80	41-50	45
81-96	51-60	55
> 96	> 60	65

## **4. Résultats**

Dans cette section, les résultats obtenus à la suite de l'extraction des routes et de la prédiction des limites de vitesse sont d'abord présentés cartographiquement. Ensuite, il est question d'une évaluation comparative des limites de vitesse entre les réseaux routiers véritables et les réseaux routiers extraits.

### **4.1. Réseaux routiers extraits et limites de vitesse**

Les différents réseaux routiers extraits à partir du modèle de segmentation CRESIv2 sont représentés avec l'image satellite qui a servi d'intrant au modèle (figures 15 à 18). Au total, le nombre de segments extraits par zone d'étude est de 2100 à Montréal, 1270 à Sherbrooke, 2500 à Akron et 1329 à Keasbey. Les vitesses prédites en mph suivent la classification utilisée lors du *SpaceNet 5 Challenge*, soit de 17,5 mph à 65 mph. Dans la légende de chacune des figures, le nombre d'entités par classe de vitesse y est inscrit. On observe que la majeure partie des routes extraites pour chaque site d'étude se trouvent dans la classe de vitesse 17,5 mph, et au contraire, une très faible proportion dans la classe 65 mph (tableau 12).





**Figure 15. Réseau routier extrait et limites de vitesse classifiées à Montréal**



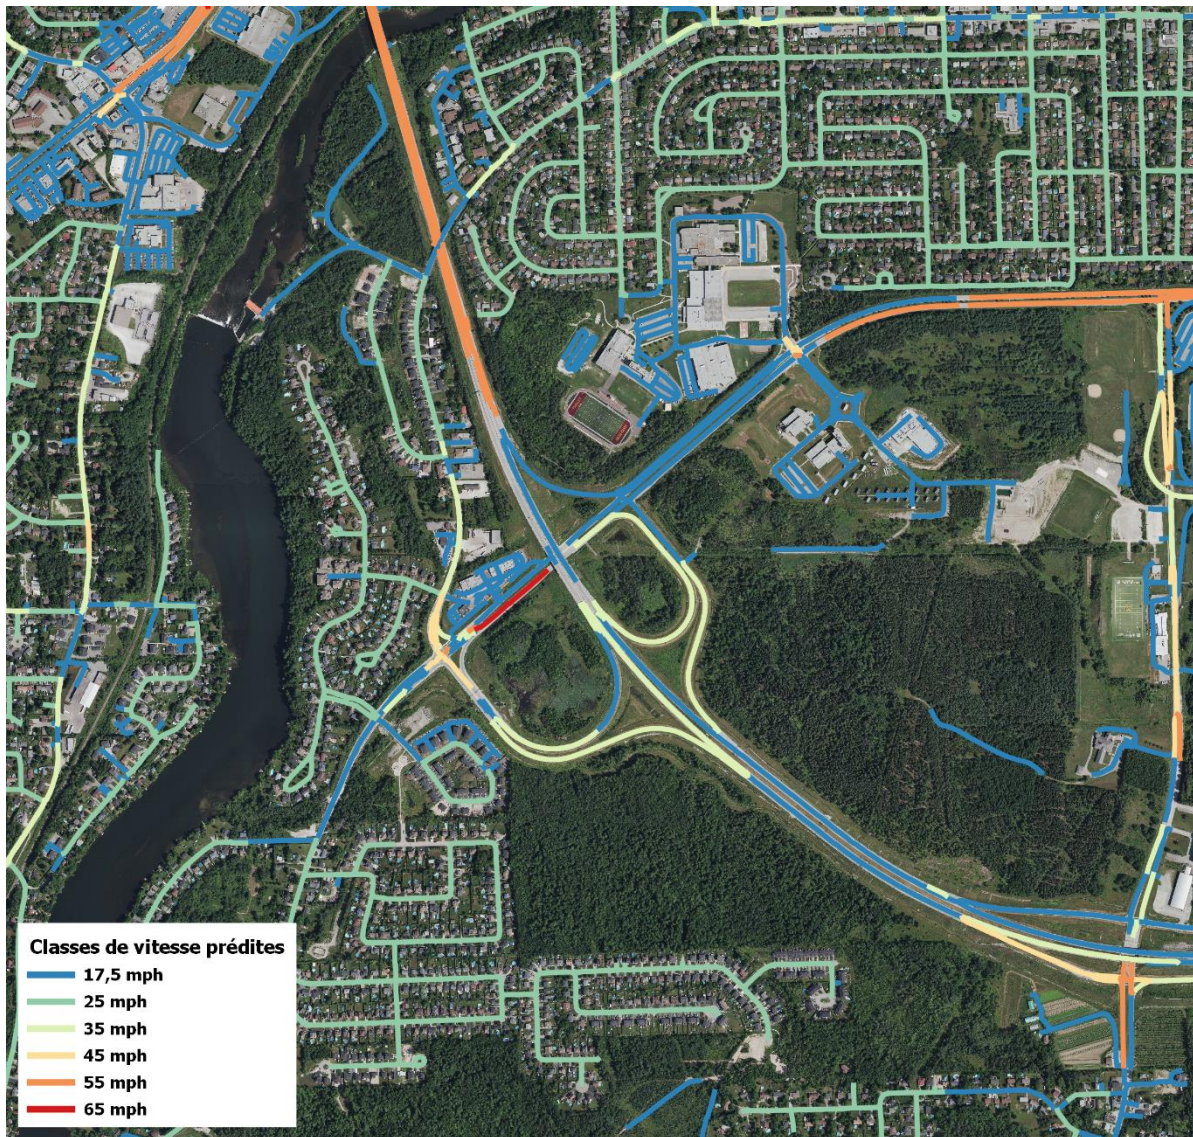


Figure 16. Réseau routier extrait et limites de vitesse classifiées à Sherbrooke






Figure 17. Réseau routier extrait et limites de vitesse classifiées à Akron





Figure 18. Réseau routier extrait et limites de vitesse classifiées à Kearsbey

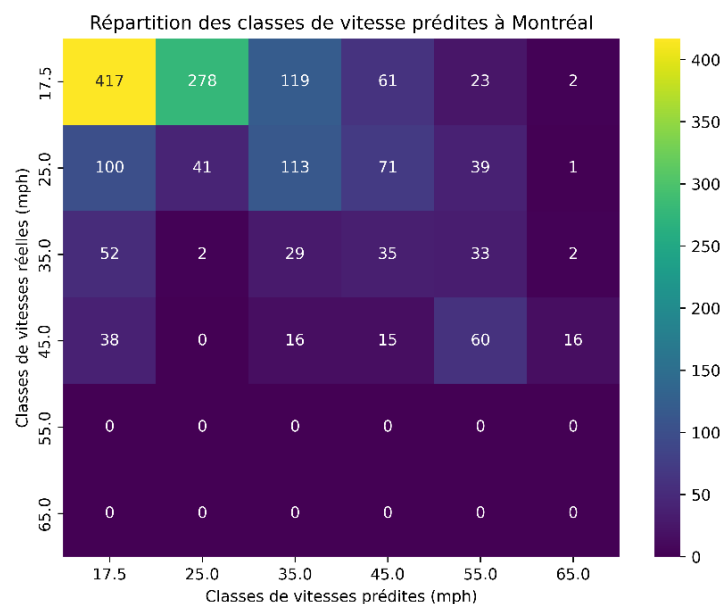
Tableau 12. Répartition des routes prédites par classe de vitesse pour chaque site d'étude

Classe de vitesse (mph)	17,5	25	35	45	55	65	Total
<b>Ville</b>							
Montréal (CA)	1150	340	266	173	151	20	<b>2100</b>
Sherbrooke (CA)	710	378	86	37	57	2	<b>1270</b>
Akron (É-U)	1512	326	338	171	131	22	<b>2500</b>
Kearsbey (É-U)	622	234	211	68	143	51	<b>1329</b>

## 4.2. Évaluation des estimations de limites de vitesse

L'évaluation des estimations de limites de vitesse est effectuée à partir des réseaux routiers prédits par le modèle auxquels les réseaux routiers véritables sont joints par la proximité des segments. Il est important de rappeler que les segments non joints, ainsi que les segments ayant plusieurs correspondances sont filtrés manuellement afin de conserver ce qui peut être comparé ce qui explique une différence dans le nombre total de routes. Pour chaque site d'étude, une matrice de confusion est calculée afin de mettre en évidence les classes de vitesse correctement prédites en fonction des classes de vitesse réelles. De plus, un tableau présente le pourcentage de bonnes prédictions par type de route. Il s'en suit des calculs des métriques MAE et RMSE qui permettent d'obtenir une évaluation générale de la qualité des prédictions.

Dans le premier site d'étude, à Montréal, 502 routes (32 %) ont été bien classifiées sur un total de 1563 (figure 19). Le modèle a particulièrement bien performé pour la classe de vitesse 17,5 mph. En effet, sur les 900 segments de route de cette classe, 417 ont été correctement prédits d'autant plus que 278 segments se trouvent dans la classe voisine de 25 mph. Ces valeurs bien prédites proviennent en grande partie de la classe de route résidentielle avec ces 397 routes correctement inférées ce qui représente 79 % des bonnes prédictions du réseau routier (tableau 13). En ce qui concerne les autres classes de vitesse, le modèle a connu des difficultés puisqu'il a surestimé les vitesses alors qu'il n'y avait aucune vitesse réelle de la classe 55 mph et la classe 65 mph.




**Figure 19. Répartition des prédictions de classe de vitesse en fonction des classes de vitesses réelles à Montréal**



**Tableau 13. Répartition des prédictions de classes de vitesse en fonction du type de route à Montréal.**

Type de route	Prédictions incorrectes	Prédictions correctes	Total	% correctes
Autoroute	46	10	56	18
Lien autoroutier	83	5	88	6
Primaire	56	1	57	2
Résidentielle	454	397	851	47
Secondaire	325	47	372	13
Lien secondaire	6	4	10	40
Voie de service	3	5	8	63
Tertiaire	52	12	64	19
Nationale	1	0	1	0
Lien national	10	0	10	0
Non classifiée	25	21	46	46

Dans le cas de la ville de Sherbrooke, seulement 77 routes sur 770 ont reçu la bonne classe de vitesse, soit 10 % du réseau routier (figure 20). De plus, 70 des 77 routes bien prédites se trouvent dans une seule classe, soit 35 mph. Dans ce cas-ci, le modèle a eu tendance à sous-évaluer la vitesse, notamment pour la classe de vitesse réelle 45 mph et 65 mph où le modèle a prédit des vitesses de 17,5 mph. La répartition des prédictions en fonction des types de routes montre que c'est la classe locale qui a le plus faible pourcentage de valeurs correctement prédites avec 3 % d'autant plus que cette classe contient plus de la moitié des routes (53 %) (tableau 14). La classe où le modèle a le mieux performé est la classe collectrice avec 32 % de valeurs correctes, soit 4 % du total des routes.

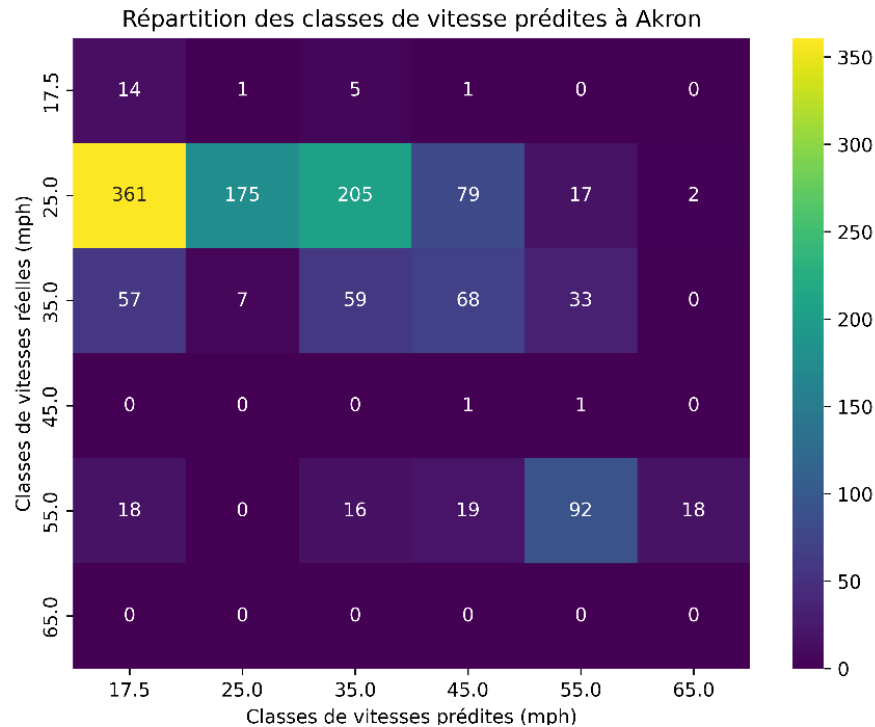


**Figure 20. Répartition des prédictions de classe de vitesse en fonction des classes de vitesses réelles à Sherbrooke**

**Tableau 14. Répartition des prédictions de classes de vitesse en fonction du type de route à Sherbrooke**

Type de route	Prédictions incorrectes	Prédictions correctes	Total	% correctes
Artère	159	26	185	14
Autoroute	60	7	67	11
Chemin privé	12	1	13	8
Collectrice	66	31	97	32
Locale	396	12	408	3

Pour la première ville aux États-Unis, à Akron, 27 % des routes ont été correctement prédites (figure 21). Pour cette ville, la majorité des bonnes prédictions sont attribuées à la classe 25 mph avec 175 bonnes prédictions. De plus, la classe de vitesse réelle 55 mph est bien prédite à 56 % avec 92 bonnes prédictions sur 163. La majorité des erreurs de prédictions sont attribuées à la classe réelle de 25 mph, ce qui représente 53 % des routes de ce réseau routier. Pour les types de routes, les autoroutes sont bien prédites à 66 % et les routes résidentielles à 42 % (tableau 15). Quant aux routes primaires, elles obtiennent 8 % ce qui a un fort impact puisque cela représente 20 % des routes au total.



**Figure 21. Répartition des prédictions de classe de vitesse en fonction des classes de vitesses réelles à Akron**

**Tableau 15. Répartition des prédictions de classes de vitesse en fonction du type de route à Akron**

Type de route	Prédictions incorrectes	Prédictions correctes	Total	% correctes
Autoroute	38	74	112	66
Lien autoroutier	58	24	82	29
Primaire	254	22	276	8
Lien primaire	2	0	2	0
Résidentielle	173	123	296	42
Secondaire	191	44	235	19
Tertiaire	149	42	191	22
Lien tertiaire	5	0	5	0
Non classifiée	38	12	50	24

Pour la deuxième ville aux États-Unis, à Keasbey, très peu de bonnes prédictions sont générées. En effet, seulement 107 (17 %) de bonnes classes de vitesse sont prédites sur un total de 643 (figure 22). La majorité des bonnes classes de vitesse se trouvent dans la classe 25 mph (53 routes) et 55 mph (37 routes) ce qui donne 14 % du total des routes. Cela est observable avec les types de routes puisque les routes résidentielles sont à 42 % et les autoroutes à 34 % de bonnes prédictions. On retrouve donc des valeurs très basses pour les autres types de routes (tableau 16).



**Figure 22. Répartition des prédictions de classe de vitesse en fonction des classes de vitesses réelles à Keasbey**

**Tableau 16. Répartition des prédictions de classes de vitesse en fonction du type de route à Keasbey**

Type de route	Prédictions incorrectes	Prédictions correctes	Total	% correctes
Autoroute	69	35	104	34
Lien autoroutier	69	8	77	10
Primaire	6	0	6	0
Résidentielle	61	45	106	42
Secondaire	83	9	92	10
Lien secondaire	38	1	39	3
Voie de service	15	0	15	0
Tertiaire	190	8	198	4
Lien tertiaire	5	1	6	17

Pour évaluer globalement les résultats obtenus, l'erreur absolue moyenne (MAE) et l'erreur quadratique moyenne (RMSE) sont calculées pour chaque zone d'étude (équations 1 et 2) (tableau 17). Il en ressort que les sites avec un réseau routier plus dense, soit à Akron et à Montréal, obtiennent les meilleurs résultats avec une MAE de 8,67 mph et de 9,88 mph. Pour Keasbey et Sherbrooke, la MAE est plus élevée de quelques mph, soit 11,31 et 13,01 mph. Globalement, le modèle a prédit à environ 10,72 mph d'erreur selon le résultat moyen du MAE. En ce qui concerne les valeurs de RMSE, elles sont plus élevées ce qui montre l'importance des plus grands écarts entre les prédictions et les valeurs réelles. C'est particulièrement le cas pour Montréal où le RMSE est à 13,73, soit 3,85 mph de plus que la MAE. Pour les autres sites d'études, on perçoit une augmentation moyenne de 2,66 mph. Quant à la valeur moyenne de RMSE, elle se situe à 13,68 mph.

$$(1) \text{ MAE} = \frac{\sum_{i=1}^n |y_i - x_i|}{n}$$

$$(2) \text{ RMSE} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y})^2}{n}}$$

**Tableau 17. Résultats des métriques d'évaluation MAE et RMSE pour les différents sites d'études**

Ville	Montréal	Sherbrooke	Akron	Keasbey	Moyenne
<b>MAE (mph)</b>	9,88	13,01	8,67	11,31	10,72
<b>RMSE (mph)</b>	13,73	15,44	11,56	13,96	13,68

## 5. Interprétation et discussion des résultats

Ce chapitre traite d'abord de l'évaluation des objectifs de l'essai. Par la suite, les limites de la méthode sont exposées tout en fournissant des pistes d'amélioration du projet.

### 5.1. Évaluation de l'atteinte des objectifs de l'essai

L'objectif principal de ce projet visait à établir une méthodologie permettant d'estimer automatiquement les limites de vitesse des routes à partir d'images satellites. Pour atteindre cet objectif, plusieurs étapes secondaires ont été réalisées.

Tout d'abord, il a fallu sélectionner une méthodologie appropriée, facile à reproduire. À cette fin, la méthode développée lors du *SpaceNet 5 Challenge* a été retenue. Cette méthode avait pour avantage d'extraire le réseau routier à l'aide d'un modèle de segmentation sémantique en plus de prédire les limites de vitesse de chacun des segments. De plus, le modèle CRESI final utilisé lors de la compétition était accessible en plus des programmes Python, nécessaire lors des étapes techniques. Ces éléments ont permis de reproduire la méthode efficacement et de vérifier son bon fonctionnement.

Ensuite, quatre sites d'étude en Amérique du Nord ont été déterminés, soit Montréal, Sherbrooke, Akron et Keasbey. Ces sites ont été sélectionnés en raison de caractéristiques communes en lien avec leur réseau routier. En effet, on y retrouve des ouvrages spécifiques, tels que des ponts, des viaducs, des échangeurs et des autoroutes, ce qui les rend plus facilement comparables entre eux. Par ailleurs, les villes d'Akron et de Keasbey ont été choisies spécifiquement, car les données de l'entreprise E-SMART pour ces sites présentaient plusieurs limites de vitesse manquantes.

Une fois la méthodologie appliquée à chacun des sites, 4 réseaux routiers ont été extraits comprenant des classes de limite de vitesse spécifique, soit 17,5 mph, 25 mph, 35 mph, 45 mph, 55 mph et 65 mph. L'évaluation des prédictions de limite de vitesse s'est effectuée en comparant les réseaux extraits aux réseaux routiers réels provenant d'OpenStreetMap, de la ville de Sherbrooke et de l'entreprise E-SMART. Cela a été possible grâce à l'utilisation de l'outil de jointure par plus proches voisins de QGIS. Ainsi, une nouvelle couche de données a été créée pour chaque réseau routier extrait, permettant de retrouver les valeurs de limite de vitesse et de classe de route du réseau routier réel correspondant spatialement. De plus, il a été nécessaire de transformer les valeurs de limite de vitesse des réseaux réels afin de correspondre aux 6 classes de

vitesse des réseaux extraits. Cela a permis de ressortir les statistiques d'évaluation des prédictions des limites de vitesse.

## 5.2. Limites et recommandations

Plusieurs facteurs ont influencé les résultats obtenus autant pour la segmentation des routes que pour l'estimation des classes de limites de vitesse. Ces facteurs concernent les données d'entraînement du modèle, l'architecture du modèle d'apprentissage profond ainsi que la méthode employée pour comparer les réseaux routiers aux réseaux routiers véritables.

Tout d'abord, le modèle conçu par l'équipe du *SpaceNet 5 Challenge* avait pour objectif d'être opérationnel à l'échelle mondiale. C'est pourquoi quatre sites à travers le monde avaient été sélectionnés pour l'entraînement du modèle CRESI. Bien que cela ait permis de créer un ensemble d'images satellites hétérogènes comportant différents contextes routiers, aucun des quatre sites ne se situait en Amérique du Nord. De plus, les images d'entraînement possédaient des angles au nadir différents, variant de 8 à 22 degrés, comparativement aux images utilisées dans l'essai, qui sont strictement au nadir. Il est donc possible que le modèle n'ait pas eu suffisamment d'exemples similaires pour extraire les routes de manière optimale dans les différents sites d'études de cet essai. Cela est observable en majeure partie lorsqu'il s'agit d'architectures plus complexes telles que des ponts et des échangeurs d'autoroutes. Il serait donc intéressant pour l'entreprise E-SMART de tester l'entraînement d'un modèle comprenant des zones uniquement au Canada et aux États-Unis ou même au sein d'une seule province ou État afin d'en évaluer les résultats. Ensuite, le contexte du *SpaceNet Challenge* implique que les données vectorielles utilisées pour l'entraînement du modèle aient été étiquetées manuellement par l'équipe à l'interne. Cela implique la possibilité que des erreurs aient été introduites dans les réseaux routiers d'entraînements. D'une part, les limites de vitesse assignées proviennent d'une matrice d'attributs qualitatifs comme la classe de route, le nombre de voies, le type de chaussée, etc. D'autre part, ces limites de vitesse ne tiennent pas compte du cadre législatif propre à chaque emplacement, ce qui tend vers une généralisation des classes de vitesses.

L'architecture utilisée dans le modèle CRESIv2 date de 2019. Avec l'apparition de nouveaux modèles et de techniques plus avancées en apprentissage profond, il serait pertinent de reproduire cette méthodologie en utilisant une architecture plus récente. Un tel modèle pourrait être entraîné

à partir d'images au nadir d'Amérique du Nord et de réseaux routiers dont les limites de vitesse proviennent de sources officielles.

Un aspect supplémentaire à considérer dans l'évaluation des résultats est la méthode utilisée pour comparer les limites de vitesse prédites aux valeurs réelles. En effet, comme le réseau routier produit n'est pas superposable spatialement avec le réseau routier réel, une recherche par proximité a été effectuée afin de joindre les attributs des routes à moins de 5 m de distance. Cela implique que certaines routes n'ont pas été jointes avec la bonne correspondance. Ce problème survient notamment lorsqu'il y a des structures telles que des ponts, viaducs ou échangeurs et en présence d'intersections. Dans le cas où la mauvaise route jointe n'a pas la même limite de vitesse que la route qui aurait dû être jointe, cela fausse le résultat et a pour impact de diminuer le pourcentage de routes correctement prédites ainsi que d'augmenter les valeurs des métriques d'erreur MAE et RMSE. Il serait donc nécessaire d'élaborer une méthode afin de déterminer si la route extraite est comparée à la bonne route du réseau de vérité terrain.

## 6. Conclusion

Cet essai réalisé avec la collaboration de l'entreprise E-SMART avait pour but la mise en œuvre d'une méthodologie d'estimation de limites de vitesse d'un réseau routier à partir d'imagerie satellite. Plus spécifiquement, la méthode employée, soit celle du *SpaceNet 5 Challenge* extrait le réseau routier des images satellites en plus de déterminer une classe de vitesse potentielle grâce à un modèle de segmentation sémantique préentraîné. À partir de quatre sites d'études urbains en Amérique du Nord, soit Montréal, Sherbrooke, Akron et Keasbey, il a été possible d'y prédire la classe de vitesse des segments de route. Les classes de vitesse des réseaux routiers extraits ont été comparées aux vitesses de jeux de données de réseau routier réel correspondant. Les résultats montrent qu'en moyenne, 22 % des vitesses prédites correspondent aux vitesses réelles. C'est à Montréal et à Akron que les meilleurs résultats ont été obtenus avec 32 et 27 % de vitesses bien prédites. Pour Keasbey et Sherbrooke, on retrouve plutôt 17 et 10 % de vitesses bien prédites. Tout de même, les métriques MAE et RMSE démontrent des résultats plus encourageants. En effet, en moyenne la MAE se trouve à 10,72 mph et la moyenne de RMSE se trouve à 13,68 mph. Ainsi, la vitesse prédite se trouve bien souvent à une classe de vitesse près de la bonne valeur.

Le principal facteur limitant de ce projet réside dans l'utilisation d'un modèle préentraîné sur des régions du monde autres que l'Amérique du Nord. L'entraînement d'un nouveau modèle basé uniquement sur des lieux situés en Amérique du Nord faciliterait considérablement l'estimation des limites de vitesse, notamment s'il était conçu spécifiquement pour un pays ou bien à l'échelle d'une province ou État. De plus, la méthode de comparaison des routes extraites à celles qui font office de vérités terrain pourrait être améliorée de sorte à réduire les erreurs venant de la jointure par proximité.

Une autre approche intéressante pour estimer les limites de vitesse sur un réseau routier consisterait à utiliser un modèle basé sur les graphes. Cette technique innovante permettrait d'entraîner un modèle capable d'analyser les attributs des routes afin de prédire la limite de vitesse. De plus, le contexte de voisinage pourrait être exploité pour déterminer une valeur en fonction de l'environnement local d'une route.

Pour conclure, l'estimation de limites de vitesse précises à partir d'imagerie satellitaire est une tâche plutôt ardue. C'est en quelque sorte ce qui explique la rareté de ce genre de projet dans la littérature actuelle. Tout de même, ce projet présente une méthode reproductible ayant un fort potentiel d'amélioration.



## Bibliographie

Badue, C., Guidolini, R., Carneiro, R. V., Azevedo, P., Cardoso, V. B., Forechi, A., Jesus, L., Berriel, R., Paixão, T. M., Mutz, F., de Paula Veronese, L., Oliveira-Santos, T. et De Souza, A. F. (2021) Self-driving cars: A survey. *Expert Systems with Applications*. vol. 165, p. 113816.

Bahl, G. (2022) Deep learning architectures for onboard satellite image analysis. Thèse de doctorat, Université Côte d’Azur. p. 131.

Bai, Y. (2022) Relu-function and derived function review. In: *SHS Web of Conferences*. vol. 144, p. 02006. EDP Sciences

Beere, P. (2016) Creating a Road Network Analysis Layer with Travel Time Estimates using Open-source Data. *GeoHealth Laboratory*, New Zealand. p. 18.

Bonhomme, A., Mathieu P., et Picault, S. (2016) Simuler le trafic routier à partir de données réelles. *Revue des Sciences et Technologies de l’Information - Série RIA : Revue d’Intelligence Artificielle*, pp.329-352.

Commission des normes, de l’équité, de la santé et de la sécurité du travail (CNESST) (2022) Statistiques annuelles, Gouvernement du Québec. [En ligne]. [https://www.cnesst.gouv.qc.ca/sites/default/files/documents/statistiques-annuelles\\_0.pdf](https://www.cnesst.gouv.qc.ca/sites/default/files/documents/statistiques-annuelles_0.pdf) (page consultée le 5 juin 2024)

Etten, A. V. (2020) City-Scale Road Extraction from Satellite Imagery v2: Road Speeds and Travel Times. *2020 IEEE Winter Conference on Applications of Computer Vision (WACV)*, p. 1775-1784.

Goodfellow, I., Bengio, Y., et Courville, A. (2016). *Deep Learning*. Cambridge, Massachusetts: MIT Press. p. 781.

Google (2024) Web Services – Roads API. [En ligne]. <https://developers.google.com/maps/documentation/roads?hl=fr> (page consultée le 5 juin 2024)

Hadi, N., Lei, X., Atefeh, D. et Payam, A. (2023). A development in the approach of assessing the sensitivity of road networks to environmental hazards using functional machine learning algorithm and fractal methods. *Environment, Development and Sustainability*. 1-29.

Insurance Institute for Highway Safety (IIHS) (2022) Yearly snapshot: Fatality statistics. [En ligne] <https://iihs.org/topics/fatality-statistics/detail/yearly-snapshot> (page consultée le 5 juin 2024)

Larousse (2024) Intelligence artificielle. *Larousse encyclopédie*, [En ligne]. [https://www.larousse.fr/encyclopedia/divers/intelligence\\_artificielle/187257](https://www.larousse.fr/encyclopedia/divers/intelligence_artificielle/187257) (page consultée le 5 juin 2024)

Microsoft (2019) Understanding Scale and Resolution. [En ligne]. <https://learn.microsoft.com/en-us/bingmaps/articles/understanding-scale-and-resolution> (page consultée le 5 juin 2024)

Ministère des Transports du Québec (2015) Gestion de la vitesse sur le réseau routier municipal en milieu urbain. Gouvernement du Québec. [En ligne]. <https://www.transports.gouv.qc.ca/fr/entreprises-partenaires/municipalites/securite->

routiere/modification-limite-vitesse/Documents/A6898\_guide\_vitesse\_EPAC\_web.pdf (page consultée le 5 juin 2024)

Ministère des Transports du Québec (2021) Guide de détermination des limites de vitesse dans les zones de travaux routiers, Gouvernement du Québec. [En ligne]. <https://cdn-contenu.quebec.ca/cdn-contenu/adm/min/transports/transports/Signalisation/zone-travaux/guide-determination-limites-vitesse-zones-travaux.pdf> (page consultée le 5 juin 2024)

Ministère des Transports et de la Mobilité durable (MTMDET) (2024) Signalisation dans une zone scolaire, Gouvernement du Québec. [En ligne]. <https://www.quebec.ca/transports/circulation-securite-routiere/signalisation-routiere/panneaux/signalisation-zone-scolaire> (page consultée le 5 juin 2024)

Ministère des Transports et de la Mobilité durable (MTMDET) (2025 -a) Classification fonctionnelle du réseau routier, Gouvernement du Québec. [En ligne]. <https://www.transports.gouv.qc.ca/fr/entreprises-partenaires/municipalites/infrastructures-routieres/Pages/classification-fonctionnelle-reseau-routier.aspx> (page consultée le 5 juin 2024)

Ministère des Transports et de la Mobilité durable (MTMDET) (2025 -b) Sécurité routière dans les municipalités, Gouvernement du Québec. [En ligne]. <https://www.transports.gouv.qc.ca/fr/entreprises-partenaires/municipalites/securite-routiere/pages/securite-routiere.aspx> (page consultée le 5 juin 2024)

Ministère des Transports et de la Mobilité durable (MTMDET) (2025 -c) Limiteurs de vitesse, Gouvernement du Québec. [En ligne]. <https://www.transports.gouv.qc.ca/fr/entreprises-partenaires/ent-camionnage/Pages/Limiteur-de-vitesse.aspx> (page consultée le 5 juin 2024)

National Motorists Association (2024) State speed limit chart. [En ligne]. <https://ww2.motorists.org/issues/speed-limits/state-chart/> (page consultée le 5 juin 2024)

OpenSteetMap (OSM) (2024) OpenStreetMap. [En ligne]. <https://www.openstreetmap.org/about> (page consultée le 5 juin 2024)

Organisation mondiale de la santé (2004) << Facteurs de risque >>. Dans Rapport mondial sur la prévention des traumatismes dus aux accidents de la circulation (Chapitre 3, pp. 75–112). [En ligne]. <https://voute.bape.gouv.qc.ca/dl/?id=00000374315>.

Othman, B. (2021) Variable speed limits and signalized access control in an urban road network for improved environmental sustainability. Thèse de doctorat, Université Grenoble Alpes, 153 p.

SAE International (2021) SAE Levels of Driving Automation™ Refined for Clarity and International Audience. [En ligne]. <https://www.sae.org/blog/sae-j3016-update> (page consultée le 5 juin 2024)

Sarker, I. H. (2021) Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions. SN Computer Science, vol. 2, n°6, p. 420.

Transport Canada (2024) Statistiques de collisions sur la route au Canada, 2022. Gouvernement du Canada. [En ligne] <https://tc.canada.ca/fr/transport-routier/statistiques-donnees/statistiques-collisions-route-canada-2022> (page consultée le 5 juin 2024)

Ville de Sherbrooke (2024) Portail de données cartographiques. [En ligne]. <https://donneesouvertes-sherbrooke.opendata.arcgis.com/> (page consultée le 5 juin 2024)

Wiki OpenStreetMap (OSM) (2024) Databases and data access APIs. [En ligne]. [https://wiki.openstreetmap.org/wiki/Databases\\_and\\_data\\_access\\_APIs](https://wiki.openstreetmap.org/wiki/Databases_and_data_access_APIs) (page consultée le 5 juin 2024)