

Analyse de données spatio-temporelles pour la construction automatique de cartes de randonnée

THÈSE

pour obtenir le grade de

Doctorat de l'Université de Strasbourg

mention Informatique

Soutenue le 6 juin 2024

présentée par

Olivier Schirm

Composition du jury

<i>Directeur de thèse :</i>	Cédric Wemmert, Professeur, Université de Strasbourg
<i>Co-directeur de thèse :</i>	Germain Forestier, Professeur, Université de Haute-Alsace
<i>Co-encadrants :</i>	Maxime Devanne, Maître de Conférences, Université de Haute-Alsace Jonathan Weber, Professeur, Université de Haute-Alsace
<i>Rapporteurs :</i>	Latifa Oukhellou, Directrice de recherche, Université Gustave Eiffel Paule-Annick Davoine, Professeure, Université de Grenoble-Alpes
<i>Examineurs :</i>	Karine Bennis Zeitouni, Professeure, Université de Paris Saclay Bertrand Kerautret, Professeur, Université Lumière Lyon 2

Table des matières

Liste des tableaux	5
1 Contexte	9
1.1 Visorando	9
1.1.1 Objectifs de Visorando pour le projet de thèse	9
1.1.2 Finalités du projet de thèse et contributions pour Visorando .	10
1.2 Fusion de traces GPS : concepts et défis	10
1.2.1 Qu'est-ce qu'une trace GPS utilisateur?	10
1.2.2 La carte résultante et ses caractéristiques	11
1.2.3 Système de projection et son importance	12
1.2.4 Difficultés potentielles de l'analyse de traces GPS	12
1.3 État de l'art	14
1.3.1 Comparaison et analyse critique des méthodes existantes . . .	17
1.4 Enjeux, défis et contributions de la recherche	18
1.4.1 Défis non résolus dans la fusion de traces GPS	18
1.4.2 Contributions uniques de cette recherche	18
1.4.3 Implications pour l'industrie et Visorando	19
1.5 Reproductibilité des travaux	20
2 Évaluation de cartes créées par fusion de traces GPS	21
2.1 Analyse des données de graphe	22
2.1.1 Indicateurs de qualité	22
2.1.1.1 Qualité des segments générés	22
2.1.1.2 Précision des intersections	23
2.1.1.3 Connectivité de la carte	23
2.1.2 Sources de référence	23

2.1.2.1	Base de données OpenStreetMap (OSM)	24
2.1.2.2	Extraction OSM partielle	25
2.1.2.3	Création manuelle de cartes	26
2.1.2.4	Analyse critique des méthodes de génération de cartes de référence	27
2.2	Métriques d'évaluation d'une carte	27
2.2.1	Évaluation des segments	28
2.2.1.1	Appariement des segment	28
2.2.1.2	Évaluation de la différence entre segments	30
2.2.2	Évaluation des intersections	31
2.2.3	Autres aspects évaluables	32
2.2.4	Limites des métriques actuelles	33
2.2.5	La visualisation au secours de l'évaluation quantitative	35
2.3	Les jeux de données de l'état de l'art	36
2.3.1	Récapitulatif de la donnée existante	36
2.3.2	Exemples d'articles ayant un jeu de données propre à leurs besoins	39
2.3.3	Les données pédestres en zones naturelles	41
2.4	Structure de notre protocole d'évaluation	42
2.4.1	Les métriques	42
2.4.1.1	Évaluation des segments (FTOP)	42
2.4.1.2	Évaluation des intersections (FINT)	45
2.4.1.3	Évaluation de la connectivité (FITO)	45
2.4.1.4	La place de l'interprétation visuelle dans notre pro- tocole d'évaluation	47
2.4.2	Les jeux de données	47
2.4.2.1	Données pour l'évaluation de la fusion par applica- tion multiple de grilles	47
2.4.2.2	Données pour l'évaluation des approches par appren- tissage profond	48
2.4.3	Construction des carte de référence	49
3	Fusion de traces GPS par application multiple de grilles	53
3.1	Contexte	53
3.1.1	L'utilisation de grilles avec les données GPS	54
3.1.2	Travail préliminaire	55
3.2	Méthodes	56

3.2.1	Pré-traitement	57
3.2.1.1	Suppression des doublons consécutifs	58
3.2.1.2	Découpage de traces	58
3.2.1.3	Homogénéisation de la fréquence d'acquisition	59
3.2.1.4	Amélioration de la précision des virages	60
3.2.2	Multiple application de grilles	63
3.2.3	Segmentation	65
3.3	Résultats	67
3.3.1	Rappel des méthodes d'évaluation	67
3.3.1.1	Les métriques	67
3.3.1.2	Les jeux de données et de référence	68
3.3.1.3	Références de notre analyse comparative	68
3.3.2	Évaluation sur le jeu de données de Chicago	69
3.3.3	Inclusion de diversité avec l'évaluation sur les jeux de données de Mahdi Hashemi	70
3.3.4	Évaluation sur un jeu de données plus proche de la réalité : Blaesheim	71
3.3.5	Résumé des résultats	73
3.3.6	Visorando	74
3.3.7	Temps de calcul	74
3.4	Discussion	75
4	Approche par extraction de ligne centrale	81
4.1	Contexte	82
4.1.1	Émergence des techniques d'apprentissage profond pour la fu- sion de trace GPS	82
4.1.2	Focus sur la donnée GPS	83
4.1.3	Analyse critique des méthodologies existantes	83
4.1.3.1	Données d'entrée	83
4.1.3.2	Architecture du réseau de neurones	84
4.1.3.3	Évaluation des méthodes	85
4.1.4	Contributions scientifiques	86
4.2	Méthode	87
4.2.1	Préparation des données	88
4.2.1.1	Traces et caractéristiques	88
4.2.1.2	Prétraitement	89
4.2.1.3	Canaux raster	89

4.2.2	Entraînement et prédictions d'un réseau de neurones	90
4.2.2.1	Préparation des données d'entrée : découpage, normalisation et augmentation	91
4.2.2.2	La donnée de référence ou vérité terrain.	93
4.2.2.3	La fonction de coût ou de perte	93
4.2.3	Conversion d'une image raster résultat en graphe	94
4.3	Résultats, analyse et perspectives	94
4.3.1	Cadre et configuration des expériences	94
4.3.1.1	Plan d'expérimentation : une stratégie d'exploration progressive	94
4.3.1.2	Constitution du jeu de donnée	95
4.3.1.3	Configuration et environnement d'entraînement	97
4.3.1.4	Rappel de la stratégie d'évaluation	97
4.3.2	Apport des données d'entrée	98
4.3.2.1	Évaluation des 17 canaux	98
4.3.2.2	Optimisation de la combinaison de canaux avec UNet	100
4.3.2.3	Positionnement par rapport à l'état de l'art	101
4.3.3	Analyse comparative des architectures de réseaux neuronaux	102
4.3.3.1	Cartographies des performances sur différentes tailles de patch	102
4.3.3.2	Évaluation sur 17 canaux	104
4.3.3.3	Comparatif global des performances	106
4.4	Conclusion	108
	Bibliographie	119

Table des figures

1	Légende des éléments graphiques utilisés dans les cartes du manuscrit.	7
1.1	Exemples de traces GPS enregistrées par des utilisateurs Visorando.	11
1.2	Exemple de génération de carte suite à la fusion de traces. La carte se compose de 9 segments et de 4 intersections.	12
2.1	Exemple d'une situation dangereuse où les traces GPS utilisateurs tendent à connecter 2 segments séparés par une falaise. © OpenStreetMap contributors [58], GoogleLandsat / CopernicusData SIO, NOAA, U.S. Navy, NGA, GEBCOGeoBasis-DE/BKG (©2009)IBCAO	22
2.2	Création d'une carte de référence par extraction OSM. © OpenStreetMap contributors [58]	24
2.3	Construction d'une carte OSM Partielle. © OpenStreetMap contributors [58]	25
2.4	Création d'une carte de référence par annotation manuelle. © OpenStreetMap contributors [58]	26
2.5	Illustration de problèmes liés à une extraction OSM	28
2.6	Les différents types d'erreurs artificiellement générées. Cette Figure provient de l'article [16].	33
2.7	Exemple de génération automatique d'un segment dangereux (en rouge). © OpenStreetMap contributors [58]	36
2.8	Chicago : 7 mois de traces brutes. Les données présentent à la fois une grande disparité et un fort bruit GPS. Le rectangle rouge indique la "zone de l'hôpital". La Figure provient de l'article [13]	37
2.9	Jeux de données Les plus populaires de la communauté scientifique .	40
2.10	Exemple d'extraction OSM mettant en avant les différences structurelles entre des données urbain et un jeu de données acquises en zone montagneuse. © OpenStreetMap contributors [58]	41
2.11	Exemple de calcul de similarité (en mètres) entre un segment généré et un segment issu de la vérité terrain. La similarité est de 8.5m en moyenne.	43
2.12	Comparaison des différentes implémentations possible de la métrique (TOPO ou FTOP) sur un exemple donné.	44

2.13	Exemple d'un appariement, 4 intersections seraient suffisamment proches mais seule la plus proche est sectionnée.	46
2.14	Exemple d'utilisation de la métrique FITO. Seuls les pixels contenus dans le cercle rouge seront considérés dans le calcul du FScore.	46
2.15	Présentation visuelle des jeux de données sélectionnés parmi le testbed de Mahdi Hashemi	48
2.16	Jeu de données <i>Blaesheim</i>	48
2.17	Jeux de données extraits de la base de données de Visorando utilisés pour l'évaluation des méthodes par apprentissage profond	51
3.1	Des traces au graphe. Une illustration tirée du rapport de stage de Ilias Rmouque et Jonathan Jadlo	56
3.2	Illustration des problèmes liés à une position stationnaire de l'utilisateur et de son smartphone pendant la collecte de données GPS. Le randonneur effectue une pause de plusieurs minutes en bord de lac, mais le GPS mesure des positions jusqu'à plusieurs dizaines de mètres autour de sa position réelle. Images ©2024 Google, Images ©2024 GeoContent.	57
3.3	Ajout d'un point de convergence pour mieux estimer un virage.	60
3.4	Ajout d'un point de convergence erroné à une trace t_1	61
3.5	Résultat du regroupement des traces avec et sans améliorations des virages.	61
3.6	Application itérative de l'algorithme de clustering avec des grilles multiples	63
3.7	Évolution du FScore en fonction du nombre d'itérations pour deux jeux de données	64
3.8	Extrait du jeu de données de Chicago pour comparer la meilleure valeur du paramètre <i>tailleCellule</i> à la largeur des traces sur une route	65
3.9	Algorithme de segmentation	66
3.10	Évaluation du FScore sur les intersections pour le jeu de données Chicago pour 5 valeurs du paramètre <i>s_paire</i> différentes.	69
3.11	Évaluation du FScore pour la détection des intersections sur GPS7.	71
3.12	Évaluation de la détection des intersections sur le jeu de données de Blaesheim selon différentes valeurs de <i>s_paire</i>	72
3.13	Vue globale des résultats sur l'ensemble des jeux de données	73
3.14	Résultats visuels sur un jeu de données extrait de Visorando	79
4.1	Vue d'ensemble de notre approche : (1) conversion des données GPS vectorielle en images raster, (2) entraînement du réseau neuronal, (3) prédiction à partir du modèle, (4) conversion de la sortie du réseau en image vectoriel et extraction des intersections. Le format vectoriel est en vert et le format raster est en noir.	87
4.2	Illustration des différents canaux d'entrée pour l'analyse des trajectoires GPS.	91
4.3	Illustration du processus de prédiction et de fusion d'images avec chevauchement des patches.	95

4.4	Moyenne des FScores pour les intersections (FINT), les segments (FTOP) et la connectivité par canal (FITO), <i>Base</i> étant la référence sans mélange de canal.	99
4.5	Résultats des modèles par taille de patche.	103
4.6	Résultats visuels des 3 premières des 10 itérations d'apprentissage par canal d'entrée utilisant l'architecture HRNet et une taille de patche de 320.	109

Liste des tableaux

1.1	Synthèse des méthodes récentes d'inférence de carte à partir de trajectoires GPS	17
2.1	Exemples de jeux de données les populaires	36
2.2	Les données GPS du testbed présenté par Hashemi et al. [33]	38
2.3	Description de tous les ensembles de données utilisés dans les expériences avec la densité de trace ajoutée	49
3.1	Évolution des résultats sur les ensembles de données Blaesheim et GPS7 avec différentes valeurs de $s_{convergence}$	62
3.2	Évaluation des segments sur le jeu de données Chicago. L'imprécision est exprimée en mètres.	70
3.3	Évaluation de la reconstruction des segments pour les jeux de données GPS7 à GPS12.	77
3.4	Évaluation de reconstruction de segments sur le jeu de données de Blaesheim.	78
3.5	Temps d'exécution de chaque méthode pour les différents jeux de données (durée en secondes). Les caractéristiques de chaque jeux de données sont également répertoriées à des fins de comparaison.	78
4.1	Description de tous les ensembles de données utilisés dans les expériences de ce chapitre	96
4.2	Moyenne des FScores pour les combinaisons d'informations préférées du réseau UNet	100
4.3	Comparaison des FScores obtenus par notre combinaisons de canaux avec celles utilisées par l'état de l'art	101
4.4	FScores harmoniques moyens pour différentes tailles de patch pour plusieurs architectures de réseaux. Les valeurs en gras indiquent le score le plus élevé obtenu pour chaque architecture à travers les différentes tailles de patche, tandis que la valeur soulignée représente le score le plus élevé parmi toutes les architectures et toutes les tailles de patch.	103
4.5	Comparaison des résultats en utilisant uniquement le carte de chaleur en entrée ou l'ensemble des 17 canaux pour différentes architectures	104

4.6	Moyenne harmonique pour les 17 canaux et pour chaque permutation. Plus le contraste de couleur est fort, plus la différence entre le score obtenu et la référence est élevée.	105
4.7	Moyenne harmonique des modèles basée sur des combinaisons. Pour chaque modèle, nous ajoutons progressivement de nouveaux canaux dans les combinaisons. V=Vitesse, B=Binaire, C=Carte de chaleur, DDIR= Diversité directionnelle, DDIF=Différence de Direction, D1=Direction1 et P=Pente	106
4.8	Comparatif des moyennes harmoniques de FINT, FTOP et FITO pour de toutes les combinaisons évaluées.	107

Préambule

Légende du manuscrit de thèse

Dans le cadre de ce manuscrit de thèse, plusieurs types de données cartographiques sont utilisés pour illustrer les analyses et les résultats obtenus. Afin de faciliter la compréhension des cartes présentées dans ce document, nous employons une légende standardisée décrivant chaque type de marqueur utilisé :

- **Traces GPS** : ce sont les données d'entrée des algorithmes présentés, elles seront représentées en **noir**, que ce soit sous une forme brute ou prétraitée.
- **Segments de référence** : ils représentent les segments de la vérité terrain, objectif à atteindre pour nos algorithmes de fusion de traces GPS. Ces objets seront illustrés en **vert**.
- **Segments générés** : ils représentent les segments en sortie des algorithmes et seront illustrés en **violet**.
- **Intersections de la carte de référence** : positions associées aux points de rencontre entre plusieurs segments de la vérité terrain, elles seront illustrées sous la forme de points **orange**.
- **Intersections de la carte générée** : elles représentent les points d'intersections inférés par les méthodes de fusion de traces GPS, elles seront illustrées par des points **bleus**.




FIGURE 1 – Légende des éléments graphiques utilisés dans les cartes du manuscrit.

Ces symboles, illustrés sur la figure 1 sont employés de manière cohérente dans toutes les illustrations cartographiques du document pour garantir une compréhension claire des informations présentées.

Données cartographiques OpenStreetMap

Les données cartographiques sont protégées par le droit d'auteur des contributeurs d'OpenStreetMap et sont disponibles sur <https://www.openstreetmap.org>

Chapitre 1

Contexte

1.1 Visorando

Les travaux présentés dans ce manuscrit ont été effectués dans le cadre d’une thèse CIFRE, réalisée au sein de l’entreprise Visorando en collaboration avec les laboratoires IRIMAS (Mulhouse), équipe Modélisation et Science des Données (MSD) spécialisée dans le traitement automatique de séries spatio-temporelles, et ICube (Strasbourg), équipe Sciences des Données et Connaissances (SDC), spécialisée dans l’apprentissage machine.

La SARL Visorando, dont le siège social se situe à Soultz-Haut-Rhin (Grand-Est), propose gratuitement plus de 27 000 suggestions de randonnées en France à travers leur site internet et leur application mobile. Visorando est le premier portail dédié à la randonnée en termes d’audience : 16 millions de visiteurs uniques en 2023 et 2,8 millions de téléchargements de l’application mobile. C’est surtout la plus grande communauté de randonneurs sur le web : plus de 2 millions d’inscrits rendent leurs idées de randonnée vivantes.

L’engagement de leurs visiteurs est important : un visiteur passe en moyenne 4 minutes sur le site. Ce sont ces mêmes utilisateurs qui confectionnent et publient les propositions de randonnées sous la surveillance accrue des modérateurs de l’entreprise. Tous les jours, des centaines de randonnées sont ainsi parcourues, commentées, puis mises à jour. En l’espace de 3 ans, durée de la thèse, Visorando a vu son effectif augmenter de 8 à 15 employés. L’entreprise s’est également ouverte au marché anglais et allemand.

1.1.1 Objectifs de Visorando pour le projet de thèse

Ce projet de thèse est perçu par l’entreprise comme une opportunité d’innover dans le domaine de la cartographie des sentiers de randonnée par l’intelligence artificielle. L’entreprise a plusieurs anticipations clés concernant ce travail de recherche.

Fusion de traces pour la création d’une carte : Le cœur du système de recommandation qui sera développé dans le cadre de cette thèse se base sur une carte (représentée sous forme d’un graphe de chemins) qui doit être mise à jour automatiquement à partir de l’ensemble des traces obtenues à partir des utilisateurs de l’application Visorando. Il existe plusieurs approches essayant de fusionner des

traces GPS pour en obtenir une seule. Cependant, aucune à l'heure actuelle n'est suffisamment robuste pour être utilisée de manière totalement automatique, sans intervention humaine préalable ou post-traitement. Ainsi, le travail principal de cette thèse sera de définir et mettre en œuvre une telle méthode, pouvant traiter un très grand volume de traces (plusieurs millions) de manière suffisamment rapide pour permettre de proposer une carte à jour à un rythme hebdomadaire. Plusieurs verrous seront à lever afin de proposer une approche robuste et efficace. Il faudra pouvoir produire une carte précise et fiable à partir d'un grand volume de traces GPS, mais aussi être capable de la mettre à jour en tenant compte de traces plus récentes.

Caractérisation automatique des sentiers : Un objectif secondaire de ce travail de thèse sera de caractériser automatiquement les sentiers en fonction de critères pouvant être utilisés par la suite pour exploiter la base de données générées. Il serait notamment intéressant de calculer la fréquentation des sentiers (outre l'intérêt pour l'utilisateur, cela permettrait le développement d'applications à destination des collectivités), d'estimer la largeur des sentiers, voire le type de terrain ou la difficulté technique en fonction des traces.

Algorithme de proposition automatique d'un itinéraire multi-critère : Finalement, le dernier sujet abordé durant cette thèse portera sur la définition d'un algorithme de construction automatique d'une proposition de randonnée à partir d'un ensemble de critères donnés par l'utilisateur. L'algorithme s'appuiera sur la carte construite automatiquement à partir des traces GPS et sur un algorithme d'apprentissage permettant de définir un profil type de l'utilisateur, permettant une recommandation au plus prêt de ses attentes et habitudes.

1.1.2 Finalités du projet de thèse et contributions pour Visorando


Ce paragraphe a pour but de comparer les attentes de l'entreprise énoncées dans le paragraphe précédent avec le travail qui a réellement été réalisé lors de la thèse. Parmi les 3 grandes étapes supposées de la thèse, il était logique de commencer par la **fusion de traces pour la création d'une carte**, puisque ce sont les segments de cette carte que nous allons chercher à caractériser pour les proposer à nos utilisateurs. Cependant, en nous plongeant dans l'état de l'art, nous nous sommes rendu compte que les résultats à ce jour de la communauté étaient loin d'être suffisants pour pouvoir prétendre passer à une phase de caractérisation. C'est pourquoi nous avons consacré l'intégralité de la thèse à essayer de créer une carte aussi propre que possible, laissant les 2 autres phases en perspective pour de futurs travaux. À l'issue de ce doctorat, nous sommes fiers d'avoir pu apporter à Visorando un algorithme capable, avec une précision correspondant à leurs attentes, de générer de nouvelles cartes de randonnée issues de leurs traces GPS.

1.2 Fusion de traces GPS : concepts et défis

1.2.1 Qu'est-ce qu'une trace GPS utilisateur ?

La donnée que nous avons exploitée tout au long de ces travaux se présente sous la forme d'un ensemble de traces GPS que nous nommerons T . Une trace $t_i \in T$

peut être considérée comme une suite de positions géographiques. Lorsque l'on parle d'une trace GPS enregistrée par un utilisateur de Visorando, nous ajoutons à ces emplacements une indication temporelle permettant alors de retracer le parcours de la personne dans le temps. La trace devient alors une série spatio-temporelle qui contient au minimum une latitude, une longitude et un repère temporel. Dans ce manuscrit, nous ferons référence à un point spécifique d'une trace avec la notation suivante : $p_{i,j} \in t_i \in T$, avec $p_{i,j} = (\text{latitude}_{i,j}, \text{longitude}_{i,j}, \text{temps}_{i,j})$. La Figure 1.1 donne un exemple visuel de 4 traces GPS associées au tableau qui donne les compositions de ces traces.



T	Symbole	$p_{i,j} \in t_i \in T$	Nombre de points
t_1	●	(48.11722, 7.28374, 02-04-2022 13 :01 :56), ..., (48.12292, 7.30630, 02-04-2022 13 :45 :42)	14
t_2	■	(48.11508, 7.29503, 12-05-2022 13 :32 :12), ..., (48.12784, 7.29841, 12-05-2022 14 :02 :33)	12
t_3	▲	(48.11519, 7.28402, 06-12-2022 08 :32 :23), ..., (48.12795, 7.29826, 06-12-2022 08 :59 :45)	12
t_4	◆	(48.11532, 7.28389, 23-03-2022 12 :27 :53), ..., (48.12100, 7.30641, 23-03-2022 12 :39 :28)	4


FIGURE 1.1 – Exemples de traces GPS enregistrées par des utilisateurs Visorando.

1.2.2 La carte résultante et ses caractéristiques

Dans ce manuscrit, nous utiliserons le mot **carte** pour faire référence au résultat de la fusion de traces GPS. La carte représente le résultat final obtenu par l'algorithme de fusion. Sa composition a été définie au début du projet par toutes les parties prenantes et pour les besoins applicatifs de l'entreprise. Lorsqu'on s'intéresse uniquement à la fusion de traces, la sortie attendue de notre méthode doit être composée de **segments** reliant des **intersections**.

La carte que nous créons se présente sous la forme d'un graphe composé de sommets et d'arêtes. Contrairement aux traces GPS initiales, cette carte ne contient aucune information temporelle. Elle se concentre uniquement sur la disposition spatiale des points. En ce qui concerne la densité des points sur la carte, il n'y a pas d'exigence spécifique quant au nombre de points par unité de surface. Toutefois, il est important que cette densité soit uniforme sur toute la carte, assurant ainsi une représentation cohérente et régulière de l'espace géographique.

La carte C est un ensemble de segments $S = \{s_1, s_2, \dots, s_n\}$ et d'intersections $I = \{i_1, i_2, \dots, i_m\}$ tels que $C = (S, I)$. Nous précisons que les points d'intersection $i_k \in I$ et les points constituant les segments $p_{i,j} \in s_i \in S$ sont simplement composés d'une latitude et d'une longitude. La Figure 1.2 représente le résultat que l'on souhaite obtenir suite à la fusion des 4 traces de la Figure 1.1.



S	Symbole	$s_i \in S$	I	Symbole	$i_k \in I$
s_1		(48.11521, 7.28391), ..., (48.12101, 7.30639)	i_1		(48.12122, 7.29370)
s_2		(48.12795, 7.29823), ..., (48.12222, 7.29782)	i_2		(48.12269, 7.29347)
s_3	—	(48.11712, 7.28371), ..., (48.12269, 7.29347)	i_3	●	(48.12223, 7.29785)
...		...	i_4		(48.12410, 7.29929)
s_n		$(lat_{n,1}, lon_{n,1}), \dots, (lat_{n,j}, lon_{n,j})$			

FIGURE 1.2 – Exemple de génération de carte suite à la fusion de traces. La carte se compose de 9 segments et de 4 intersections.

1.2.3 Système de projection et son importance


L'utilisation d'un système de projection est essentiel dans notre domaine, car il permet de représenter précisément la surface sphérique de la Terre sur un plan bi-dimensionnel. Travailler avec des représentations de données planes est crucial pour tout type de calcul que nous aurons à effectuer, tels que les distances et les angles, par exemple. Nous avons choisi le système de projection WGS 84 (World Geodetic System 1984), reconnu dans les travaux utilisant des traces GPS pour sa précision. En procédant ainsi, nous pouvons garantir que nos données sont interprétées de manière cohérente et précise, ce qui est essentiel pour la fiabilité et l'exactitude de la fusion de traces GPS.

1.2.4 Difficultés potentielles de l'analyse de traces GPS


Dans cette sous-section, nous explorons les défis liés à l'analyse de traces GPS. Ces difficultés englobent la précision des données GPS, la gestion des erreurs et redondances, les interruptions de signal, le bruit dans les traces, la scalabilité du traite-

ment des grandes quantités de données, l'hétérogénéité des sources, et les questions de confidentialité. Chaque aspect influence la qualité des résultats obtenus, soulignant l'importance d'adopter des stratégies adaptées pour surmonter ces obstacles dans le domaine de la géolocalisation.

1. **Précision et erreurs GPS** : Les dispositifs GPS ne sont pas toujours précis et peuvent introduire des erreurs dans les données de localisation. Des erreurs de quelques mètres peuvent fausser le résultat de la fusion, conduisant à des segments imprécis et des intersections mal placées.



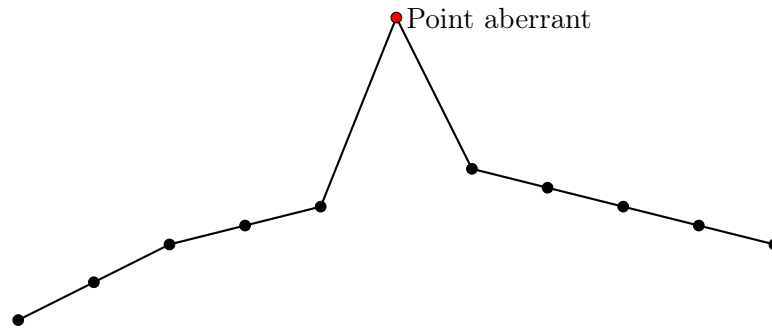
2. **Redondance** : Il est tout à fait possible qu'un utilisateur ait, volontairement ou non, enregistré un même point plusieurs fois, voire même une même trace plusieurs fois. Cela peut avoir des conséquences importantes sur la qualité du résultat selon la technique de fusion choisie, en introduisant un biais dans les données, en apportant une pondération plus importante à ces éléments.



3. **Gestion des interruptions GPS** : Il arrive que l'enregistrement des données GPS soit interrompu, laissant des sections de la randonnée sans informations de localisation. La stratégie adoptée pour gérer ces interruptions sera donc déterminante.



4. **Gestion du bruit** : Les traces peuvent contenir du bruit. Qu'ils soient temporels ou positionnels, ces points forment des aberrations qui rompent la continuité logique d'une trace. L'élimination de ces artefacts est requise pour une bonne inférence.



5. **Scalabilité** : La fusion de grandes quantités de traces peut poser des problèmes en termes de performance et d'efficacité. La gestion du temps d'exécution est une contrainte. L'objectif est de pouvoir mettre à jour une carte française le plus régulièrement possible.
6. **Hétérogénéité des données** : Les traces peuvent provenir de différentes sources et dispositifs, chacun ayant ses propres caractéristiques et précisions. La Figure 1.1 montre une trace avec marqueurs \blacklozenge ayant une fréquence d'acquisition plus faible que les 3 autres traces \bullet , \blacksquare , \blacktriangle .
7. **Respect de la vie privée** : La fusion de traces GPS d'utilisateurs peut soulever des questions de confidentialité et de protection des données. Il convient de s'assurer que le processus respecte toutes les réglementations pertinentes en matière de vie privée.

1.3 État de l'art

Au fil des dernières années, les données de trajectoire GPS ont été largement utilisées dans de nombreux domaines, incluant les études sur le comportement de conduite, l'analyse des intentions de déplacement [38, 48], l'analyse du flux de transport [69, 67], la prédiction du temps de trajet [57, 19], la planification des transports [67], et le suivi des déplacements des animaux [66]. Notre étude se focalise sur l'utilisation des trajectoires GPS enregistrées par des individus pour créer des cartes de randonnée. Nous estimons qu'en extrayant des informations précises sur les lieux de randonnée à partir de ces données, il est possible de produire des cartes plus exactes et plus actuelles que celles disponibles actuellement.

Contrairement aux méthodes traditionnelles qui combinent l'imagerie aérienne et les données de trajectoire GPS pour la cartographie, notre approche exclut intentionnellement l'utilisation de sources aériennes. Ceci permet d'inclure toutes les zones de randonnée possibles, y compris les forêts denses, les montagnes et les déserts, où l'interprétation des images aériennes peut être difficile. D'après une étude approfondie de Chao et al. [16] sur les algorithmes de déduction de cartes à partir de données GPS, trois catégories principales de techniques émergent : l'abstraction de la route, la ramification incrémentielle, et la connexion d'intersections. Cependant, il serait pertinent d'ajouter une quatrième catégorie pour refléter les avancées récentes, incluant les techniques d'apprentissage profond. Des approches innovantes comme l'extraction de lignes médianes et la squelettisation, proposées par Dal et al. [20], ne se classent pas clairement dans ces quatre catégories.

L'abstraction de la route vise à identifier les zones densément peuplées sur une carte et à extraire les réseaux routiers à l'aide d'algorithmes de regroupement. Cette méthode implique généralement trois étapes : la préparation des données, le regroupement et la génération de la route. Diverses techniques de regroupement, telles que k-means et le regroupement basé sur KDE (*kernel density estimation*), ont été utilisées pour créer des cartes routières. L'étude met en évidence trois méthodes représentatives : RA-K-MEANS, RA-TOPIC et RA-KDE [72, 92, 13], considérées comme des travaux pionniers dans ce domaine. Chaque méthode adopte des approches et des optimisations uniques pour l'inférence d'une carte.

Une autre méthode plus récente, décrite dans Guo et al. [32] construit une surface de densité à partir des données GPS, La compacte en utilisant une version améliorée de la méthode Slide puis enfin construit un réseau routier initial puis raffine ce réseau en calculant les poids des arêtes pour filtrer les arêtes incorrectes et améliorer la précision du réseau. En outre, une étude postérieure à l'étude de Chao et al. [16], réalisée par Yang et al. [85], se concentre sur les données piétonnières où les segments sont extraits en utilisant l'algorithme d'Analyse des Composantes Connexes (CCA) modifié et les chemins sont extraits via une méthode de regroupement de points basée sur KDE.

D'autres travaux sont notables dans ce domaine. En commençant par le plus récent, Arman et al. (2021) [9] ont innové avec une reconstruction de cartes numériques routières au niveau des voies en utilisant des données GPS de faible précision. Avant cela, He et al. (2021) [35] ont mis en œuvre une technique de reconstruction de signal pour une inférence précise des cartes. Chen et al. (2016) [17] ont utilisé des algorithmes de clustering pour extraire des segments de route à partir de données GPS et la fonctionnalité traj-SIFT pour la classification des jonctions routières. Suyi Wang et al. (2015) [79] ont utilisé la théorie de Morse pour une reconstruction adaptative des routes. Li et al. (2016) [47] ont proposé une technique de clustering spatial-linéaire pour inférer des segments routiers. Liu et al. (2012) [51] ont comparé divers algorithmes pour l'inférence de cartes à partir de données GPS. Enfin, Edelkamp et Schrödl (2003) [25] ont transformé des informations GPS en une structure de graphe pour la planification d'itinéraire.

La ramification incrémentale consiste à construire une carte en insérant de manière itérative de nouvelles routes dans une carte initialement vide, jusqu'à ce que toutes les trajectoires soient examinées. Il y a principalement deux méthodes utilisées : la fusion de traces et l'expansion de carte. La fusion de traces intègre progressivement les trajectoires dans la carte, en les combinant avec les routes existantes à l'aide de mesures de distance. Par contre, l'expansion de carte débute à partir d'un nœud de la carte et génère de nouvelles routes en fonction des trajectoires passant par ce nœud. L'état de l'art proposé par Chao et al. [16] identifie deux articles principaux représentant ces approches : IB-TM pour la fusion de traces et IB-ME pour l'expansion de carte [5, 37].

Récemment, une étude de Fu et al. [30] a introduit une méthode estimant les lignes médianes des routes à partir de la densité des trajectoires GPS et les fusionnant progressivement pour créer un réseau routier. Cette méthode utilise l'extraction de la ligne médiane de la route grâce à l'analyse de la densité du noyau (KDE) et à l'ajustement de la distribution gaussienne, suivie par la fusion et le raffinement

incrémentales des lignes médianes. Le travail de Cao et al. [14] représente l'une des premières tentatives d'utilisation de telles techniques de ramification incrémentale.

Les approches de connexion d'intersections visent à détecter avec précision les intersections et à établir des liens entre elles en utilisant des informations de trajectoire. Ces méthodes identifient les intersections en fonction des caractéristiques du mouvement de la trajectoire ou de la densité des points. Les principales étapes impliquent généralement : 1) examiner attentivement les points de la trajectoire enregistrée et isoler les groupes de points situés près des intersections, en s'assurant qu'ils répondent aux critères spécifiques relatifs à la direction et à la vitesse de déplacement ; 2) Regrouper les points d'intersection en fonction de la proximité ou de la similarité des virages pour délimiter les régions d'intersection et 3) établir des connexions entre les intersections directement liées par les trajectoires.

La méthode IL-TURN de Karagiorgou et al. [43] est considérée comme une méthode représentative dans cette famille de méthodes. Dans les publications ayant eu lieu après l'étude de Chao et al. [16] on retrouve Alsaifi et al. [6, 7], qui utilisent l'algorithme Douglas-Peucker [23] pour l'identification des intersections, et Guo et al. [31], qui utilisent la détection d'intersection basée sur Otsu[59] et le regroupement de trajectoires basé à la fois sur la similarité de distance et de direction. De plus, Zhou et al. [95] adoptent trois méthodes d'ajustement différentes pour différents types de liens afin d'assurer l'intégrité des résultats d'extraction, même avec une distribution de données de trajectoire GPS clairsemée et inégale. Enfin, Zhang et al. [88] utilisent l'algorithme CFDP (en anglais, *clustering by fast search and find of density peaks*) pour une détection précise des intersections.

Segmentation des lignes médianes par CNN La méthode de segmentation des lignes médianes utilisant les réseaux neuronaux convolutifs (CNN) s'est révélée être la plus récente et avancée pour créer des cartes à partir de données de trajectoire GPS. Cette approche émerge du développement des techniques d'apprentissage profond, survenu principalement après d'importantes études dans le domaine. Initialement, l'apprentissage profond était appliqué pour l'élagage des bords, comme l'illustre l'algorithme de Prabowo et al. [60]. Plus tard, des techniques d'apprentissage profond ont été utilisées pour combiner des images aériennes avec des données de trajectoire GPS, améliorant ainsi la précision de la segmentation. Sun et al. [74] ont montré les bénéfices d'intégrer les données GPS collectées par les utilisateurs en tant que couche supplémentaire à l'imagerie aérienne traditionnelle.

D'autres études ont exploré cette fusion, notamment celles de Wu et al. [80], Liu et al. [50], Li et al. [49], et Sun et al. [74]. Zhang et al. [90] ont proposé une méthode alternative en utilisant un CNN pour générer des données d'entraînement à partir de trajectoires GPS, avec des images aériennes comme support additionnel. Il existe également des recherches se concentrant exclusivement sur l'usage d'apprentissage profond avec des images aériennes pour l'inférence de cartes routières, sans inclure de données GPS [94, 96, 1]. Toutefois, notre article se focalise uniquement sur l'élaboration de cartes routières à partir de données de trajectoire GPS, sans s'appuyer sur des données supplémentaires comme l'imagerie aérienne. Pour atteindre cet objectif, quatre études majeures ont été menées : Ruan et al. [68], Freng et al. [27], Prabowo et al. [60] et Eftelioglu et al. [26]. Ces recherches représentent des progrès

significatifs dans le domaine, introduisant des méthodes novatrices pour créer des cartes routières en se basant uniquement sur les données GPS.

TABLE 1.1 Synthèse des méthodes récentes d'inférence de carte à partir de trajectoires GPS

Famille de méthode	Article
Abstraction de la route	Guo et al., 2021, [32] Yang et al., 2020, [85] He et al., 2021, [35] Zhang et al., 2019, [89] Arman et al., 2021, [9] Stanojevic et al., 2018, [72] Joseph et al., 2022, [42] De et al., 2023, [22] Guo et al., 2022, [31]
Ramification incrémentielle	Fu et al., 2020, [30] Cao et al., 2009, [14] Ahmed et al., 2012, [5] He et al., 2018, [37]
Connexion d'intersection	Alsahfi et al., 2019 and 2020, [6, 7] Guo et al., 2022, [31] Zhou et al., 2022, [95] Zhang et al., 2021, [88] Arman et al., 2020, [8] Shen et al., 2023, [71]
Segmentation de la ligne médiane CNN	Prabowo et al., 2019, [60] Ruan et al., 2020, [68] Feng et al., 2020, [28] Eftelioglu et al., 2022, [26]

1.3.1 Comparaison et analyse critique des méthodes existantes

Dans cette section, nous examinons les difficultés émergentes liées à la comparaison des différentes méthodes de pointe. Un premier enjeu concerne la diversité des données de trajectoire GPS dans les études. La variété des véhicules et modes de transport, y compris le vélo et la marche, peut significativement influencer les calculs et les caractéristiques du réseau déduit. Selon une récente review par Badran et al. [10], les études emploient diverses méthodes de validation, rendant la comparaison des résultats complexe. Par exemple, certaines études utilisent l'indice F-score pour mesurer la précision des réseaux par rapport aux cartes standards.

Cependant, la diversité des sources de données GPS utilisées dans ces recherches pour extraire les caractéristiques du réseau rend difficile la sélection de la meilleure méthode basée uniquement sur le F-score. Chao et al. [16] confirment que les évaluations actuelles et les comparaisons entre méthodes sont loin d'être complètes et

manquent de précision. Cette problématique sera abordée dans un chapitre dédié de ce manuscrit, compte tenu de son importance. Enfin, la reproductibilité de plusieurs études est remise en question, soit à cause d’une description imprécise de la méthode, soit en raison de données non disponibles, compliquant ainsi la comparaison de leurs résultats avec d’autres études.

1.4 Enjeux, défis et contributions de la recherche

1.4.1 Défis non résolus dans la fusion de traces GPS

La fusion de traces GPS consiste à combiner avec précision plusieurs ensembles de données GPS en une seule trajectoire cohérente et représentant la trace réelle empruntée lors des déplacements enregistrés. Cette fusion reste un défi majeur actuellement, car elle se confronte à plusieurs obstacles liés à la qualité et à la diversité des données. Les imprécisions inhérentes au signal GPS, les différences de fréquences d’échantillonnage entre les dispositifs, ainsi que l’intégration des données dans des zones de faible signal GPS, telles que les zones urbaines denses ou les forêts, sont des problèmes critiques. La protection de la vie privée et la sécurisation des données personnelles ajoutent une complexité supplémentaire à ces défis techniques.

Par ailleurs, la standardisation des algorithmes représente un enjeu notable, aggravé par le manque de normes uniformes et la réticence à partager les codes sources, limitant ainsi les possibilités de comparaison et d’amélioration collaborative. Cette fragmentation méthodologique complique l’évaluation et la validation des réseaux routiers déduits, d’autant plus que l’utilisation de métriques comme l’indice F-score, bien que courante, ne reflète pas entièrement la qualité qualitative et la précision géographique des cartes. Un autre défi crucial est l’intégration des facteurs environnementaux et urbains affectant la qualité du signal GPS, et donc la fiabilité des inférences. Ces facteurs ne sont pas systématiquement pris en compte dans les évaluations actuelles, conduisant parfois à des résultats qui ne représentent pas fidèlement la complexité des conditions de réception du signal GPS. Enfin, calculer précisément les intersections et assurer une connectivité adéquate du réseau généré demeurent des verrous techniques, soulignant le besoin d’approches innovantes pour améliorer la cohérence et l’intégrité des données dans le domaine de la fusion de traces GPS.

1.4.2 Contributions uniques de cette recherche

Face à l’absence d’uniformité dans les normes d’évaluation des graphes générés dans notre domaine, nos travaux visent à contribuer à l’uniformisation de ces normes pour la fusion de traces GPS. Le **Chapitre 2** sera entièrement dédié à cette problématique cruciale. Nous y examinerons les différents jeux de données et leurs spécificités, tels qu’identifiés par l’état de l’art, ainsi que leurs cadres de référence. Nous procéderons aussi à une analyse détaillée des différentes métriques utilisées actuellement pour mesurer la conformité entre une carte générée et un modèle de référence, soulignant les limites de ces métriques dans l’identification des problèmes propres à une carte générée automatiquement. Notre contribution consistera en un appel à une prise de conscience au sein de la communauté scientifique,

essentielle pour un progrès rigoureux dans la fusion de traces GPS. Nous justifierons les métriques que nous considérons comme les plus efficaces, tout en fournissant des arguments solides à leur appui.

Nos efforts se concentreront ensuite sur la fusion de traces GPS elle-même, avec le développement de deux méthodes novatrices. La première, présentée dans le **Chapitre 3**, repose sur des techniques de clustering et se distingue par sa capacité à produire des cartes de haute qualité. Le **Chapitre 4** explore l'utilisation des techniques d'apprentissage profond pour extraire les lignes centrales à partir d'images rastérisées de traces GPS. Nous soulignerons le manque d'études se concentrant exclusivement sur cette fusion sans recourir à des données aériennes, mettant en évidence une lacune significative dans le domaine. En reconnaissant le caractère innovant de la fusion pour les réseaux de neurones, notre étude réoriente les objectifs initiaux pour jeter les bases de ce domaine peu exploré. Nous nous attacherons à la façon dont les données sont présentées aux réseaux de neurones et à la comparaison de cette présentation avec celles de l'état de l'art, afin de déterminer les informations essentielles et leur format optimal.

Enfin, nous étudierons les architectures neuronales les plus prometteuses, évaluant leur potentiel pour relever le défi de la fusion de traces GPS. Cette thèse vise non seulement à enrichir le corpus scientifique existant, mais aussi à établir une méthodologie pour les recherches futures, créant ainsi une fondation solide pour les avancées dans le domaine complexe de la fusion de traces GPS par l'intelligence artificielle.

1.4.3 Implications pour l'industrie et Visorando

L'utilisation avancée des traces GPS pour générer des cartes topographiques représente une innovation majeure pour les applications de randonnée, tant en France qu'à l'échelle internationale. Cette évolution a pour but d'utiliser les données recueillies par des randonneurs actifs afin de créer des cartes précises et fidèles à leur expérience sur le terrain. L'objectif est de fournir aux randonneurs, à la fois sources et utilisateurs des données GPS, des cartes qui reflètent exactement les parcours et les points d'intérêt qu'ils fréquentent. Le principal défi est de se détacher des cartes traditionnelles, qui sont souvent coûteuses et ne représentent pas toujours fidèlement les sentiers réellement parcourus.

En produisant ses propres cartes, Visorando vise à offrir un niveau de détail et une représentation des sentiers la plus proche de la réalité et actualisée en permanence, ce qu'aucun acteur actuel ne propose sur le marché. Les cartes résultantes mettront en évidence les segments de sentiers et leurs intersections, permettant une analyse et des annotations vectorielles précises des itinéraires, une fonctionnalité non disponible avec les cartes raster conventionnelles. Avec cette nouvelle approche cartographique, Visorando envisage de proposer une gamme de fonctionnalités inédites à ses utilisateurs, enrichissant ainsi les possibilités d'interaction et d'expérience. L'atout principal réside dans la personnalisation de la carte, s'adaptant continuellement aux pratiques changeantes de la randonnée, assurant ainsi une expérience utilisateur optimale et une précision sans précédent.

1.5 Reproductibilité des travaux

Comme mentionné précédemment, notre domaine de recherche, centré sur la fusion de traces GPS, est confronté à un problème récurrent : le manque de partage des données et des codes sources par les chercheurs, ce qui limite grandement la possibilité de comparer les travaux. Conscients de cet obstacle, nous avons pris des mesures pour assurer la clarté de nos méthodes et faciliter leur réimplémentation, ce qui est expliqué en détail dans ce manuscrit. Il est important de noter que le code source développé est protégé par les droits de propriété intellectuelle de Visorando et ne sera donc pas divulgué dans cette thèse. Cependant, cela n'exclut pas la possibilité que Visorando choisisse de partager ce code avec la communauté scientifique à l'avenir.

Dans un souci de transparence et pour assurer la reproductibilité de nos résultats, nous mettons à disposition toutes les cartes générées utilisées dans nos expériences, ainsi que les protocoles expérimentaux. Cette approche démontre notre engagement à contribuer activement au progrès scientifique dans notre domaine. Nous insistons sur l'importance du partage des codes sources auprès de nos collègues chercheurs. La réticence à rendre ces ressources accessibles représente un frein majeur à l'évolution de notre discipline. Nous appelons à une culture de collaboration plus ouverte, afin de progresser collectivement de manière plus rapide et transparente dans la compréhension et l'application de la fusion de traces GPS.

Évaluation de cartes créées par fusion de traces GPS

Introduction

L'évaluation de la génération automatique de cartes représente un domaine crucial, bien que encore sous-développé dans l'état de l'art actuel. Pour mesurer l'efficacité des algorithmes d'inférence, la mise en place d'un protocole d'évaluation précis s'avère impérative. Cette démarche permet non seulement de comparer les résultats obtenus, mais aussi d'orienter les réflexions et les développements futurs, et d'identifier les aspects du graphe généré qui nécessitent des ajustements. Par conséquent, la tâche d'évaluation est essentielle et justifie la rédaction d'un chapitre entier à ce sujet dans ce manuscrit. Dans ce chapitre, nous présenterons le cadre global d'évaluation, en examinant les différents aspects d'un graphe nécessitant une évaluation. En outre, en reconnaissant la nécessité d'une référence pour la comparaison, nous énumérerons les différentes méthodes de génération d'une carte de référence. Nous décrirons ensuite les problèmes potentiels inhérents à un graphe. Après cette introduction, nous discuterons des différentes métriques proposées par l'état de l'art, ainsi que de celles que nous avons développées. Nous analyserons la pertinence de ces métriques et les confronterons aux problèmes spécifiques des graphes pour déterminer quelle métrique est la plus apte à détecter chaque problème. Il apparaîtra clairement que nous sommes encore loin de posséder un cadre d'évaluation idéal. Une réflexion intéressante à mener concerne la place de l'évaluation visuelle dans ce cadre. Bien que l'évaluation quantitative, basée sur des scores, offre une précision notable, nous verrons qu'un ajout d'analyses visuelles peut apporter des informations complémentaires souvent cruciales. En conclusion de ce chapitre, nous justifierons nos choix de métriques pour les expériences que nous entreprendrons dans ce manuscrit.

Les enjeux associés à l'évaluation d'une carte générée par un algorithme sont considérables. Une évaluation inadéquate d'une carte issue de la fusion de traces GPS peut entraîner de multiples complications. Premièrement, elle risque de compromettre la sécurité, notamment en reliant deux chemins séparés par une falaise, mettant ainsi en péril la vie des utilisateurs. Cette situation est illustrée dans la Figure 2.1, où les traces dans la zone rouge (Figure 2.1a et 2.1b) sont fortement sus-

ceptibles d'être fusionnées par un algorithme en raison de leur proximité. La création d'un segment dans cette zone particulièrement abrupte (Figure 2.1c) pourrait avoir des conséquences désastreuses. De plus, des erreurs de représentation, telles que la création de chemins fictifs ou l'omission de routes essentielles, peuvent induire les utilisateurs en erreur et les conduire vers des impasses. Les incohérences, comme les intersections mal positionnées ou les segments de route mal représentés, peuvent également engendrer de la confusion. Par conséquent, une évaluation rigoureuse et approfondie s'avère essentielle pour assurer une utilisation sûre et efficace de la carte.

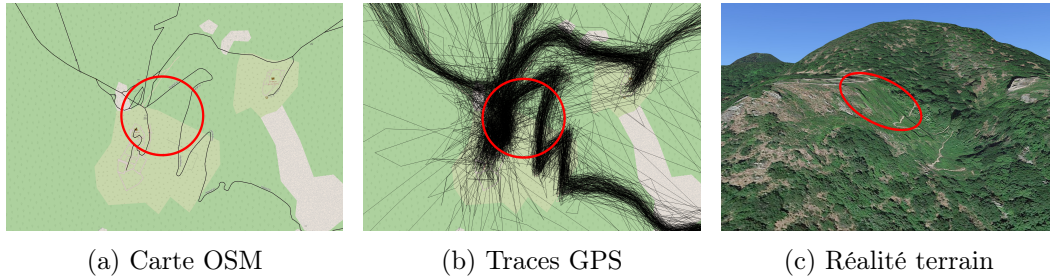


FIGURE 2.1 – Exemple d'une situation dangereuse où les traces GPS utilisateurs tendent à connecter 2 segments séparés par une falaise. © OpenStreetMap contributors [58], GoogleLandsat / CopernicusData SIO, NOAA, U.S. Navy, NGA, GEBCOGeoBasis-DE/BKG (©2009)IBCAO

2.1 Analyse des données de graphe

2.1.1 Indicateurs de qualité

L'évaluation d'une carte générée automatiquement ne se limite pas à une simple comparaison visuelle : elle exige une approche quantitative et méthodique. Cette section a pour objectif de présenter les critères principaux retenus pour évaluer la qualité des cartes générées par rapport à une carte de référence. Nous aborderons trois aspects fondamentaux : la qualité des segments, la pertinence des nœuds d'intersection et la connectivité globale de la carte. Ces critères, parfois négligés dans les méthodologies actuelles, sont essentiels pour assurer une représentation cartographique fidèle, intuitive et, surtout, adaptée à des applications pratiques, qu'elles soient urbaines ou en milieu naturel.

2.1.1.1 Qualité des segments générés

La qualité d'un segment inféré par un algorithme de génération de cartes dépend de plusieurs facteurs. Il est crucial de partir d'une position correcte pour atteindre la destination voulue, mais la forme et la précision du trajet sont également importantes. Pour chaque segment $s_x \in C_r$ de la base de données de référence, son équivalent dans la base de données inférée $s_x \in C_i$ peut présenter diverses anomalies. Évaluer ces aspects est très important pour obtenir une estimation robuste de la qualité de chaque segment. Ci-dessous, nous présentons une liste des critères auxquels nous accorderons une attention particulière tout au long de nos travaux, et que nous chercherons à identifier et à évaluer lors de l'analyse de notre solution :

- **Forme des segments** : Les segments inférés peuvent différer en forme de ceux de la base de données de référence, avec des anomalies telles que des zigzags ou des boucles. Identifier et sanctionner ces écarts est essentiel pour évaluer précisément la qualité des segments.
- **Discontinuités dans les segments** : Les segments inférés peuvent présenter des discontinuités, c'est-à-dire des ruptures dans leur tracé. Ces interruptions influent sur la qualité des segments et doivent être prises en compte dans leur évaluation.
- **Longueur des segments** : La longueur des segments est un facteur important. Les segments inférés peuvent être plus courts ou plus longs que ceux de la base de référence, impactant ainsi leur qualité et l'intégrité du réseau.

2.1.1.2 Précision des intersections

Dans notre étude, nous accordons autant d'importance aux intersections qu'aux segments eux-mêmes. En effet, ces points particuliers dans les traces GPS représentent des jonctions entre différents chemins, faisant office de zones stratégiques pour les randonneurs lorsqu'il s'agit de choisir une direction. Il est donc essentiel d'identifier correctement les intersections, qu'elles se trouvent en milieu urbain ou en montagne. Lors de l'évaluation des intersections, il est primordial de mesurer :

- **Le taux de détection** : avons-nous bien identifié toutes les intersections ?
Lesquelles manquent ?
- **La précision** : l'écart en mètres par rapport à leur position réelle.

Bien que ces indicateurs soient rarement abordés dans la littérature, ils nous semblent fondamentaux pour estimer la qualité du graphe généré.

2.1.1.3 Connectivité de la carte

La **connectivité** des segments constitue une variable critique pour l'utilisateur, dans la mesure où elle détermine la capacité à se déplacer d'un point *A* à un point *B*. Une connectivité efficace est essentielle pour une cartographie précise et fiable. Elle ne se limite pas à améliorer la navigation, mais contribue aussi significativement à l'analyse et à la compréhension de l'espace géographique d'une région. Imaginons des segments utilisés pour cartographier le territoire français. Si ces segments présentent des problèmes de connectivité, cela pourrait entraîner une perte de temps et d'énergie, réduisant l'efficacité de l'outil pour nos utilisateurs. Il est donc crucial de s'assurer que les segments cartographiques soient correctement alignés et connectés lors de la création de la carte. Il est essentiel d'identifier les segments qui devraient être connectés mais ne le sont pas, de même que ceux qui sont interconnectés de manière erronée. Par exemple, des éléments physiques tels qu'un édifice obstruant deux voies ou une rupture de pente abrupte. Si ces éléments ne sont pas précisément identifiés sur la carte, l'expérience de l'utilisateur en sera une fois de plus affectée.

2.1.2 Sources de référence

Lors de l'évaluation des cartes générées, il est essentiel de disposer de points de comparaison fiables et pertinents. Cette section se concentre sur les différentes sources de référence pouvant servir de base pour comparer les cartes inférées issues

des algorithmes testés. Nous examinerons tout d’abord la base de données OpenStreetMap (OSM) [58], reconnue pour son accessibilité et sa couverture géographique étendue, ce qui en fait un choix incontournable. Puis, nous nous intéresserons à des fragments spécifiques d’OSM, afin de réaliser une analyse plus détaillée et ciblée. En dernier lieu, nous considérerons des cartes créées manuellement, offrant une perspective unique et adaptée. Chacune de ces trois sources présentant ses avantages et ses limites, nous enrichirons notre discussion par les choix réalisés par l’état de l’art concernant la source de référence. Nous concluons cette section en expliquant et justifiant notre choix personnel pour la source de référence.

Notons que Arman et al. [9, 8] ont porté leur choix sur Google Maps au lieu d’OpenStreetMap (OSM). Ce choix est considéré comme peu courant dans la communauté scientifique, compte tenu des avantages d’OSM. OpenStreetMap est souvent préféré à Google Maps pour le travail avec des données cartographiques en raison de sa nature open source qui offre une plus grande liberté d’utilisation et de modification, une personnalisation plus poussée, et l’accès aux données brutes. En outre, OSM est alimenté par une communauté mondiale, assurant des mises à jour fréquentes et détaillées, particulièrement utiles pour les zones moins couvertes par Google Maps. Enfin, OSM est gratuit, ce qui le rend attrayant pour des utilisations à grande échelle et pour des projets avec des contraintes budgétaires.

2.1.2.1 Base de données OpenStreetMap (OSM)

L’une des stratégies les plus couramment adoptées pour l’évaluation des cartes est de recourir à des bases de données cartographiques préexistantes, largement reconnues pour leur fiabilité. Il est préférable que ces bases soient communautaires, c’est-à-dire qu’elles permettent des modifications et des contributions de la part des utilisateurs du monde entier. Cette approche garantit une mise à jour régulière et précise des données. OpenStreetMap (OSM) se distingue dans ce domaine, privilégiant la connaissance locale, la collaboration à l’échelle mondiale, et offrant un libre accès à ses données. Ainsi, lorsqu’il s’agit d’évaluer des algorithmes de création de cartes, il est naturel de se référer à une base telle qu’OSM [26, 28, 35, 52, 31, 37]. Pour cela, une extraction des données d’OSM pertinentes à la zone d’étude est réalisée.

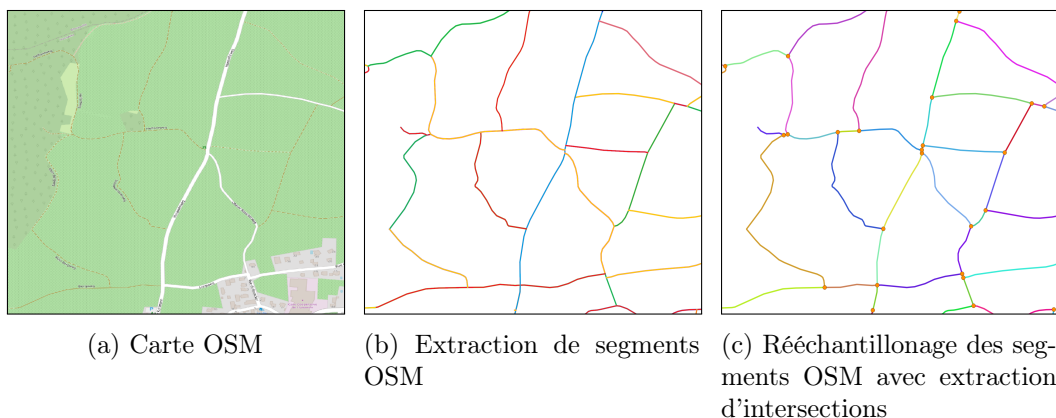


FIGURE 2.2 – Création d’une carte de référence par extraction OSM. © OpenStreetMap contributors [58]

Lors de l'extraction d'une base de données depuis OpenStreetMap (OSM), le découpage des segments peut ne pas correspondre à nos besoins spécifiques. Par exemple, nous pourrions nécessiter des segments qui s'arrêtent à chaque intersection, où les chemins se divisent. Cependant, une extraction standard depuis OSM ne respecte pas toujours ces critères de segmentation. Pour illustrer ce point, prenons l'exemple du segment bleu sur la Figure 2.2b, qui représente le chemin principal dans cette extraction, clairement visible sur la Figure 2.2a. Bien que ce segment croise plusieurs intersections, il n'est pas automatiquement segmenté à ces points par OSM. Il est donc nécessaire de réaliser ce découpage manuellement. Les résultats de ce processus de segmentation sont visibles sur la Figure 2.2c. Grâce à l'utilisation de différentes couleurs, nous pouvons observer que les segments ont été correctement isolés et que des intersections supplémentaires ont été ajoutées, rendant la carte bien plus adaptée à l'évaluation d'algorithmes d'inférence cartographique. Le pseudo-code présenté en annexes 1 décrit notre méthode pour le rééchantillonnage des segments OSM. Cette méthode commence par diviser les segments en sous-segments aux points d'intersection, puis fusionne ceux qui étaient faussement considérés comme intersectants, afin de produire une liste de segments adaptée.

2.1.2.2 Extraction OSM partielle

L'approche d'extraction partielle d'OSM vise à cibler spécifiquement les segments de données utiles dans OpenStreetMap pour l'analyse des traces GPS. Contrairement à une extraction complète, cette méthode ne prend en compte que les segments qui correspondent directement aux traces GPS analysées. Ceci est réalisé en appliquant des filtres avancés qui éliminent les données superflues, comme les segments non empruntés et les intersections non pertinentes. Seuls les segments pour lesquels il existe des traces GPS correspondantes dans notre base de données sont conservés. Cela permet de s'assurer que chaque segment inclus dans l'analyse reflète un chemin potentiellement emprunté par les auteurs des traces GPS.

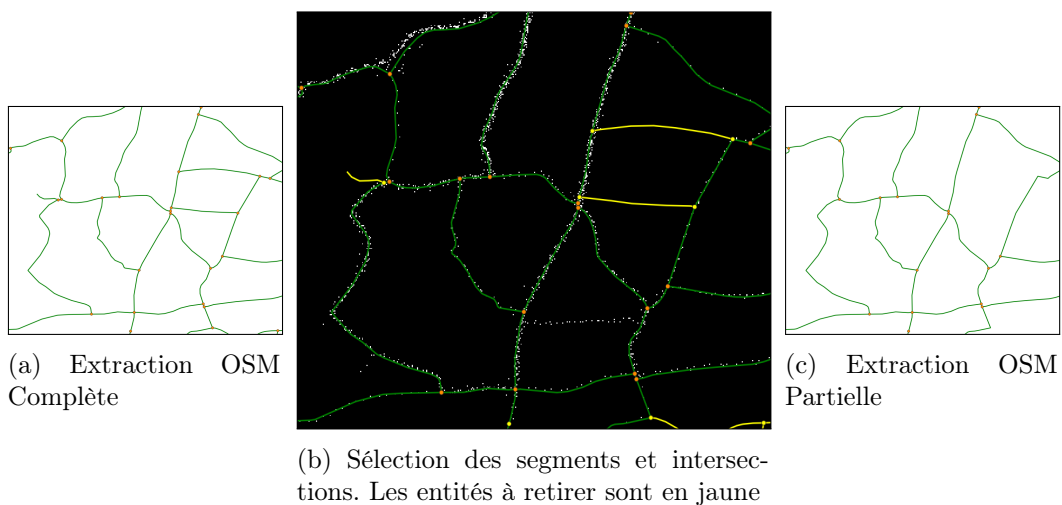


FIGURE 2.3 – Construction d'une carte OSM Partielle. © OpenStreetMap contributors [58]

La Figure 2.3 illustre la création d'une carte de référence partielle à partir d'une extraction complète des données OpenStreetMap (OSM) dans une zone définie. Pour obtenir une compréhension visuelle du processus de sélection des segments, nous avons généré une image binaire représentant les traces GPS qui se superpose avec l'extraction OSM complète. Cette superposition est présentée dans la Figure 2.3b. Les résultats mettent en évidence le fait que les segments de référence non empruntés par les utilisateurs sont exclus de la carte partielle OSM. Cette sélection a pour effet de retirer de la carte partielle les tronçons qui n'ont pas été utilisés. De même, les intersections de référence qui ne trouvent plus d'utilité sont également écartées de la carte partielle. Nous donnons en annexe 2 un algorithme qui détaille une des implémentations possible pour réaliser une carte OSM, qui a été développé dans le cadre de ces travaux de thèse.

2.1.2.3 Création manuelle de cartes

En dehors des méthodes basées sur des bases de données préexistantes, il est également possible de créer manuellement des cartes de référence [22]. Cette technique consiste à dessiner à la main une carte basée sur les résultats attendus après la fusion des traces GPS. En d'autres termes, lors de cette approche manuelle, le cartographe superpose les données GPS et esquisse la carte en fonction de sa perception de la réalité du terrain. Cette méthode permet d'obtenir une carte de référence sur-mesure, adaptée spécifiquement à l'objectif de l'étude.



(a) Représentation binaire des traces GPS (b) Superposition de a) et de c) (c) Extraction Manuelle des segments et des intersections

FIGURE 2.4 – Création d'une carte de référence par annotation manuelle. © OpenStreetMap contributors [58]

À partir de la Figure 2.4, nous observons un réseau de segments qui ont été annotés manuellement, superposés à une image représentant de manière binaire des traces GPS. Cette annotation manuelle exige une grande concentration et une précision méticuleuse. Étant un travail humain, elle s'accompagne de prises de décisions qui reflètent la subjectivité de son auteur. Dans notre exemple, nous avons choisi d'annoter tous les segments visibles sur la carte binaire (Figure 2.4a), y compris ceux empruntés une seule fois. Toutefois, il est envisageable d'opter pour un seuil de densité différent, permettant d'exclure les segments moins fréquentés. Il est essentiel, lors de cette annotation, de conserver une cohérence dans l'approche adoptée sur l'ensemble de la carte. Dans cet article, nous avons opté pour l'annotation de

tous les segments, quelle que soit leur densité. Nous sommes cependant conscients que cette approche peut influencer les résultats. En effet, certains segments, bien que présents sur la carte, peuvent ne pas être pertinents ou utilisables dans la réalité pratique. Une sélection plus rigoureuse sera effectuée lors de la finalisation de cette recherche, endors du cadre de la thèse.

2.1.2.4 Analyse critique des méthodes de génération de cartes de référence

Les deux techniques se basant sur OSM pour la création d'une carte de référence comportent des avantages et des inconvénients communs. En utilisant OSM, les études bénéficient d'une vaste couverture géographique puisque cette base englobe presque tous les endroits du monde, garantissant ainsi une couverture systématique des zones d'étude. De plus, grâce à sa nature communautaire, OSM est régulièrement mis à jour, ce qui renforce sa fiabilité.

Cependant, l'utilisation d'OSM pose un certain nombre de problèmes comme notamment les potentielles incohérences introduites par les contributions des utilisateurs, principalement des erreurs ou des omissions. Lorsqu'on utilise la carte OSM dans son intégralité, un autre écueil courant est la surcharge d'informations non pertinentes, notamment des segments et intersections non traversés par la trace GPS, un problème contourné lors de l'usage d'une carte partielle. Néanmoins, la conception de cette dernière nécessite un développement supplémentaire pour le filtrage, et implique une certaine subjectivité quant aux critères de sélection des segments à intégrer. Une extraction standard via OSM produit des segments basés sur les types de chemins. Autrement dit, un changement de type de chemin signifie la fin d'un segment et le début d'un autre. Cependant, pour nos besoins, un segment devrait plutôt se terminer à une intersection. Étant donné que ces intersections ne sont pas toujours présentes dans OSM, il devient évident que son utilisation nécessite un prétraitement pour segmenter adéquatement et générer les intersections appropriées.

Le principal inconvénient d'une extraction via OSM, comparée à une notation manuelle, réside dans sa fidélité à la réalité. Il est possible qu'un segment d'OSM soit mal positionné ou même absent, alors que l'objectif de cette étude est de générer de nouveaux segments à partir des traces GPS non forcément présents sur des cartes existantes. Certains exemples sont visibles sur la Figure 2.5. Ces problèmes sont la raison pour laquelle nous avons régulièrement opté pour l'utilisation d'une carte annotée manuellement, plus fidèle à la trace GPS. Malgré ses avantages, la création manuelle présente aussi des inconvénients : elle est fortement influencée par la perception de son créateur et est très chronophage.

2.2 Métriques d'évaluation d'une carte

L'évaluation d'une carte inférée par rapport à une carte de référence est cruciale dans toutes les études traitant de ce sujet. Cependant, les techniques d'évaluation ont évolué au fil du temps, et il semble exister un manque d'uniformité dans le choix des métriques. Cette divergence est également observable dans le choix du jeu de données ou de la carte de référence.




FIGURE 2.5 – Illustration de problèmes liés à une extraction OSM

Dans cette section, nous explorerons les différentes métriques proposées au fil des années pour l'évaluation de cartes. En nous appuyant sur l'analyse menée dans l'article [16], nous examinerons la pertinence de chaque métrique vis-à-vis d'un critère d'évaluation spécifique. Nous constaterons que la majorité de ces métriques ont du mal à se concentrer sur un critère unique, rendant ainsi leur interprétation complexe.

2.2.1 Évaluation des segments

2.2.1.1 Appariement des segment

Afin de pouvoir comparer la carte générée à une carte de référence, il convient tout d'abord de mettre en correspondance chaque segment généré avec un segment, le plus similaire/proche, de la vérité terrain. Ensuite, il est possible de quantifier les différences entre eux. Bien que la majorité des travaux s'appuient sur cette technique de correspondance, le type d'entité (segments [33], lignes [45], etc.) pris en compte et la méthode utilisée pour établir ces correspondances varient d'une étude à l'autre. Nous avons identifié plusieurs méthodes permettant d'associer les segments entre eux.

TOPO Introduit par [12] et très largement adopté par la communauté [68, 72, 30, 37, 26], TOPO est une évaluation basée sur l'exploration locale. En partant d'un point de départ aléatoire, elle explore les segments de route dans chaque carte en déposant des "trous virtuels" ou des "billes" à des intervalles réguliers jusqu'à une distance maximale déterminée. Lors de l'exploration, les intersections sont également prises en compte, en privilégiant les segments de route menant loin du point de départ, afin de minimiser les parcours improbables tels que les demi-tours. Une fois l'échantillonnage terminé pour les deux cartes, une comparaison est effectuée : si une "bille" (représentant un point d'un segment de la carte générée) se trouve à proximité d'un "trou" (représentant un segment de la carte de référence), cela indique une correspondance. Les "billes" non appariées désignent des segments hypothétiques de la carte générée, tandis que les "trous" sans "bille" correspondent à des segments manquants.

Distance pathbased Cette méthode permettant d'établir des correspondances entre deux cartes de réseau routier a été introduite par Ahmed et al. [2] et a été utilisée dans plusieurs travaux ultérieurs [32, 24, 75]. Lors de la comparaison de deux cartographies routières, la superposition directe peut se révéler insuffisante pour une analyse détaillée. Le document propose une méthode basée sur la décomposition des graphes en ensembles distincts de chemins. La clé pour comparer individuellement ces chemins réside dans l'utilisation de la distance de Fréchet, une métrique qui quantifie la ressemblance entre deux séquences ou trajectoires.

Mesure de proximité entre points de référence et segment Dans la méthode proposée par Hashemi et al. [33] et utilisée dans les travaux ultérieurs [93, 40], l'association des segments issus d'une carte générée et d'une carte de référence repose sur une méthodologie précise basée sur la mesure des distances. Chaque segment du réseau construit est systématiquement comparé au segment le plus proche dans le réseau de référence. Pour évaluer la distance entre deux segments donnés, une approche basée sur des points de forme est adoptée. Concrètement, pour un segment A du réseau construit, chaque point de forme est mesuré par rapport au segment B du réseau de référence, produisant ainsi un ensemble de distances minimales. Ces distances sont ensuite assemblées dans un tableau dont la taille correspond au nombre de points de forme du segment A. La distance finale entre les segments A et B est alors calculée en prenant la moyenne des distances contenues dans ce tableau. Cette méthode permet d'établir une correspondance univoque entre chaque segment du réseau construit et un segment du réseau de référence, assurant ainsi une association précise et systématique.

Distance et angles Dans la méthode décrite par Liu et al. [51], chaque segment de route de la carte de référence est échantillonné à intervalles réguliers d'un mètre. Pour chaque échantillon, on détermine si celui-ci se situe à une distance perpendiculaire inférieure à un seuil défini d'un segment de la carte inférée. De plus, l'angle entre le segment de la carte de référence et celui de la carte inférée ne doit pas excéder 60 degrés. Cette restriction permet d'éviter des correspondances inexactes aux intersections tout en tolérant certaines imprécisions dans l'alignement. Grâce à cette méthode, même si une route inférée est sinueuse à proximité d'une route de référence droite, la longueur totale reconnue comme correcte ne dépasse pas celle de la route de référence. Cette technique a été employée dans les travaux de Liu et al. [51], Qiu et al. [64], ainsi que dans [63].

Correspondance de pixels Le processus de correspondance repose ici sur une comparaison précise, pixel par pixel, entre deux ensembles transformés en grilles. Ces grilles sont alimentées par les segments pour produire deux cartes binaires. Un 'pixel valide' désigne un pixel de la carte de référence qui coïncide parfaitement avec un pixel de la carte générée. Idéalement, chaque pixel de la première carte devrait avoir un équivalent dans la seconde carte. Toutefois, des variations peuvent survenir. Certains pixels peuvent être présents sur une carte mais absents sur l'autre, indiquant ainsi soit un segment manquant, soit un segment incorrect. Cette approche de mise en correspondance par imagerie a été introduite par Mariescu et al. [56] et réemployée par Zhang et al. [88].

Nous avons observé que les techniques d'appariement des segments constituant des cartes varient grandement. Aucune d'entre elles n'a véritablement été reconnue comme une technique de référence par la communauté. De plus, certaines études, comme [28, 22, 89], omettent même de préciser la méthode employée pour cette mise en correspondance.

2.2.1.2 Évaluation de la différence entre segments

Après avoir établi la correspondance entre les segments, nous pouvons maintenant procéder à l'analyse proprement dite. Toutefois, en raison de l'indécision persistante dans l'état de l'art concernant la meilleure stratégie à adopter, nous allons énumérer de nouveau les différentes techniques utilisées pour quantifier les différences entre les deux cartes.

La précision compare la quantité de prédictions correctes à l'ensemble des prédictions positives faites par un algorithme. En d'autres termes, elle mesure la pertinence des prédictions positives. La formule de la précision est la suivante :

$$\text{Précision} = \frac{\text{Nombre de vrais positifs}}{\text{Nombre de vrais positifs} + \text{Nombre de faux positifs}}$$

Les 'vrais positifs' représentent les cas où le modèle a correctement prédit une entité comme positive, et cette prédiction est effectivement correcte. Les 'faux positifs' sont les cas où le modèle a prédit une entité comme positive, mais cette prédiction est incorrecte, c'est-à-dire que l'entité n'était pas réellement présente dans la carte de référence. Cet indicateur permet de mesurer la prudence de l'algorithme dans ses prédictions positives et d'évaluer sa capacité à éviter de générer des prédictions fausses ou erronées. Certains articles, comme celui de Yang et al. [85], utilisent la précision comme un indicateur à part entière, sans la combiner au rappel pour former un FScore, que nous décrivons ci-dessous.

Le rappel est un indicateur qui mesure la capacité d'un algorithme à identifier l'intégralité des entités présentes dans la carte de référence. En d'autres termes, il évalue dans quelle mesure les prédictions correctes de l'algorithme sont exhaustives et couvrent toutes les entités réellement présentes. La formule du rappel est la suivante :

$$\text{Rappel} = \frac{\text{Nombre de vrais positifs}}{\text{Nombre de vrais positifs} + \text{Nombre de faux négatifs}}$$

Dans cette formule, les 'vrais positifs' sont les cas où l'algorithme a correctement identifié une entité présente dans la carte de référence, tandis que les 'faux négatifs' sont les cas où l'algorithme a omis de détecter une entité réellement présente. Le rappel est donc crucial pour évaluer l'efficacité d'un algorithme dans la détection complète des entités. Une fois encore, certaines études comme [22, 33] utilisent cet indicateur seul sans le mettre en lien avec la précision.

Le F1Score, que nous nommerons FScore puisque dans cette étude $\beta = 1$, est une mesure qui équilibre la précision et le rappel, et est souvent crucial pour évaluer globalement les performances d'un modèle. Il offre une évaluation globale des

performances d'un algorithme d'inférence de carte en tenant compte à la fois de la précision et de l'exhaustivité des prédictions. La formule du FScore est la suivante :

$$\text{FScore} = \frac{2 \times \text{Précision} \times \text{Rappel}}{\text{Précision} + \text{Rappel}}$$

Le FScore permet de combiner les avantages de la précision et du rappel en une seule métrique, offrant ainsi une vision plus complète de la performance d'un algorithme. Le FScore est particulièrement utile dans les situations où un équilibre entre la précision et le rappel est nécessaire. Un FScore élevé indique à la fois une bonne précision et un bon rappel puisqu'il s'agit d'une moyenne harmonique de ces deux indicateurs. Il s'agit de la métrique la plus utilisée dans l'état de l'art [26, 35, 56, 30, 45, 10].

Méthodes basées sur l'itinéraire Cette approche repose sur la comparaison de trajets. Elle se fonde principalement sur l'identification des chemins les plus courts entre divers points de départ et d'arrivée, à la fois sur la carte en cours d'évaluation et sur une carte de référence. La clé de cette évaluation réside dans la mesure des distances entre ces itinéraires. He et al. [37] utilisent des paires origine-destination échantillonnées aléatoirement à partir des données de trajectoires GPS pour calculer la distance de Fréchet médiane entre les chemins les plus courts dans la carte inférée et la carte de référence afin d'évaluer l'erreur de routage. De même, Karagiorgou et al. [45] ont utilisé cette approche dans leurs études, mais en recourant à la distance de Fréchet discrète.

Précision en mètres Jusqu'à présent, aucune métrique n'a directement évalué la précision géographique. Cependant, certains travaux ont exploré cette dimension en cherchant à déterminer la correspondance entre les segments générés et leurs homologues réels, en mettant de côté les erreurs topologiques. Hashemi et al. [33] utilisent, par exemple, un algorithme leur permettant de faire correspondre les segments des deux cartes basé sur les distances entre eux. En calculant la moyenne de ces distances, ils parviennent à une mesure de précision métrique. Une autre approche, que nous avons relevée, consiste à combiner une métrique avec un FScore, tel que 'topo', et à l'ajuster à plusieurs reprises avec différents seuils de correspondance. Si en abaissant le seuil, le FScore diminue peu, nous pouvons en conclure que la précision géographique de l'algorithme est satisfaisante. Stanojevic et al. [72] fournissent un exemple de l'application de cette méthode.

2.2.2 Évaluation des intersections

Lorsqu'un randonneur entreprend une randonnée, il suit des segments, marchant le long de ces chemins jusqu'à atteindre une intersection. Ces intersections jouent un rôle crucial, servant de points pivots tout au long de la randonnée. En effet, c'est à ces endroits que les randonneurs prennent des décisions sur la direction à suivre. Il est donc essentiel que les algorithmes de cartographie puissent identifier correctement ces intersections. Nous accordons à l'évaluation de la détection des intersections une importance comparable à celle que nous avons attribuée aux segments.

Malheureusement, beaucoup d'études ont tendance à sous-estimer l'importance des intersections, mettant l'accent principalement sur les segments. Cependant, quelques recherches se sont penchées sur cette question, et voici les métriques qu'elles ont adoptées.

Le FScore est également utilisé pour l'évaluation des intersections. Cette évaluation se déroule de manière similaire à celle des segments : on calcule d'abord la précision et le rappel, puis on les combine en déterminant leur moyenne harmonique. Cependant, la distinction principale réside dans le fait que l'appariement des intersections entre la carte générée et la carte de référence est généralement plus simple. Pour réaliser cet appariement, on compare les positions géographiques des intersections. Si une intersection sur une carte est suffisamment proche de son homologue sur l'autre carte, elles sont alors considérées comme jumelées. La définition d'un seuil de correspondance S_{paire} est nécessaire. Des études telles que Zhang et al. [88], Mariescu et al. [56], Zhang et al. [89], et Tang et al. [75], ont utilisé le FScore pour évaluer leurs intersections. Guo et al. [31] ont mesuré le rappel de manière visuelle, tandis que Yang et al. [85] se sont concentrés uniquement sur la précision.

La précision en mètres est en tout point similaire à celle des segments. Il est à noter que les intersections générées et celles de référence n'ont jamais exactement la même position géographique. Il s'agit donc de mesurer cet écart et de faire une moyenne pour toutes les intersections. Une autre approche serait de réduire le seuil de correspondance du FScore précédent et d'observer si le score varie. Si le score ne change que légèrement avec un seuil de correspondance plus bas, cela indique que les intersections sont inférées avec précision. À notre connaissance, ces techniques ne sont pas encore établies dans l'état de l'art, mais sont discutées uniquement dans un de nos articles [70].

2.2.3 Autres aspects évaluables

Bien que la plupart des métriques de l'état de l'art se concentrent sur les segments et les intersections, certaines études ont proposé des métriques intéressantes liées à d'autres aspects. Par exemple, l'évaluation de la **complexité** des réseaux consiste à compter les segments et les intersections de la carte générée et à les comparer au nombre d'intersections et de segments de la carte de référence, comme le suggère Guo et al. [32].

Dans leur framework, Hashemi et al. [33] évaluent la **connectivité** de leur graphe en utilisant une matrice d'adjacence. Cette approche repose sur l'algorithme de Floyd pour le calcul du plus court chemin, afin d'obtenir une matrice indiquant le coût pour se déplacer d'un nœud à un autre dans le graphe, avec un poids uniforme de 1 attribué à chaque arête. L'exactitude de la topologie est ensuite déterminée par la comparaison des matrices de la vérité terrain et du graphe généré. La connectivité est également évaluée par Eftelioglu et al. [26] qui reprennent le principe de TOPO, mais en se concentrant uniquement sur les zones d'intersection, dans une méthode qu'ils ont nommée ITOPO.

2.2.4 Limites des métriques actuelles

Selon l'enquête réalisée par Chao [16], qui est la seule étude que nous avons trouvée se concentrant sur l'efficacité des métriques, l'évaluation quantitative des algorithmes d'inférence de carte est encore insuffisante pour plusieurs raisons. Premièrement, bien que les mesures actuelles aient été élaborées dans divers buts, aucune recherche n'a véritablement examiné les types spécifiques de problèmes de qualité des cartes qu'elles peuvent effectivement détecter. En conséquence, les métriques ont souvent été adoptées sans discernement dans des travaux antérieurs, sans compréhension claire de ce qu'elles évaluent exactement. Ensuite, certaines anomalies, telles que des erreurs dans la forme des segments ou des intersections mal placées, semblent avoir été négligées par une grande partie des études. Cela suggère que ces problèmes pourraient ne pas être repérés par les méthodes actuelles. De plus, les auteurs suggèrent que certaines métriques, comme celles basées sur des itinéraires, peuvent s'avérer peu informatives et peu pertinentes.




FIGURE 2.6 – Les différents types d'erreurs artificiellement générées. Cette Figure provient de l'article [16].

Afin d'adresser cette problématique, les auteurs introduisent une méthode expérimentale destinée à évaluer l'efficacité des mesures actuelles en matière de détection d'erreurs cartographiques. Elle se base sur un générateur de cartes artificielles, qui introduit volontairement des erreurs de différents types dans une carte de référence.

Il est alors possible de comparer les différentes métriques en les appliquant pour analyser la carte de référence altérée, en la comparant à la carte de référence originale. L'enjeu est de lier chaque métrique à un type d'erreur spécifique. Les erreurs évoquées dans l'étude sont listées ci-dessous, tandis que la Figure 2.6 illustre ces différents types d'erreurs :

1. **Erreur topologique** : Cette erreur est présente lorsqu'un segment est correctement placé mais ne se connecte pas à une intersection, se terminant ainsi à proximité de celle-ci.
2. **Erreur géographique** : Ces erreurs sont causées par des décalages aléatoires aux intersections. Les routes peuvent rester topologiquement connectées comme dans la carte originale, mais leur position géographique est légèrement décalée.
3. **Perte de segment** : Il s'agit de segments présents dans la carte originale mais absents dans la carte inférée. Par exemple, un segment important pourrait être omis de la carte résultante.
4. **Segment factice** : Des segments qui n'existent pas dans la carte originale sont ajoutés dans la carte inférée. En raison de données GPS bruitées, un nouveau segment peut apparaître entre deux points distants.
5. **Erreur de forme** : Ce type d'erreur concerne des segments qui présentent une forme en "zigzag" en raison de l'ajout de points supplémentaires. Un segment droit dans la réalité pourrait apparaître comme sinueux dans la carte inférée.
6. **Erreur de placement d'intersection** : Des intersections existantes sont scindées en deux points distincts. Une grande intersection pourrait être représentée par deux intersections distinctes et proches l'une de l'autre dans la carte inférée.

Les auteurs ont examiné trois métriques face à différents types d'erreurs, comprenant : la mise en correspondance suivie d'un FScore, l'échantillonnage de graphe TOPO, et la distance basée sur les itinéraires (voir section 2.2.1). La première métrique se révèle particulièrement efficace pour identifier la perte de segments et est sensible aux erreurs topologiques ainsi qu'aux segments factices. Cependant, elle est moins performante pour détecter les erreurs de forme ou les anomalies liées à la suppression ou au déplacement d'intersections. TOPO, quant à lui, excelle dans la détection des erreurs topologiques et est très fiable pour mesurer la perte de segments, tout en identifiant également, bien que de manière moins prononcée, les segments superflus et les erreurs d'intersection. Toutefois, il peut manquer certaines erreurs de forme. La métrique basée sur les itinéraires est particulièrement précise pour détecter les segments superflus et les erreurs associées aux intersections, en particulier les décalages. Bien qu'elle soit sensible aux problèmes de connectivité, elle a du mal à identifier la perte de segments.

Nos conclusions sur cette étude importante menée par Chao sont qu'aucune des métriques testées n'est en mesure de répondre pleinement au défi proposé. Il existe toujours au moins un type d'erreur qui n'est pas correctement identifié. En opposition à ce constat, bien que la sensibilité des métriques varie en fonction du type d'erreur, le fait qu'une métrique révèle systématiquement différents types d'erreurs

est problématique. Peu importe la métrique de l'état de l'art choisie pour évaluer son algorithme, un score moyen ne peut jamais être associé à une erreur précise, mais au mieux à un ensemble d'erreurs. Ce travail sera la base de notre réflexion et nous permettra de formuler systématiquement d'éventuelles réserves sur la signification de nos résultats. Actuellement, les scores obtenus ne doivent pas être considérés comme une limitation de l'algorithme, mais plutôt comme une voie vers une compréhension plus profonde des défis rencontrés. Dans cette thèse, nous n'avons pas eu l'opportunité d'approfondir ce sujet, mais nous estimons que nos observations actuelles constituent une base solide pour des recherches futures. Nous sommes certains que ces résultats pourraient ouvrir la voie à de nouvelles méthodologies d'évaluation et améliorations dans notre domaine.

2.2.5 La visualisation au secours de l'évaluation quantitative

Les outils de représentation 2D, devenus très performants de nos jours, facilitent grandement la visualisation des traces GPS dans l'espace. Cette forme de représentation est nettement plus accessible pour l'humain que de simples tableaux affichant les séries temporelles d'une trace GPS. De même, les résultats d'un algorithme d'inférence de carte, une fois importés dans un logiciel 2D, peuvent être facilement superposés à une carte de référence pour une comparaison visuelle directe. Il est important de noter que la majorité des études examinées incorporent une représentation visuelle des données ou des résultats. Cette représentation peut varier d'une simple illustration à un outil d'évaluation à part entière. Suite à nos recherches approfondies sur le sujet et à notre expérience personnelle, il apparaît que le recours systématique à la comparaison visuelle d'éléments pour compléter une analyse quantitative est une réponse directe aux limites inhérentes à la précision de cette dernière.

Lorsque la visualisation sert de complément à l'analyse quantitative, elle se compose généralement de représentations visuelles de la vérité terrain, des données utilisées et des performances des différents algorithmes comparés. Ainsi, le lecteur peut juxtaposer un résultat quantitatif avec son illustration graphique, enrichissant sa compréhension de la performance d'un algorithme et des problématiques rencontrées. Par exemple, dans les cas où le réseau généré est destiné à un usage routier ou pédestre, la visualisation de la carte permet une projection plus aisée sur le terrain, offrant une meilleure appréhension des enjeux liés à la fusion de traces GPS. Karagiorgou et al. [44] soutiennent qu'une image des résultats est un moyen rapide d'apprécier la qualité de ceux-ci. Zhou et al. [93] et Stanojevic et al. [72] sont deux autres exemples qui combinent une analyse visuelle avec des résultats quantitatifs.

Dans un contexte où l'analyse se concentre sur l'évaluation qualitative, la représentation visuelle devient un élément central de cette évaluation. Les confrontations directes entre différentes images offrent une perspective unique sur la qualité et la pertinence d'un algorithme ou d'une méthode. Par exemple, Mariescu et al. [56] utilisent l'approche visuelle pour souligner les similitudes ou divergences avec les images issues d'études antérieures, permettant ainsi de tirer des conclusions directement de cette comparaison graphique. De la même manière, Karagiorgou et al. [45] mettent l'accent sur l'approche visuelle pour démontrer que leur réseau généré est plus aligné avec OSM comparé à d'autres réseaux de l'état de l'art. Enfin, Cao et

al. [15] fondent intégralement leur évaluation sur une méthodologie visuelle, démontrant ainsi que, dans certains contextes de recherche, une représentation graphique peut être plus éloquente et révélatrice qu’une accumulation quantitative de données.




FIGURE 2.7 – Exemple de génération automatique d’un segment dangereux (en rouge). © OpenStreetMap contributors [58]

La visualisation peut révéler des anomalies ou des particularités qui pourraient rester inaperçues dans une analyse purement numérique, soulignant ainsi l’importance de combiner méthodes quantitatives et qualitatives pour une évaluation complète. La Figure 2.1, introduite au début de ce chapitre sur les méthodes d’évaluation, illustre un cas où une évaluation quantitative pourrait sous-estimer la qualité des segments. Supposons qu’une méthode de segmentation factice soit intégrée au protocole d’évaluation, les segments générés par un algorithme, tels qu’illustrés dans la Figure 2.7, n’affecteraient que faiblement le score global accordé par cette métrique. Ces segments pourraient donc passer inaperçus dans une évaluation strictement quantitative. Actuellement, aucune méthode recensée dans la littérature n’est capable de pondérer différemment des erreurs en fonction de la nature ou de la dangerosité des zones concernées.

2.3 Les jeux de données de l’état de l’art

2.3.1 Récapitulatif de la donnée existante

La sélection d’un jeu de données approprié reste un sujet de débat non résolu au sein de la communauté scientifique. Dans cette section, nous examinerons la composition des différents jeux de données, leurs domaines d’application, ainsi que les objectifs des recherches qui les utilisent.

TABLE 2.1 Exemples de jeux de données les populaires

Nom	Lien	Article original	Articles	#Traces	Moyen de collecte	Type de zone
Chicago	Lien	[13]	[56, 30, 89, 45]	889	navettes universitaires	Urbaine
Joensuu	Lien	[56]	[30, 32, 76]	109	coureur humain	Urbaine
Hashemi testbed	Lien	[33]	[93, 34, 54]	variable	variable	Urbaine
Athens_large	Lien	[3, 45]	[32]	511	bus scolaire	Urbaine
Athens_small	Lien	[3]	[32, 30]	129	bus scolaire	Urbaine
Berlin	Lien	[3]	[32, 45]	26831	taxis	Urbaine
Pékin	Lien	[87, 86]	[26, 28, 68]	10357	taxis	Urbaine

Chicago Le jeu de données de Chicago, présenté par Biagioni et al. [13], est l'un des plus populaires dans l'état de l'art. Il a été constitué sur une période de 7 mois grâce à des données collectées par 13 navettes universitaires desservant le campus de l'Université de l'Illinois à Chicago. Ces navettes empruntent plusieurs itinéraires réguliers avec de nombreux trajets quotidiens, deux itinéraires moins fréquents avec quelques trajets par jour, ainsi que des trajets utilisés de manière occasionnelle. Cette diversité de trajets offre un degré élevé de disparité de densité. De plus, les auteurs mentionnent que dans la zone de l'hôpital (soulignée par un rectangle rouge dans la Figure 2.8), des 'canyons urbains' se forment, où la réception GPS est particulièrement sujette aux erreurs, certaines traces montrant des écarts constants de plus de 100 mètres.




FIGURE 2.8 – Chicago : 7 mois de traces brutes. Les données présentent à la fois une grande disparité et un fort bruit GPS. Le rectangle rouge indique la "zone de l'hôpital". La Figure provient de l'article [13]

Joensuu Ce jeu de données (Figure 2.9a) est extrait d'une collection qui inclut les traces d'un utilisateur unique (Pasi) issues de la collection Mopsi, couvrant la période du 16 novembre 2014 au 25 avril 2015. Au total, cette collection comporte 102 itinéraires, mais seuls les 45 itinéraires situés dans le centre-ville de Joensuu, en Finlande, ont été sélectionnés. Les données ont été redimensionnées pour couvrir une zone carrée englobant la majorité du centre-ville. Joensuu se caractérise par un réseau de rues rectilignes dans son centre, tandis que les routes périphériques sont plus complexes et sinueuses, comprenant notamment des sentiers pédestres et cyclables. Les itinéraires à Joensuu ont été enregistrés pendant que l'utilisateur effectuait des séances de jogging, principalement le long des rues.

Hashemi testbed Les chercheurs ont collecté 33 jeux de données de traces GPS distincts, chacun ayant des caractéristiques spécifiques en termes de précision, de taux d'échantillonnage et de typologie du réseau. Les données sont principalement issues du projet Open Street Map (OSM) et du projet GeoLife. Pour pallier le

manque de traces concernant les réseaux piétonniers, les 9 derniers jeux de données ont été générés en utilisant l'application GPS Kit sur iPhone, en parcourant à pied les zones concernées. Cette collecte vise à créer une diversité en termes de complexité, de densité des réseaux, de taux d'échantillonnage et de précision, afin de fournir un cadre de test robuste pour les algorithmes de construction de réseau. Ces données sont détaillées dans le Tableau 2.2. Un exemple visuel est visible sur la Figure 2.9b

TABLE 2.2 Les données GPS du testbed présenté par Hashemi et al. [33]

GPS	Nombre de points	Taux d'échantillonnage moyen (s)	Erreur GPS moyenne (m)	Écart-type de l'erreur GPS (m)	Longueur (m)
GPS1	4833	9	7.39	5.30	348,528
GPS2	4833	9	3.70	2.65	348,528
GPS3	2432	18	8.06	5.35	348,528
GPS4	2432	18	4.03	2.68	348,528
GPS5	1170	40	8.37	5.39	348,528
GPS6	1170	40	4.19	2.70	348,528
GPS7	7745	9	5.10	4.01	367,143
GPS8	7745	9	2.55	2.01	367,143
GPS9	3953	17	5.56	4.53	367,143
GPS10	3953	17	2.78	2.27	367,143
GPS11	1866	38	5.96	4.97	367,143
GPS12	1866	38	2.98	2.49	367,143
GPS13	4693	2	5.81	5.96	60,363
GPS14	4693	2	2.91	2.98	60,363
GPS15	1030	10	5.97	5.95	60,363
GPS16	1030	10	2.99	2.98	60,363
GPS17	358	30	6.05	6.14	60,363
GPS18	358	30	3.03	3.07	60,363
GPS19	24,314	2	4.57	3.85	689,204
GPS20	24,314	2	2.29	1.93	689,204
GPS21	5789	10	4.56	3.85	689,204
GPS22	5789	10	2.28	1.93	689,204
GPS23	2016	30	4.52	3.79	689,204
GPS24	2016	30	2.26	1.90	689,204
GPS25	9862	5	4.81	3.96	53,798
GPS26	9862	5	2.41	1.98	53,798
GPS27	9862	5	1.00	0.82	53,798
GPS28	4275	12	4.77	3.95	53,798
GPS29	4275	12	2.39	1.98	53,798
GPS30	4275	12	1.00	0.83	53,798
GPS31	1620	33	4.71	3.97	53,798
GPS32	1620	33	2.36	1.99	53,798
GPS33	1620	33	1.00	0.84	53,798

Pékin Cet ensemble de données (Figure 2.9c) contient les trajectoires GPS de 10 357 taxis pendant la période du 2 au 8 février 2008 au sein de Pékin. Le nombre total de points dans cet ensemble de données est d'environ 15 millions et la distance totale de les trajectoires atteignent 9 millions de kilomètres. L'intervalle d'échantillonnage moyen est d'environ 177 secondes avec une distance d'environ 623 mètres.

Athens_small L'ensemble de données Athens_small (Figure 2.9d) comprend 129 traces avec une longueur totale de 443 km (moyenne : 3,82 km et écart-type : 1,45 km) obtenues à partir de bus scolaires couvrant une zone de 2,6 km × 6 km ; les traces comptent entre 13 à 47 positions, avec un taux d'échantillonnage de 20s à 30s (moyenne : 34,07s et écart-type : 31,92s) et une vitesse moyenne de 19,55 km/h. Cette description provient du l'article [4] de Ahmed et Al.

Athens_large L'ensemble de données Athens_large (Figure 2.9e) comprend 511 traces avec une longueur totale de 6 781 km (moyenne : 13,27 km et écart-type : 10,79 km) obtenues à partir de bus scolaires couvrant une zone de 12 km × 14 km ; les traces comptent entre 32 à 80 positions, avec un taux d'échantillonnage de 20s à 30s (moyenne : 30,14s et écart-type : 24,77s) et une vitesse moyenne de 20,16 km/h. Cette description provient du l'article [4] de Ahmed et Al.

Berlin L'ensemble de données de Berlin (Figure 2.9f) comprend 26 831 traces avec une longueur totale de 41 116 km (moyenne : 1,53 km et écart-type : 634,51 m) obtenues à partir d'une flotte de taxis couvrant une zone de 6 km × 6 km ; les traces comptent entre 22 à 58 positions, avec un taux d'échantillonnage de 15s à 127s (moyenne : 41,98s et écart-type : 38,70s) et une vitesse moyenne de 35,23 km/h. Cette description provient du l'article [4] de Ahmed et Al.

Suite à notre analyse des jeux de données les plus couramment utilisés dans la fusion de traces GPS, une conclusion importante émerge : ces données ont principalement été acquises dans des contextes urbains. Plus précisément, elles se concentrent sur des trajets effectués par des véhicules, dans des conditions relativement uniformes où les variations de comportement de conduite et de trajectoire entre différents conducteurs sont minimales. Dans les sections suivantes, nous explorerons l'intégration de nouvelles données à notre étude, qui se distinguent nettement des précédentes par leur contexte d'application. Notre focus se portera sur des données représentatives des randonneurs dans des environnements pédestres. Cette orientation marque un tournant significatif, car elle introduit une complexité supplémentaire inhérente à notre sujet d'étude. Le Tableau 2.1 renseigne des liens pour télécharger chacun des différents jeux de données visible sur la Figure 2.9.

2.3.2 Exemples d'articles ayant un jeu de données propre à leurs besoins

Il est fréquent que les bases de données couramment utilisées dans la communauté scientifique, mentionnées dans la section précédente, ne répondent pas aux spécificités des domaines d'étude de certaines recherches approfondies. Plusieurs facteurs, comme la nécessité d'utiliser des données issues exclusivement de dispositifs mobiles, ou l'étude centrée sur des environnements spécifiques tels que les réseaux routiers plutôt que les milieux urbains, contraignent les chercheurs à élaborer leurs propres jeux de données. Ces données, adaptées aux contraintes spécifiques de leur champ d'investigation, sont souvent non partagées publiquement et restent en marge des bases de données communautaires.

Arman et al.[8, 9] visent à présenter un algorithme pour identifier les voies sur des segments d'autoroute en utilisant des trajectoires GPS collectées par des téléphones mobiles. Leurs tests ont été effectués sur les autoroutes E313 et R1 entre Wommelgem et Antwerpen-Zuid dans les deux sens de circulation près d'Anvers, en Belgique. Les données ont été collectées via l'application smartphone Touring Mobilis de Be-Mobile, disponible sur iOS et Android.

Moura Morceli et al. [22] proposent une méthode pour extraire les lignes centrales des routes à partir de données GNSS denses collectées avec des dispositifs GNSS à faible coût, comme des smartphones. Ils ont utilisé 490 trajectoires GNSS collectées

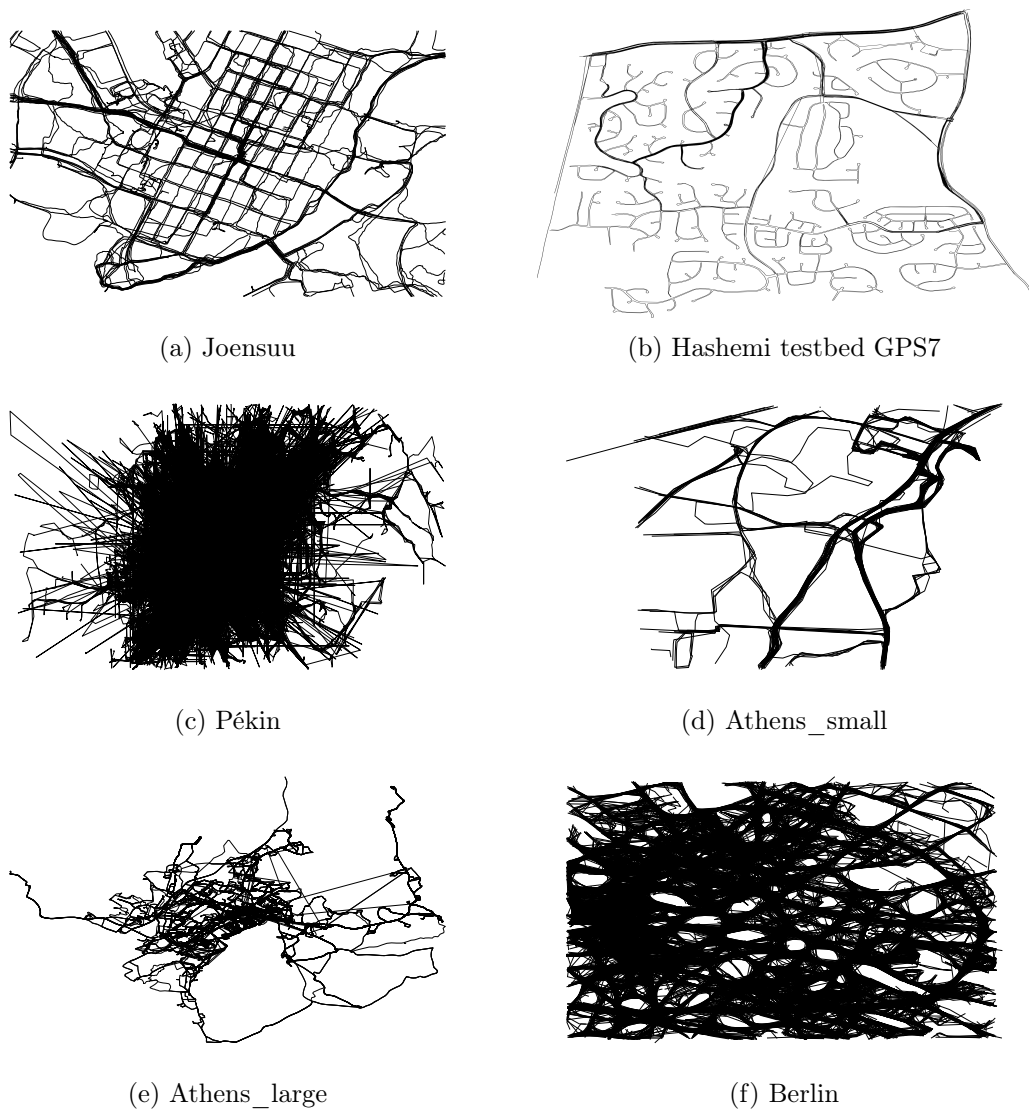


FIGURE 2.9 – Jeux de données Les plus populaires de la communauté scientifique


via les applications Ultra GPS Logger et GPS Logger entre décembre 2018 et mars 2020 sur 70 km de routes, avec des subdivisions en zones urbaines et rurales pour évaluer leur méthode.

Enfin, Yang et al. [85] présentent une méthode de génération de réseau piétonnier testée avec des données GPS collectées dans les villes de Wuhan et Pékin. Les données de Wuhan ont été recueillies sur un mois en 2016 par environ 83 participants utilisant les GPS de leurs téléphones mobiles, tandis que les données de Pékin provenaient du dataset public GeoLife, sélectionnées selon le mode de transport. Le taux d'échantillonnage maximal était d'environ 10 secondes, avec une vitesse de marche médiane d'environ 1 m/s

2.3.3 Les données pédestres en zones naturelles

Dans les études précédentes, il a été constaté que la communauté scientifique travaillant sur la fusion de traces GPS ne partage pas un objectif commun clairement défini, et les domaines d'application sont très divers. Une analyse des jeux de données les plus reconnus, comme présentés dans le Tableau 2.1, révèle une sous-représentation significative des traces pédestres ; la majorité des données disponibles proviennent de véhicules, divergeant ainsi de notre domaine de recherche axé sur le déplacement pédestre.

De plus, il apparaît que peu d'études se sont spécifiquement concentrées sur cette thématique. Dans ce contexte, l'étude de Yang et al. (2020) [85] est notable pour son accent sur le manque de données concernant les piétons, par rapport à celles relatives aux voies réservées aux véhicules motorisés. Cette recherche souligne l'opportunité de développer des études sur des déplacements à pied basés sur des données géographique à jour.



(a) Extraction OSM - Zone montagneuse de Ribeauvillé (Alsace)



(b) Extraction OSM - Zone urbaine de Chicago

FIGURE 2.10 – Exemple d'extraction OSM mettant en avant les différences structurales entre des données urbaine et un jeu de données acquises en zone montagneuse. © OpenStreetMap contributors [58]

Jusqu'à présent, aucune recherche ne s'est spécifiquement concentrée sur l'analyse des données de randonnée, qui implique l'exploration de zones naturelles. La majorité des études se focalisent sur les environnements urbains, comme le montre l'utilisation fréquente de l'ensemble de données de Chicago, caractérisé par sa structure principalement rectiligne (voir Figure 2.8). Cette orientation vers les zones urbaines crée une lacune notable dans l'état actuel de la recherche, car le comportement des individus en randonnée en terrain montagneux diffère grandement de celui observé en milieu urbain.

Dans les zones naturelles, des facteurs tels que la difficulté technique, les sentiers vertigineux, les obstacles naturels ou les points de vue influencent significativement la formation de la trace GPS. De plus, les spécificités du terrain, y compris les configurations de chemin comme les virages serrés, illustrés dans la Figure 2.10, doivent être prises en compte. L'altitude est aussi un facteur clé, affectant la vitesse de déplacement et la fréquence et la durée des pauses, entraînant des variations dans l'espacement des points GPS, différentes de celles observées dans les environnements urbains plats. Il est plausible qu'un algorithme conçu pour les données urbaines ait une performance moindre avec des données de zones naturelles. Cette limitation est

particulièrement critique pour les algorithmes d'apprentissage profond, où l'absence de caractéristiques ou de comportements spécifiques aux zones naturelles durant la phase d'apprentissage pourrait affecter la capacité du réseau neuronal à généraliser efficacement sur ces données.

2.4 Structure de notre protocole d'évaluation

Dans les sections précédentes de ce chapitre, dédiées à l'évaluation d'une carte générée, nous avons synthétisé les diverses approches adoptées par la communauté scientifique pour créer leurs protocoles d'évaluation. Par « protocole », nous faisons référence au contexte global de l'évaluation, abordant des questions telles que : Quelles métriques sont utilisées par les auteurs ? Qu'évaluent ces métriques ? Quels éléments sont comparés et à quoi le sont-ils ? Nos recherches ont mis en évidence une grande diversité dans les réponses à ces questions, soulignant ainsi la variété des méthodes existantes. Chaque étude, se focalisant sur un domaine spécifique, a mené à une spécialisation des systèmes d'évaluation, rendant difficile l'établissement d'un cadre de tests et d'évaluation unifié.

Dans cette section, nous décrivons les composantes de notre protocole d'évaluation choisi, qui s'aligne sur les approches des études les plus reconnues, tout en intégrant des spécificités propres à notre nouveau domaine d'étude : l'analyse des traces GPS collectées par un randonneur utilisant son téléphone mobile en France. Pour détailler notre environnement d'étude, nous exposerons d'abord les métriques que nous avons choisies d'utiliser, puis nous présenterons les jeux de données sélectionnés et la carte de référence. Il est important de noter qu'au cours des trois années de cette thèse, tant les techniques que notre approche ont évolué. Nous présenterons donc plusieurs conceptions que nous avons mises en œuvre, en précisant le contexte d'utilisation pour chacune.

2.4.1 Les métriques

2.4.1.1 Évaluation des segments (FTOP)

Au cours de la première phase de notre recherche doctorale, nous avons développé une technologie qui sera détaillée dans le Chapitre 3. Cette technologie relève du domaine des technologies d'abstraction de route, un champ principalement basé sur une méthode d'évaluation des segments qui utilise l'association de paires et le calcul du FScore. Lors de la création de cette technologie, l'écosystème d'évaluation proposé par Hashemi dans son étude de 2017 [33] était relativement récent, avec peu de retours disponibles.

Néanmoins, nous avons choisi de soutenir cette initiative, anticipant son potentiel bénéfique pour la communauté scientifique en favorisant une standardisation des méthodes d'évaluation. Pour notre étude, nous avons adopté leur méthode d'évaluation des segments, qui consiste à calculer la distance moyenne entre un segment évalué et tous les segments de la vérité terrain, puis à sélectionner le segment le plus proche. Cette approche garantit que chaque segment évalué trouvera un appariement, tout en permettant que certains segments de la vérité terrain ne soient pas appariés. De plus, elle stipule qu'un segment de la vérité terrain ne peut être apparié

qu'une seule fois. Les auteurs suggèrent de comparer les points structurels des segments générés avec les lignes reliant les points structurels des segments de la vérité terrain, permettant ainsi de contourner les problèmes liés à la fréquence d'échantillonnage hétérogène de la carte de référence. Un exemple de calcul de similarité entre deux segments est illustré dans la Figure 2.11.





FIGURE 2.11 – Exemple de calcul de similarité (en mètres) entre un segment généré et un segment issu de la vérité terrain. La similarité est de 8.5m en moyenne.


Suite à la première phase de cette thèse, nous avons adopté une nouvelle approche, nous écartant des méthodes d'abstraction de route pour nous orienter vers les techniques émergentes de l'état de l'art, qui intègrent l'imagerie et les réseaux de neurones. Dans ce domaine, la métrique d'évaluation **TOPO** semble être largement adoptée, comme décrit dans la section 2.2.1. Dans la version originale proposée par Biagioni et al. [13], la méthode consiste à définir une position aléatoire dans le graphe généré au format vectoriel, puis à explorer les segments dans un rayon spécifié autour de cette position. Sur la carte de vérité terrain, la méthode place sur ces segments, et dans cette zone, des "trous" à intervalles réguliers, et sur les segments du graphe généré, des "billes". Le score est ensuite calculé en analysant le nombre de billes qui correspondent aux trous pour chaque itération de l'algorithme.

Nous postulons que la méthode actuelle de l'état de l'art est excessivement sensible aux indicateurs de connectivité des segments, comme illustré dans la Figure 2.12. Une déconnexion, même mineure, peut complètement annuler la détection d'un segment pertinent, comme le montre le segment le plus à gauche dans la Figure 2.12b. En conséquence, le score pourrait être affecté négativement de manière injustifiée. Il est important de noter que la méthode itérative avec origine aléatoire est la seule approche documentée dans la littérature pour l'évaluation au format vectoriel. Afin de pallier ces limitations et d'augmenter la spécificité de la métrique **TOPO** par rapport à la qualité des segments, nous proposons d'adapter cette méthode au format raster, exploitant ainsi le format naturel de sortie d'un réseau de neurones. En comparant deux images géoréférencées, cette adaptation que nous nommerons **FTOP** permet de minimiser l'impact des déconnexions et d'éliminer l'aspect aléatoire et répétitif de l'évaluation.


La Figure 2.12c illustre l'efficacité de cette méthode en permettant l'évaluation d'un segment déconnecté. Dans notre version, les "trous" et les "billes" sont repré-



(a) Exemple à évaluer



(b) Résultat de la métrique TOPO au format vectoriel. Les points noirs représentent les origines de l'exploration de l'algorithme.



(c) Résultat de la métrique FTOP au format raster. Cette implémentation est celle choisie pour nos expérimentations.

FIGURE 2.12 – Comparaison des différentes implémentations possible de la métrique (TOPO ou FTOP) sur un exemple donné.

sentés par des pixels, et une correspondance est établie si une "bille" se trouve à une distance maximale prédéfinie d'un "trou", mesurée en pixels. Reste à déterminer la dimension d'un pixel et donc sa couverture géographique, ainsi que le nombre de pixels voisins à prendre en compte.

$$\text{Précision} = \frac{\text{billes correspondantes}}{\text{billes correspondantes} + \text{billes superflues}}$$

$$\text{Rappel} = \frac{\text{trous correspondants}}{\text{trous correspondants} + \text{trous manquants}}$$

$$\text{FScore} = \frac{2 \times \text{Précision} \times \text{Rappel}}{\text{Précision} + \text{Rappel}}$$

L'équation ci-dessus définit trois métriques clés pour évaluer la performance de notre adaptation. La "Précision" mesure la proportion de "billes" identifiées qui

correspondent réellement à des "trous". Elle évalue la justesse des prédictions de notre modèle en termes de détection de segments. Le "Rappel", quant à lui, estime la fraction des "trous" présents qui ont été correctement identifiés par notre modèle. Enfin, le "FScore" est une moyenne harmonique des deux métriques précédentes, offrant une évaluation globale de la pertinence et de la complétude de la détection. La définition de la distance maximale, en pixels, entre une "bille" et un "trou" est cruciale, car elle influence directement les valeurs de la précision et du rappel.

En introduisant cette variante de TOPO utilisant le format raster, nous n'avons aucun point de repère bibliographique pour anticiper cette valeur de distance maximale. Nous avons donc dû la définir de manière arbitraire. Basés sur les résultats de nos manipulations, nous avons estimé qu'examiner le voisinage direct d'une bille suffisait pour obtenir un score fiable. Aller plus loin que les 8 pixels autour avait pour impact d'associer des bouts de segments à des segments de la vérité terrain qui ne correspondaient pas. Cette approche nous a permis de maintenir un équilibre entre la précision et le rappel, tout en assurant une détection de segments cohérente et pertinente.

2.4.1.2 Évaluation des intersections (FINT)

L'évaluation des intersections demeure la seule composante de notre protocole d'évaluation qui n'a subi aucune évolution, principalement en raison de sa structure simplifiée, puisqu'une intersection n'est constituée que d'un seul point. La stratégie adoptée vise à appairer les intersections annotées sur la carte de référence avec celles présentes sur la carte générée, en se basant sur un seuil de distance défini, comme détaillé dans la section 2.2.2. Suite à cette phase d'appariement, nous calculons le **FScore (FINT)** afin de quantifier la qualité des intersections obtenues.

Dans notre étude préliminaire [70], nous avons étendu cette analyse en explorant l'influence du seuil de distance sur la valeur du FScore, une démarche qui nous a permis de définir une nouvelle métrique mesurant l'écart entre les intersections calculées et la réalité terrain, que nous avons dénommée **Imprécision**, pour éviter toute confusion avec la composante "précision" du FScore. Dans nos travaux qui emploient des techniques d'apprentissage profond, nous avons décidé de ne pas utiliser la métrique d'imprécision, afin d'éviter une surcharge d'informations lors de la présentation des résultats. Dans nos évaluations, nous nous assurons qu'une intersection calculée puisse être appariée à une intersection de la vérité terrain (comme illustré dans la Figure 2.13). Si plusieurs intersections calculées peuvent être associées à une seule intersection réelle, nous ne retenons que la plus proche pour maintenir l'intégrité du FScore. Cette approche diffère de celle adoptée dans certaines études de l'état de l'art.

2.4.1.3 Évaluation de la connectivité (FITO)

L'évaluation des intersections ainsi que des segments peut offrir une estimation de la qualité générale du graphe généré. Cependant, nous pensons qu'il manque un élément important dans cette évaluation qui est la connectivité. L'objectif principal de la métrique de connectivité est de déterminer si les segments détectés sont interconnectés de manière similaire à ceux de la carte de vérité terrain.




FIGURE 2.13 – Exemple d’un appariement, 4 intersections seraient suffisamment proches mais seule la plus proche est sectionnée.

Bien qu’il existe une forte corrélation entre cette métrique et celle de détection des intersections, car une intersection détectée implique qu’au moins trois segments sont correctement connectés, certaines situations nécessitent une évaluation plus précise. Par exemple, dans des scénarios où quatre segments ou plus devraient être connectés en un seul point d’intersection, la métrique de qualité des intersections peut s’avérer insuffisante. En effet, une intersection peut être détectée même si tous les segments ne sont pas correctement connectés. Compte tenu de la fréquence des cas où quatre segments ou plus convergent vers une intersection, l’élaboration d’une métrique plus adaptée à l’évaluation de la connectivité est essentielle.




FIGURE 2.14 – Exemple d’utilisation de la métrique FITO. Seuls les pixels contenus dans le cercle rouge seront considérés dans le calcul du FScore.

Les métriques spécifiquement dédiées à la connectivité sont peu fréquentes dans l’état de l’art. La méthode proposée par Hashemi et al. [33] a l’inconvénient de ne pas être efficace si le graphe n’est pas totalement connecté. En d’autres termes, si un seul segment est inféré sans être connecté à un autre, le score global de la connectivité du graphe généré serait de zéro. Eftelioglu et al. [26] ont proposé une solution que nous avons intégrée dans notre protocole dès sa publication en 2022.

Cette approche consiste à reprendre la métrique FTOP, utilisée pour l’évaluation des segments, et à l’appliquer spécifiquement aux intersections. Nous utilisons ainsi

les intersections de la carte de vérité comme référence et appliquons la méthode FTOP dans un certain rayon autour de ces points. En examinant la qualité des segments au niveau des intersections, nous obtenons une indication fiable sur la qualité de la connectivité du graphe. La Figure 2.14 illustre le concept de cette nouvelle métrique, nommée **ITOP** par ses auteurs. Elle se base sur le même exemple présenté pour justifier notre choix de la métrique FTOP pour l'évaluation des segments. Dans cet exemple, visible sur la Figure 2.12a, un segment déconnecté entraînera un ensemble de "trous manquants", réduisant ainsi la valeur du FScore.

2.4.1.4 La place de l'interprétation visuelle dans notre protocole d'évaluation

L'importance de l'évaluation visuelle est cruciale dans notre étude, notamment en raison de la difficulté à effectuer une réévaluation quantitative précise pour chaque indicateur de qualité identifié sur un graphe. Les métriques actuelles, conçues pour évaluer la qualité d'une carte selon différents critères, sont difficiles à isoler, rendant complexe l'attribution d'une métrique unique et précise à un indicateur spécifique. Par conséquent, l'évaluation visuelle devient un outil indispensable pour identifier et expliquer les raisons d'un score bas attribué par une métrique 2.4.1 à deux indicateurs 2.1.1 ou plus.

La section 2.2.5 montre que l'approche visuelle est également bénéfique pour l'analyse de nouveaux indicateurs, qui ne peuvent actuellement pas être calculés, comme la détection de segments dangereux par exemple. Bien que nous reconnaissons l'importance de cette dimension dans l'évaluation globale, elle ne sera pas examinée en profondeur dans nos travaux, car notre objectif est de nous aligner sur les normes actuelles concernant les indicateurs évalués sur une carte générée dans la littérature afin de pouvoir nous comparer aux approches existantes.

2.4.2 Les jeux de données

2.4.2.1 Données pour l'évaluation de la fusion par application multiple de grilles

À l'origine, l'objectif était d'acquérir de l'expérience en développant une technique de fusion de traces GPS alignée sur les méthodes de l'état de l'art, tout en n'ayant pas encore accès à la base de données Visorando. Pour la première technique de fusion par grille, nous avons donc travaillé avec le jeu de données le plus répandu, à savoir celui de *Chicago* (voir 2.3.1).

Dans le but d'évaluer la capacité de notre algorithme à gérer des traces d'entrée de qualité variable, nous avons choisi d'utiliser en plus les données du testbed d'Hashemi [33] qui contiennent des traces GPS enregistrées dans la ville de Cary en Caroline du Nord aux États-Unis. Certains des jeux de données de ce testbed comprennent des autoroutes à plusieurs voies, que nous avons exclues de notre évaluation car elles ne sont pas comparables à des traces de randonnée. Nous avons conservé tous les ensembles de données liés à la vérité terrain NET2, aboutissant à un total de six jeux de données présentant différents niveaux de précision. Nous représentons graphiquement la dégradation de la qualité des traces (voir Tableau 2.2) à l'aide de la Figure 2.15.

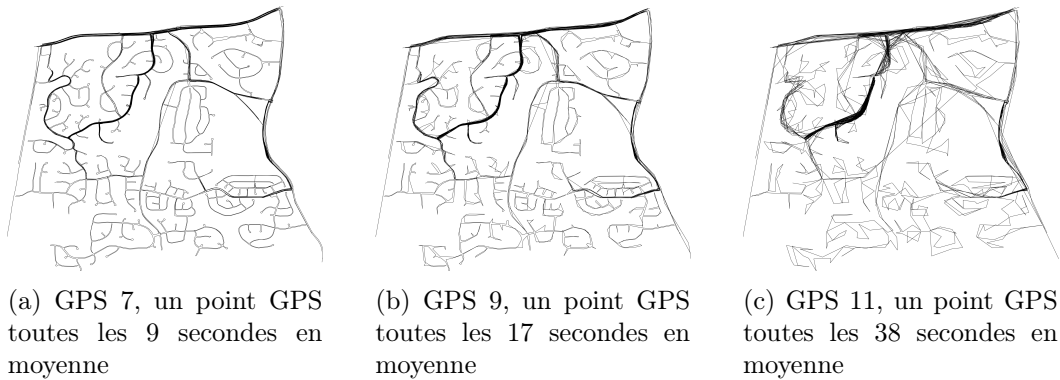


FIGURE 2.15 – Présentation visuelle des jeux de données sélectionnés parmi le test-bed de Mahdi Hashemi

Enfin, nous avons introduit un nouveau jeu de données construit par nos soins, nommé *Blaesheim*. Ce jeu de données vise à se rapprocher des conditions d’une randonnée, tout en conservant la possibilité de construire facilement la vérité terrain associée, la zone d’étude étant bien connue et proche de notre lieu de travail. Il se compose de 39 traces concentrées autour d’un village français. Les traces, toutes connectées, ont été enregistrées avec une montre Suunto Ambit2 (SiRF star IV en 1m/3ft). La majorité des traces présente une fréquence d’une seconde entre les points, tandis que les autres possèdent une fréquence variable, mais toujours inférieure à deux minutes.




FIGURE 2.16 – Jeu de données *Blaesheim*

2.4.2.2 Données pour l’évaluation des approches par apprentissage profond

Lors de la seconde partie la thèse, nous avons développé une nouvelle approche basée sur l’apprentissage profond. Notre modèle a été spécifiquement entraîné sur un ensemble de données exclusif fourni par Visorando. Ce jeu de données, détaillé dans le Tableau 2.3 et illustré dans la Figure 2.17, comprend des dizaines de milliers de traces GPS non filtrées, recueillies par des utilisateurs lors de diverses activités de plein air. L’introduction de nouveaux jeux de données vise à aligner nos expériences sur les conditions réelles et diversifiées rencontrées par l’entreprise.

Les données initiales, telles que celles issues de Chicago, bien qu’utilisées fréquemment, présentaient des limites, notamment en raison de leur collecte majori-

tairement auprès de taxis, ce qui manquait de diversité pour représenter fidèlement les terrains variés et les conditions d'enregistrement que nos applications nécessitent. Notre sélection de jeux de données enrichie intègre des environnements variés, y compris les montagnes des Vosges et la plaine d'Alsace. Ces terrains montagneux offrent un contraste avec les données urbaines structurées comme celles de Chicago, facilitant une évaluation plus précise et une adaptation de notre algorithme aux différents scénarios d'utilisation.

Les traces GPS utilisées dans cette étude, enregistrées par les utilisateurs de Visorando sur leurs appareils personnels, présentent un niveau de bruit et de variabilité représentatif des comportements d'utilisation divers et des conditions d'enregistrement. À titre d'exemple, le jeu de données de Blaesheim, situé à proximité d'une autoroute, se caractérise par des vitesses moyennes élevées, illustrant les défis supplémentaires inhérents à ces variations.

TABLE 2.3 Description de tous les ensembles de données utilisés dans les expériences avec la densité de trace ajoutée

Jeu de données	Nombre de traces	Distance moyenne (km)	Vitesse moyenne (m/s)	Boîte englobante (lat/lon)	Terrain	Densité de trace (#traces/km ²)
Labaroche	292	33.530	1.512	48.084–48.118, 7.183–7.245	montagne	18.24
Hunawilr	183	32.022	1.547	48.158–48.188, 7.282–7.326	vignoble	15.92
Ribeauville	2519	36.929	1.764	48.180–48.219, 7.250–7.319	vignoble	62.97
Lintthal	3509	45.217	2.184	47.939–48.014, 7.059–7.204	montagne	49.31
Blaesheim_Visorando	137	59.562	21.138	48.488–48.525, 7.577–7.647	plaine	11.13
Haguenau	1676	53.723	3.337	48.777–48.865, 7.696–7.886	plaine	37.45

2.4.3 Construction des carte de référence

Dans la mise en œuvre de notre méthode de clustering basée sur une approche par grille, il était impératif de garantir une reproductibilité fidèle aux conditions expérimentales établies dans l'état de l'art. Cette rigueur était essentielle pour permettre une évaluation comparative robuste et positionner notre travail par rapport aux études antérieures.

Pour le dataset *Chicago*, nous avons sélectionné OpenStreetMap (OSM) comme référentiel cartographique, en accord avec les standards méthodologiques largement adoptés dans les recherches précédentes sur ce corpus. De manière similaire, pour les jeux de données de Mehdi Hashemi, nous avons choisi une carte de référence basée sur une extraction OSM, conformément aux pratiques courantes dans les travaux existants.

Cependant, pour le jeu de données *Blaesheim* et d'autres associés au domaine de Visorando, nous avons dû relever des défis méthodologiques uniques. En l'absence de benchmarks établis pour ces ensembles de données, la création de cartes de référence ex nihilo était nécessaire. L'annotation manuelle a été retenue comme le protocole le plus rigoureux, permettant une saisie complète des spécificités topographiques, y compris des chemins non répertoriés par des référentiels conventionnels comme OSM. Cette approche assure une représentation cartographique fidèle aux réalités empiriques du terrain.

En conclusion, notre démarche scientifique pour le clustering par grille s'est alignée avec précision sur les protocoles méthodologiques de l'état de l'art, assurant une cohérence expérimentale et facilitant la comparaison de nos résultats. Toute-

fois, pour la partie traitant des données Visorando de notre recherche, l'originalité des jeux de données a nécessité des adaptations méthodologiques, notamment la création de nouvelles cartes de référence. Bien que cela ait représenté un investissement significatif, cette démarche était indispensable pour la robustesse et la validité de notre étude. Le processus de génération de données synthétiques, crucial pour alimenter notre architecture neuronale, sera détaillé et discuté dans le Chapitre 4.

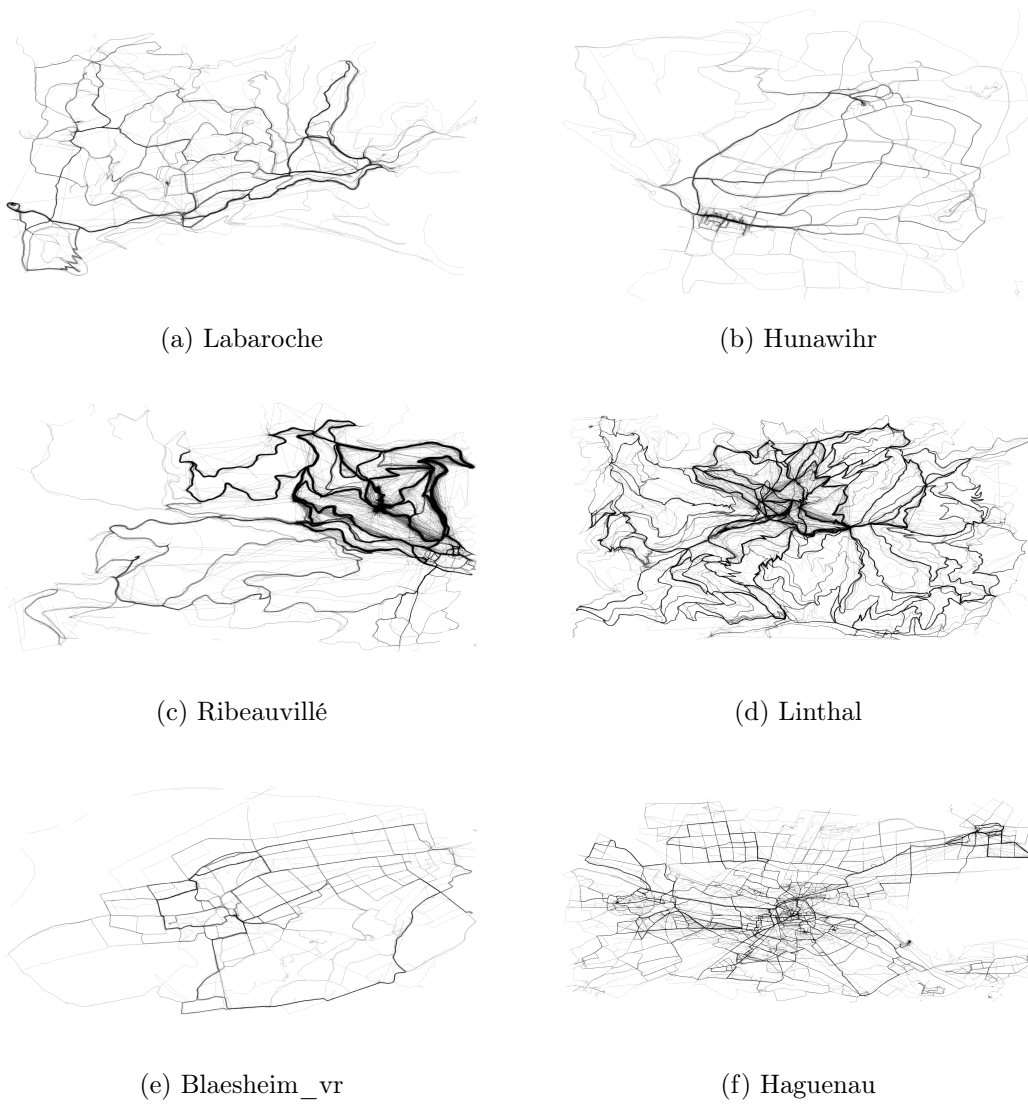


FIGURE 2.17 – Jeux de données extraits de la base de données de Visorando utilisés pour l'évaluation des méthodes par apprentissage profond

Chapitre 3

Fusion de traces GPS par application multiple de grilles

Introduction

La thèse se divise en deux axes principaux. La première partie se concentre sur le traitement des données GPS et le développement d'une méthode innovante pour la fusion des traces en utilisant des techniques de clustering. Cette phase initiale était essentielle pour établir les bases de la seconde partie de la recherche. Le Chapitre 4, quant à lui, est dédié spécifiquement à l'exploitation des données de Visorando, offrant une contribution significative dans le domaine du deep learning. Pour contextualiser, ce travail s'inscrit dans la continuité d'un projet débuté par un groupe de stagiaires au sein de la même unité de recherche. Notre rôle a consisté à finaliser ce travail préliminaire et le compléter en modifiant l'approche proposée, puis à le valider par un ensemble d'expériences sur un jeu de données réelles.

Concernant la première partie, nous commencerons par un rappel du contexte global, suivi d'une présentation détaillée de la méthode développée. Cette présentation abordera les étapes clés, y compris le prétraitement des données, les techniques de clustering, et la segmentation. Nous justifierons les innovations apportées et discuterons de la paramétrisation optimale de la méthode. Suite à la présentation de la méthode, une évaluation rigoureuse sera effectuée. Comme exposé dans le chapitre correspondant, cette évaluation vise à mesurer l'efficacité, la robustesse et la pertinence de la méthode dans le contexte des données GPS de l'état de l'art, avec une extension aux données de Visorando.

3.1 Contexte

Avant de débiter notre thèse, nous avons mené un projet de quatre mois sous la supervision de Cédric Wemmert, qui est l'actuel directeur de cette thèse, et en collaboration avec Visorando. L'objectif de ce projet était d'explorer le potentiel des données GPS, en reprenant les travaux préliminaires de Ilias Rmouque et Jonathan Jadlo. Ces derniers avaient esquissé une méthode de fusion de traces GPS à l'aide d'une grille lors de leurs études de Master. Lorsque nous avons repris ces travaux,

un prototype de code avait été développé, permettant la fusion des traces via une grille. Cependant, le processus était incomplet, particulièrement en ce qui concerne la phase de post-traitement, rendant les résultats préliminaires difficiles à évaluer.

Malgré ces limites initiales, nous avons rapidement reconnu le potentiel significatif de cette méthode. Ses performances semblaient prometteuses, avec la possibilité de rivaliser, voire surpasser, les approches existantes dans l'état de l'art. Sur cette base, nous avons décidé de consacrer le début de cette thèse à l'exploration approfondie et à l'amélioration de cette technique.

Dans ce chapitre, nous reviendrons d'abord sur les travaux initiaux qui ont posé les fondations de cette approche de fusion. Nous approfondirons l'état de l'art des méthodes de fusion de traces GPS à l'aide de grilles. Puis, nous décrirons les améliorations significatives que nous avons apportées, transformant ainsi une méthode embryonnaire en une solution robuste et compétitive.

Cette méthode et ses résultats comparés aux approches de l'état de l'art constituent notre première contribution et ont été présentés lors de la conférence ORASIS 2023. De plus, au moment de la rédaction de ce manuscrit, un article plus complet est en cours d'examen pour publication dans le journal international "ACM Transactions on Spatial Algorithms and Systems".

3.1.1 L'utilisation de grilles avec les données GPS

L'utilisation d'une grille pour fusionner des données GPS a été proposée par Radu Marescu-Istodor et Pasi Franti [55] en 2017. Leur étude a étendu l'application des grilles pour calculer des mesures de similarité entre les trajets GPS et réaliser des recherches basées sur la similarité dans les bases de données de trajets. Ils ont utilisé le système de référence militaire (Military Grid Reference System - MGRS), qui fournit une taille de cellule constante sur toute la surface de la Terre. La conversion des coordonnées GPS en MGRS et la représentation des trajets sous forme d'ensembles de cellules de grille sont discutées, incluant la gestion des lacunes dans la représentation et l'importance de la dilatation pour gérer les points proches. L'article présente des algorithmes pour ces processus et démontre l'efficacité et la précision de leur approche dans des scénarios réels, contribuant ainsi significativement au domaine de l'analyse et de la récupération des trajectoires GPS.

Dans des travaux ultérieurs [56], les mêmes auteurs ont proposé une approche où les grilles jouent un rôle central dans le processus de fusion de traces GPS. Elles servent de structure de référence pour interpréter et manipuler les données GPS. Les trajets GPS sont représentés par des cellules à travers lesquelles ils passent, transformant les trajectoires continues en des représentations discrètes. Ces cellules facilitent la comparaison entre les différents segments de route. Une fonction de similarité, basée sur ces cellules, est utilisée pour déterminer la similitude entre deux chemins. Cette fonction utilise également des cellules dilatées, obtenues avec un élément structurel carré, pour compenser les petites variations ou erreurs dans les données GPS. De plus, une fonction d'inclusion basée sur ces représentations de grilles est utilisée pour filtrer les segments potentiellement incorrects, en déterminant si un segment est contenu dans un autre. Cette représentation en grille rend la comparaison et le filtrage des segments plus efficaces et précis.

Dans leur étude, Pu et al. [61] emploient une méthode basée sur des grilles pour

détecter les intersections routières à partir de données de trajectoire GPS. Cette approche repose sur l'idée que les intersections sont des points de convergence de multiples trajectoires GPS provenant de différentes directions. Afin d'identifier efficacement ces intersections, les auteurs divisent la carte en cellules de tailles variables en utilisant un modèle de quadtree [29]. Chaque cellule de ce quadtree contient les points GPS qui s'y situent. En analysant la vitesse et la direction des trajectoires au sein de chaque cellule, à commencer par les plus grandes, ils déterminent si une cellule contient une intersection. Si une cellule est jugée candidate, des techniques de clustering sont appliquées pour préciser la localisation de l'intersection. Cette méthode de grille permet de filtrer les sections de route qui ne sont pas des intersections, tout en identifiant les points clés de convergence des trajectoires GPS.

L'analyse des données de trajectoire GPS a été significativement améliorée par l'intégration de structures matricielles, un concept mis en évidence dans les travaux de Xie et Al [82]. Ces structures, telles que la matrice de longueur et la matrice de flèches, facilitent une représentation analytique rigoureuse des sous-séquences communes dans les données de trajectoire GPS, permettant une évaluation comparative détaillée. La matrice de longueur offre une représentation quantitative de la longueur des sous-séquences partagées entre deux ensembles de données GPS, tandis que la matrice de flèches fournit une visualisation directionnelle de ces correspondances. Ce processus permet l'identification de la plus longue sous-séquence commune (LCSS), un indicateur clé dans l'analyse des trajectoires. Par ailleurs, l'application d'une grille pour l'élaboration d'histogrammes 2D permet une discrétisation efficace de l'espace géographique. Cette méthode transforme les données GPS en une forme structurée, facilitant ainsi la quantification et la visualisation de la densité des points. Cette approche granulaire ne se limite pas à améliorer l'interprétation des données ; elle optimise également les performances en termes de calculs spatiaux.

3.1.2 Travail préliminaire

La collaboration entre le laboratoire ICube et l'entreprise Visorando a été initiée dans le cadre d'un projet de stage mené par Ilias Rmouque et Jonathan Jadlo, deux étudiants en informatique. Cette expérience a constitué le fondement de nos recherches doctorales ultérieures. La méthode exposée dans cette section représente le point de départ de notre travail académique. Dans le cadre des travaux présentés par les stagiaires, une technique innovante pour la fusion de traces GPS a été développée, se basant sur un découpage en zones rectangulaires. Initialement, les traces GPS sont filtrées puis sont projetées sur une grille, chaque point de la trace étant associé à une case spécifique selon sa position. La fusion s'effectue par le calcul du barycentre de chaque case, permettant ainsi de générer un graphe en connectant toutes les cases adjacentes, procédant un point, entre elles. Cette méthode s'inspire de travaux antérieurs, en particulier ceux de Mariescu-Istodor et Franti [55].

Plusieurs paramètres sont ajustés pour optimiser l'algorithme sur des données de randonnée. La taille des zones, cruciale pour la distinction des différents types de chemins, a été fixée à 15x15m après divers tests, offrant une séparation efficace entre les chemins proches. Un seuil a été défini pour exclure les traces anecdotiques, souvent dues à des déplacements hors sentier. Les fonctions de nettoyage présentent

également leurs spécificités : une fonction de correction angulaire nécessite un cosinus seuil (fixé à 0.7, soit environ 45°) et une distance de fusion (35m). Pour les zones de confusion (Zone contenant plusieurs sommets de degrés supérieurs à 3), les arêtes proches sont évaluées jusqu'à une certaine distance (100m), et une distance minimale est établie pour les sommets de degré 1.

En conclusion de leur méthode, l'algorithme de déformation temporelle dynamique (DTW) est utilisé pour affiner les chemins, en associant les points des traces GPS selon leur similarité pour déduire le tracé final.




FIGURE 3.1 – Des traces au graphe. Une illustration tirée du rapport de stage de Ilias Rmouque et Jonathan Jadlo

La méthode développée au cours du stage, présentée dans la Figure 3.1, a permis de produire une carte détaillée. Toutefois, cette approche n'est pas exempte d'imperfections, telles que l'omission de certains chemins, principalement en raison d'un manque de données et des seuils établis, ainsi que le positionnement inexact de plusieurs intersections. Nous avons aussi relevé des limites de la méthode, en particulier lorsque les jeux de données étaient plus volumineux ou moins précis. En réponse à ces défis, nous avons choisi de donner la priorité à la précision des intersections. Le processus de post-traitement a été revu et simplifié, se concentrant sur l'application successive de grilles en deux et trois dimensions, suivant un décalage défini. Enfin, la méthode a ensuite été comparée aux approches de l'état de l'art pour être validée.

3.2 Méthodes

La discussion précédente a mis en lumière l'intérêt de l'utilisation de grille pour fusionner des informations spatio-temporelles. Nous présentons ici une nouvelle approche basée sur plusieurs grilles et permettant la construction d'un graphe modélisant l'ensemble des données issues d'un ensemble de traces GPS.

Nous commencerons par décrire les traitements préliminaires nécessaires pour adapter la trace GPS à la structure de la grille. L'objectif est d'harmoniser la flexibilité de la trace GPS avec la rigidité de la grille. Puis, nous présenterons notre méthode de fusion des traces GPS, suivie par une explication des traitements postérieurs. Ces derniers exploitent aussi la grille, mais avec une application et un ajustement spécifiques. La taille des cellules et le niveau de décalage seront des paramètres clés discutés en détail. Enfin, cette section introduira également notre approche pour convertir les données générées en un graphe, composé de segments et d'intersections, offrant ainsi une représentation claire et structurée des informations extraites des traces GPS.

3.2.1 Pré-traitement

Bien que les technologies GPS aient révolutionné la façon dont nous capturons les déplacements et traçons les itinéraires, l'exploitation de ces données, notamment celles acquises via des applications mobiles, présente plusieurs défis. Les séries temporelles issues des traces GPS peuvent contenir diverses formes de bruits et d'incohérences, comme des points manquants, des erreurs de localisation, ou des enregistrements en double. Les différentes causes potentielles de ces anomalies sont exposées dans le premier chapitre, section 1.2.4. Parmi les facteurs susceptibles d'affecter la qualité des données, on peut citer les interférences dues à des obstacles naturels ou artificiels tels que les ponts et les arbres. Les caractéristiques de l'appareil d'enregistrement, telles que la précision du GPS ou une perte temporaire de signal, peuvent également introduire des erreurs. Des études, comme celle de Mingqi et al. [53], ont souligné que les points d'intérêt pourraient générer des comportements inhabituels dans les données. Une représentation de ces anomalies est illustrée à la figure 3.2.




FIGURE 3.2 – Illustration des problèmes liés à une position stationnaire de l'utilisateur et de son smartphone pendant la collecte de données GPS. Le randonneur effectue une pause de plusieurs minutes en bord de lac, mais le GPS mesure des positions jusqu'à plusieurs dizaines de mètres autour de sa position réelle. Images ©2024 Google, Images ©2024 GeoContent.

Plusieurs méthodes([21, 56]) de fusion de traces traitent chaque point de la trace GPS comme une entité isolée lors de la fusion de données, éliminant ainsi le besoin de prétraitement. Toutefois, dans notre approche, nous employons une méthode de clustering axée sur une grille pour fusionner les traces. Cela signifie qu'il est essentiel que chaque trace d'entrée présente des caractéristiques semblables à celles des autres traces de l'ensemble de données. Pour cette raison, un prétraitement rigoureux est indispensable pour éliminer les anomalies et assurer la qualité des données en entrée.

3.2.1.1 Suppression des doublons consécutifs

Les traces GPS contiennent fréquemment des points identiques consécutifs, résultant en des positions exactement similaires au sein de la série temporelle. Ces doublons, dépourvus de valeur ajoutée, peuvent biaiser ou compliquer le processus de fusion, particulièrement lors de l'utilisation d'algorithmes de clustering où les groupes formés pourraient être influencés de manière disproportionnée par des positions répétées. Les causes de ces doublons sont variées, incluant des interruptions temporaires du signal, des problèmes de mise à jour des coordonnées ou des erreurs d'enregistrement. Leur présence peut altérer la perception des mouvements, indiquant à tort une immobilité là où pourrait se trouver une simple anomalie de mesure. Pour pallier ce problème, un filtre a été intégré lors de la phase de prétraitement afin d'identifier et d'éliminer ces doublons consécutifs. Chaque série temporelle est minutieusement examinée, et toute position identique à la précédente est retirée de l'ensemble de données. Cette étape assure que notre algorithme de clustering traite des données plus précises et fiables.

Soit $t_1 \in T$ une série temporelle de positions GPS, où chaque élément p_i est un triplet composé de la latitude, de la longitude et d'un horodatage :

$$t_1 = \{p_1, p_2, p_3, p_4, p_5\}$$

Supposons les valeurs suivantes pour ces points :

$$\begin{aligned} p_1 &= (48.8566, 2.3522, 2023-10-05\ 12:00:00) \\ p_2 &= (48.8566, 2.3522, 2023-10-05\ 12:01:00) \\ p_3 &= (48.8566, 2.3522, 2023-10-05\ 12:02:00) \\ p_4 &= (48.8570, 2.3530, 2023-10-05\ 12:03:00) \\ p_5 &= (48.8575, 2.3540, 2023-10-05\ 12:04:00) \end{aligned}$$

Ici, p_1 , p_2 et p_3 sont des doublons consécutifs, car ils ont la même latitude et la même longitude, bien que leurs horodatages soient différents. Après suppression des doublons consécutifs, la série temporelle nettoyée t'_1 serait :

$$t'_1 = \{p_1, p_4, p_5\}$$

3.2.1.2 Découpage de traces

Pour certaines raisons (perte de signal par exemple), un appareil GPS peut arrêter d'enregistrer une partie d'une randonnée ou d'une course. Le résultat inclura un saut qui dépasse parfois plusieurs kilomètres. Garder ces aberrations dans le jeu de données aurait évidemment un impact négatif sur le résultat. Pour résoudre ce problème, nous définissons un seuil $s_{distMax}$ représentant la distance maximale acceptable entre deux points consécutifs d'une série. Au-delà de ce seuil, la trace est scindée en deux. Pour trouver la meilleure valeur pour $s_{distMax}$ nous avons mené une analyse statistique sur 500 traces aléatoires de notre base de données. Sur chaque

trace, nous avons calculé la valeur moyenne de la distance et constaté que l'addition de la moyenne et de l'écart-type ne dépasse jamais 200 m dans les cas normaux. Comme [34], nous décidons de fixer $s_{distMax}$ à 250 m pour le réseau piéton et à 400m dans le cas des réseaux routiers (acquis par des véhicules se déplaçant plus vite que les piétons).

En prenant un exemple simplifié de trace $t_1 \in T$:

$$t_1 = \{(1, 1), (2, 2), (10, 10), (11, 11)\}$$

et en supposant que $s_{distMax} = 5$ m, la distance entre les points (2, 2) et (10, 10) dépasse ce seuil. Par conséquent, la trace est scindée pour donner :

$$\begin{aligned} t_1 &= \{(1, 1), (2, 2)\} \\ t_2 &= \{(10, 10), (11, 11)\} \end{aligned}$$

3.2.1.3 Homogénéisation de la fréquence d'acquisition

L'acquisition GPS dépend de l'appareil utilisé, et les résultats peuvent varier considérablement en fonction de la fréquence d'acquisition et de la vitesse du piéton. Pour garantir une équité dans l'analyse, il est essentiel d'homogénéiser la fréquence des points au sein de chaque trace. Ici, la vitesse (et donc le facteur temps) n'intervient pas dans le calcul. Aussi, nous avons opté pour une homogénéisation spatiale des points acquis, en ajoutant des points à chaque trace selon un seuil fixe $s_{freq} = 1m$, assurant ainsi que les traces possèdent un point tous les mètres. Dans ce travail nous comptons mettre en œuvre une technique de fusion de traces GPS par application de grille. Cependant, pour que cette technique soit efficace et que chaque trace ait une contribution équilibrée, l'homogénéisation préalable de la distribution spatiale des points sur chacune des traces est indispensable. Cela garantit qu'aucune trace ne soit considérée comme plus importante qu'une autre lors de la fusion.

Considérons initialement la trace t_1 . Avant le processus d'homogénéisation, elle se présente comme suit :

$$\begin{aligned} \text{coef} &= \frac{\text{circonférence moyenne de la Terre}}{360} = 11320(m) \\ \text{distance}(p_i, p_j) &= \sqrt{((\text{lat}_{p_j} - \text{lat}_{p_i}) * \text{coef})^2 + ((\text{lon}_{p_j} - \text{lon}_{p_i}) * \text{coef})^2} \\ t_1 &= \{p_1, p_2, p_3, p_4\} \\ \text{distance}(t_1) &= \{-, 5, 2, 6\} \end{aligned}$$

Après l'application du processus d'homogénéisation, la trace est transformée et s'enrichit de points supplémentaires pour respecter la résolution définie. Elle devient :

$$\begin{aligned} t'_1 &= \{p_1, p_2^*, p_3^*, p_4^*, p_5^*, p_6, p_7^*, p_8, p_9^*, p_{10}^*, p_{11}^*, p_{12}^*, p_{13}^*, p_{14}\} \\ \text{distance}(t'_1) &= \{-, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1\} \end{aligned}$$

Nous considérons que la distance entre les points d'une trace est courte et ne nécessite pas de prendre en compte la courbure de la Terre lors du calcul de la distance entre 2 points.

3.2.1.4 Amélioration de la précision des virages

Les techniques de clustering, y compris celle que nous avons développée, présentent souvent une tendance naturelle à arrondir les angles du graphe résultat. Cette caractéristique, commune à de nombreuses méthodes de traitement de données, peut conduire à une diminution significative de la précision lors de l'identification des points de virage critiques. Or, les virages sont souvent indicatifs d'intersections dans de nombreuses applications de cartographie, et une détection précise de ces intersections est cruciale pour améliorer la justesse de nos résultats. Dans ce contexte, l'étude de Wu et al. [81] a apporté une avancée notable en affinant la densité des points aux virages, ce qui a amélioré la précision de leur détection des intersections, principalement grâce à l'utilisation de cartes de chaleur.

Bien que notre méthode diffère fondamentalement de celle de Wu et al. [81], notamment en ce qui concerne l'usage des cartes de chaleur pour détecter les points cruciaux, leur approche a influencé notre réflexion. Nous avons adopté une stratégie similaire visant à améliorer la précision aux points névralgiques. Il est important de noter une différence majeure dans l'objectif de nos deux études. Tandis que notre recherche se concentre sur la création d'un réseau dédié aux segments de randonnée pédestre, avec une topographie et une morphologie des chemins variées et complexes, l'étude de Wu et al. se focalise sur les données issues de routes urbaines, caractérisées par leur linéarité. Cette distinction, loin d'être négligeable, met en évidence la flexibilité et la robustesse de notre méthode face à une diversité de terrains et de contextes.

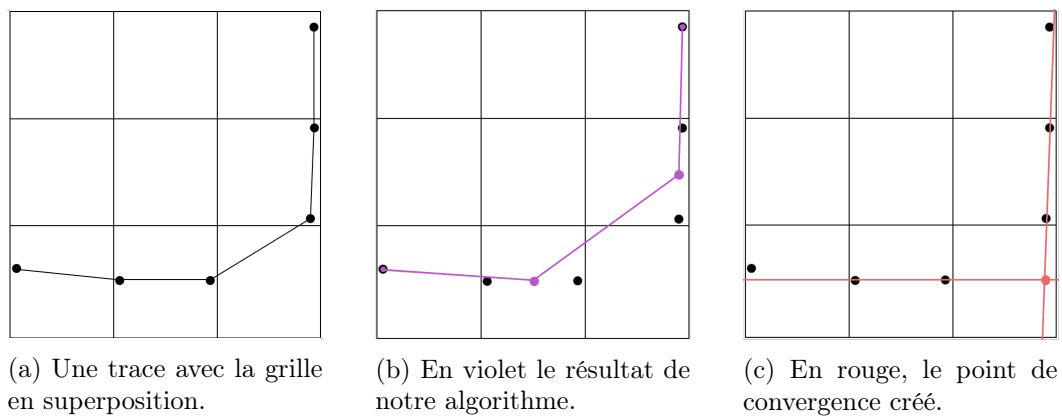


FIGURE 3.3 – Ajout d'un point de convergence pour mieux estimer un virage.

La méthode adoptée par Wu et al. se base sur l'extraction de séries de quatre points consécutifs p_1 , p_2 , p_3 , et p_4 d'une trajectoire. L'angle α formé entre les vecteurs $p_1\vec{p}_2$ et $p_4\vec{p}_3$ est calculé puis un point de convergence est intégré à la trajectoire. Cependant, pour mieux répondre aux besoins de notre réseau complexe, nous avons cherché une approche qui pourrait s'adapter à une variété de configurations de trajectoires. C'est pourquoi nous avons dévié de la méthodologie de Wu et al. pour adopter une vision plus généralisée. Cette nouvelle approche associe les cellules d'une grille, introduite dans la section 3.1.2 aux points de convergence calculés. L'intérêt majeur de cette méthode est qu'elle permet d'apporter une information bénéfique à l'ensemble des traces passant par les cellules concernées, sans se limiter à un contexte

particulier.





FIGURE 3.4 – Ajout d’un point de convergence erroné à une trace t_1

Étant donné la nature de notre réseau, il était évident que tous les virages ne seraient pas standardisés. Par exemple, dans un contexte pédestre, il est courant de rencontrer des virages en épingle ou des virages très serrés qui ne sont pas forcément à angle droit. Conserver la méthode initiale dans de tels cas aurait comme conséquences d’ajouter des points erronés aux cellules comme nous pouvons l’observer sur la Figure 3.4. Dans cet exemple le point ajouté est bien trop éloigné du chemin réellement emprunté.

Pour répondre à cette variabilité, nous avons introduit un intervalle pour le positionnement du point de convergence, défini par : $\{90 - s_{virage}; 90 + s_{virage}\}$. La configuration de cet intervalle est critique. Ainsi, pour éviter de générer des représentations erronées, nous avons dû calibrer avec soin le paramètre s_{virage} . Nos tests ont démontré que, pour capturer efficacement la majorité des virages de notre réseau, un écart de 30 degrés par rapport à l’angle de 90 degrés était optimal.



(a) Sans améliorations de virages

(b) Avec améliorations de virages

FIGURE 3.5 – Résultat du regroupement des traces avec et sans améliorations des virages.

Dans notre recherche, l’intégration des points de convergence n’est pas un simple ajout formel ou esthétique, mais elle est au cœur de notre démarche algorithmique

pour déterminer des trajectoires précises et pertinentes. Cette importance est particulièrement mise en évidence dans notre méthodologie de regroupement basée sur l'utilisation de grilles multiples. Dans cette approche, nous associons systématiquement les points de convergence aux points caractéristiques de chaque cellule de la grille. Afin de souligner leur impact et leur pertinence dans notre modèle, nous avons introduit un paramètre de pondération, désigné par $s_{convergence}$, que nous avons fixé à une valeur de 4 (Voir la justification ci-après). Cette pondération accorde une importance accrue à ces points par rapport aux autres points caractéristiques, reflétant ainsi leur rôle clé dans l'affinement et la précision de notre méthode et notamment dans la détection des intersections qui sont des éléments d'une importance capitale dans les résultats. La Figure 3.5 illustre l'influence significative des points de convergence sur les résultats de notre algorithme.

TABLE 3.1 Évolution des résultats sur les ensembles de données Blaesheim et GPS7 avec différentes valeurs de $s_{convergence}$.

Jeux de données	$s_{convergence}$	Intersections		Segments	
		Imprécision	Score-F	Imprécision	Score-F
Blaesheim	0	17.1m	0.84	10.4m	0.86
	1	11.5m	0.85	9.3m	0.88
	2	12.3m	0.86	9.2m	0.88
	3	12.1m	0.86	9.3m	0.88
	4	11.9m	0.87	9.0m	0.88
	5	12.0m	0.86	9.1m	0.88
GPS7	0	12.1m	0.86	6.2m	0.90
	1	8.4m	0.89	5.3m	0.91
	2	8.4m	0.90	5.1m	0.92
	3	8.4m	0.90	5.0m	0.92
	4	8.4m	0.90	4.9m	0.92
	5	8.4m	0.90	4.9m	0.92

L'analyse des résultats, présentés dans le Tableau 3.1, indique nettement que les performances pour $s_{convergence} = 1+$ sont supérieures, selon nos critères, à celles pour $s_{convergence} = 0$. Lorsque nos points de convergence sont intégrés, c'est-à-dire pour $s_{convergence} = 1+$, nous observons une amélioration significative de la précision. Cette constatation confirme notre hypothèse sur l'impact crucial des points de convergence dans l'établissement précis des trajectoires. Notre technique va au-delà d'une simple amélioration ; elle optimise effectivement les virages, rendant ainsi les trajectoires plus précises et pertinentes. Le choix de la valeur de $s_{convergence}$ est donc fondamental pour exploiter pleinement les capacités de notre approche algorithmique.

En fixant $s_{convergence}$ à 4, nous avons trouvé un équilibre entre la considération des points de convergence et l'importance des autres points caractéristiques. Cette valeur permet une intégration efficace des points de convergence tout en préservant la contribution des autres éléments dans le calcul des trajectoires.

3.2.2 Multiple application de grilles

Le processus de fusion des traces GPS pour obtenir une représentation unique et unifiée repose sur un clustering basé sur l'utilisation d'une grille. Cette grille est superposée aux traces GPS, et chaque cellule englobe certains points de ces traces. La moyenne des positions de ces points dans chaque cellule permet de déterminer un point central pour la cellule. La dimension de ces cellules est définie par le paramètre *tailleCellule*. Cependant, le positionnement initial de la grille pose certains défis, comme l'illustre la Figure 3.6. Un exemple particulièrement représentatif est celui des quatre segments bleus dans la Figure 3.6b. Ces segments, formant une structure en losange, résultent de la fusion des traces de la Figure 3.6a, effectuée en fonction de la disposition de la grille bleue.

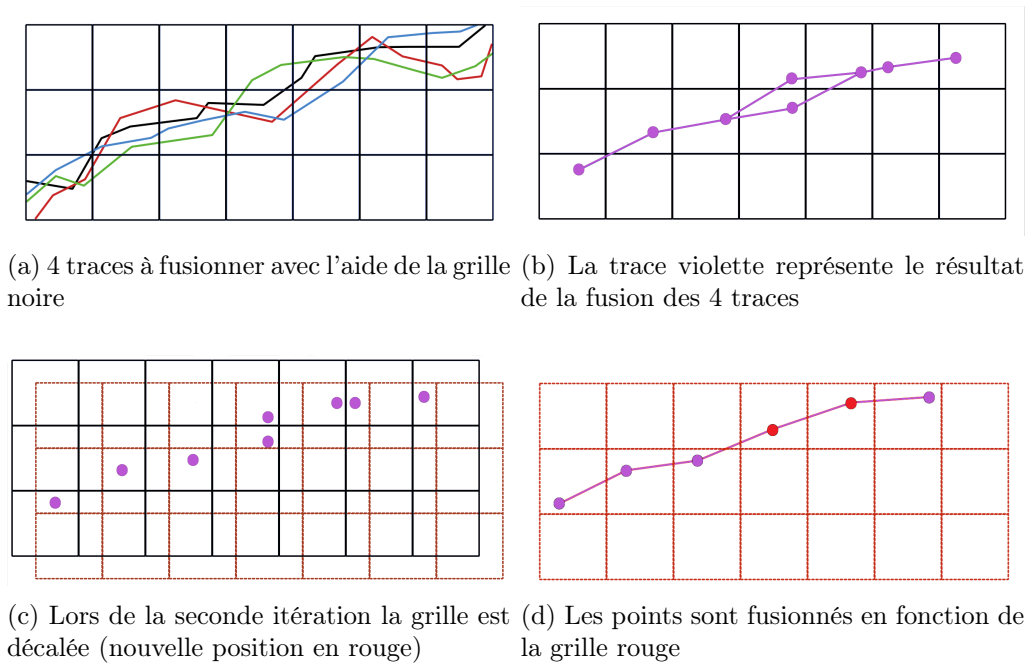


FIGURE 3.6 – Application itérative de l'algorithme de clustering avec des grilles multiples

Pour traiter les défauts liés à la localisation initiale de la grille, nous avons élaboré une version itérative de notre algorithme de clustering. Dans cette approche, le processus est répété plusieurs fois, avec un décalage systématique de la grille à chaque itération. Les coordonnées minimales des latitudes et longitudes (qui définissent les bords inférieur et gauche, notés e) de la grille sont ajustées à chaque itération. Cette modification est basée sur l'équation 3.1, qui dépend de l'itération courante i et du nombre total d'itérations I :

$$e' = e - \frac{I - i}{I} \times \text{tailleCellule} \quad (3.1)$$

Dans l'exemple illustré par la Figure 3.6c, la grille en rouge indique la position de la grille après pour la seconde itération. Grâce à ce décalage, les points formant initialement un losange se retrouvent désormais dans la même cellule, et sont par

conséquent fusionnés efficacement. Cette correction est mise en évidence dans la Figure 3.6d. Il est crucial de souligner que cette itération ne modifie pas la position des autres points représentatifs.

Paramétrage Un autre paramètre dans notre approche, est le nombre d'itérations, désigné par I . Intuitivement, on pourrait s'attendre à ce qu'une augmentation du nombre d'itérations conduise à une amélioration de la précision des résultats. Cependant, cela implique également une augmentation proportionnelle du temps de calcul. La Figure 3.7 montre comment le FScore évolue en fonction du nombre d'itérations pour deux ensembles de données distincts, détaillés dans la section 2.4.2.1. Il est intéressant de constater que, pour les deux jeux de données, le FScore tend à se stabiliser après seulement 6 itérations. Ce comportement a été confirmé sur l'ensemble des jeux de données que nous avons testés. De plus, la précision reste remarquablement constante, indépendamment de la valeur de I . Compte tenu de ces observations, et dans le but de maintenir une balance optimale entre la couverture et le temps de traitement, nous avons décidé de fixer la valeur de I à 7 itérations.

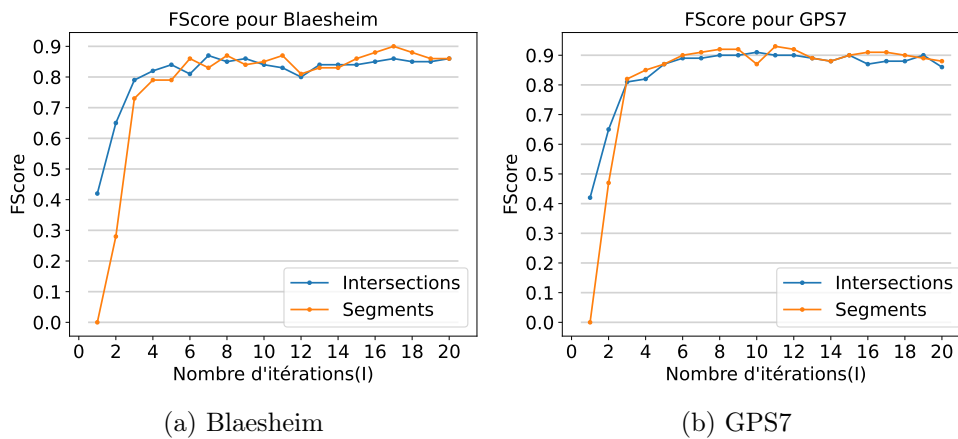


FIGURE 3.7 – Évolution du FScore en fonction du nombre d'itérations pour deux jeux de données

La dimension des cellules, indiquée par $tailleCellule$, est le seul paramètre à définir manuellement dans notre approche et à ajuster en fonction du jeu de données. Lera-Pérez et al. [46] ont recommandé un seuil de 55m pour classifier deux trajectoires comme similaires, mais nous pensons que différents facteurs peuvent influencer ce choix. Selon notre hypothèse, la dimension de $tailleCellule$ devrait correspondre à la dispersion moyenne des traces d'un ensemble de données par rapport à leur route d'origine. La rapidité de notre algorithme nous a permis de conduire des expérimentations approfondies sur différents jeux de données pour déterminer manuellement la valeur optimale de $tailleCellule$. Par exemple, après plusieurs essais sur le jeu de données de Chicago, nous avons constaté que $tailleCellule=87m$ offrait les résultats les plus satisfaisants. La Figure 3.8, montrant une échelle le long d'un itinéraire fréquemment utilisé, illustre que cette distance de 87m est en rapport avec la largeur des traces représentant une route.




FIGURE 3.8 – Extrait du jeu de données de Chicago pour comparer la meilleure valeur du paramètre *tailleCellule* à la largeur des traces sur une route

3.2.3 Segmentation

Après la phase de regroupement, chaque cellule de la grille contient un point représentatif unique. L'objectif de l'étape suivante est d'identifier les cellules fonctionnant comme des intersections pour construire un graphe représentatif des chemins possibles. Notre approche se distingue des méthodes existantes dans l'état de l'art par une détection simultanée des intersections et une fusion des traces, optimisant ainsi le temps d'exécution. Nous allons maintenant détailler le fonctionnement de notre algorithme de segmentation, en mettant l'accent sur sa capacité à traiter conjointement les intersections et les fusions de traces. Cette méthodologie se distingue par son efficacité et sa pertinence, produisant un modèle simplifié mais précis des traces GPS.

Nous décrirons chacune des étapes du processus, depuis l'identification initiale des sections jusqu'à la fusion finale des segments, et illustrerons notre approche avec des exemples visuels. L'objectif est de fournir une compréhension claire et approfondie de la manière dont notre méthode innove par rapport aux techniques conventionnelles. Cette présentation mettra en lumière les avantages spécifiques de notre approche, notamment en termes d'efficacité et de précision dans la construction de graphes à partir de traces GPS.

Pour illustrer notre méthode, référons-nous à la Figure 3.9. La sous-Figure 3.9a montre deux traces d'entrée constituées de points représentatifs, qui sont les barycentres des cellules traversées par une trace GPS, calculés lors de la phase de regroupement. Ces points offrent une représentation simplifiée de la trace originale. Un exemple notable est observé dans la trace rouge, où un rebroussement de chemin entraîne l'utilisation multiple de trois cellules. Notre algorithme de segmentation est conçu pour traiter uniformément les cellules traversées plusieurs fois par différentes traces ou par une seule trace. Il se compose de trois étapes principales.

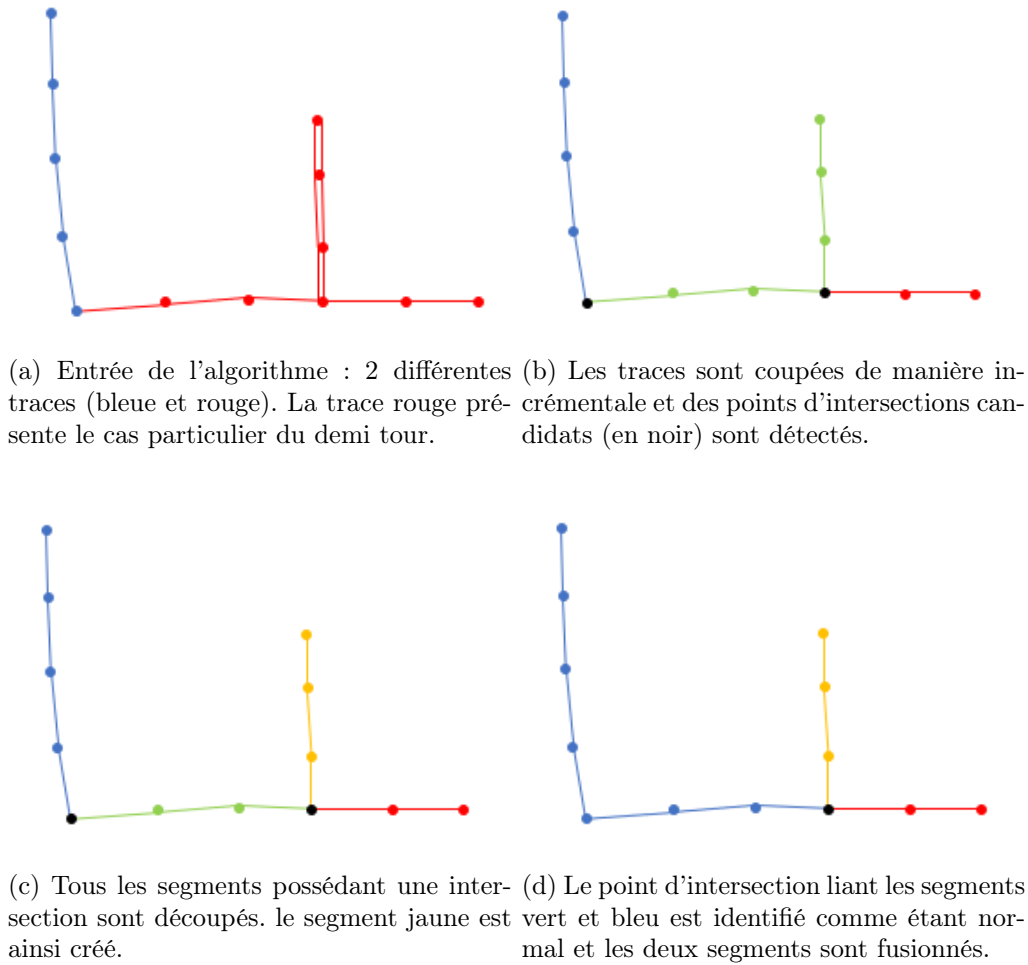


FIGURE 3.9 – Algorithme de segmentation

Fractionnement incrémental Cette étape consiste à parcourir séquentiellement les traces tout en gérant une variable d'état nommée *new*. Cette variable indique si la trace courante correspond à une nouvelle section ou à une section déjà identifiée dans le graphe. À titre d'exemple, partons du point bleu en haut à gauche de la Figure 3.9a. L'algorithme initie une section (en bleu dans la Figure 3.9b) qui s'étend jusqu'à la fin de la trace bleue. Lors du traitement de la trace rouge, la première cellule rencontrée est déjà référencée dans le graphe et la variable *new* signale que nous entamons une nouvelle section. Cette situation conduit l'algorithme à finaliser la section actuelle, la transformant en segment, et à identifier une intersection (en noir). Le segment suivant se développe jusqu'au mouvement de retour en arrière de la trace rouge. La cellule suivante étant déjà présente dans le graphe, le segment vert est intégré et *new* est mise à jour, indiquant que la section en cours est reconnue. À la fin du demi-tour, la combinaison de la détection d'une nouvelle cellule et de la valeur de *new* mène à la création du segment rouge et à l'identification de la deuxième intersection.

Découpage par intersection L’objectif de cette étape est de s’assurer que chaque segment ne contienne aucune intersection inattendue en son intérieur. Chaque segment est donc examiné minutieusement. Lorsqu’une intersection qui ne se situe pas à une extrémité du segment est découverte, une opération de fractionnement supplémentaire est mise en œuvre. Cette étape est essentielle pour garantir la précision de la segmentation et la pertinence des données. La Figure 3.9c illustre cette démarche : un segment initial, en vert, inclut une intersection qui n’est pas située à l’une de ses extrémités. Cette intersection, marquée en noir, déclenche le besoin de fractionner à nouveau ce segment. Suite à cette opération, le segment vert est divisé, engendrant un nouveau segment, représenté en jaune.

Fusion La dernière étape de notre processus vise à éliminer les intersections candidates incapables de connecter au moins trois segments. L’importance de cette démarche réside dans le fait qu’une intersection reliant moins de trois segments est souvent le résultat d’une anomalie ou d’une erreur de segmentation plutôt que d’une véritable intersection. Cette fusion est nécessaire pour simplifier le modèle et réduire les redondances. En examinant les Figures 3.9b et 3.9c, on remarque que les segments bleu et vert, bien que distincts initialement, partagent une connexion étroite et peuvent être considérés comme une seule entité. Ainsi, dans la Figure 3.9d, ces deux segments sont fusionnés en un segment unique de couleur bleue.

3.3 Résultats

Cette section a pour objectif de quantifier la contribution de notre nouvelle méthode en la comparant à des méthodes existantes, suivant les protocoles d’évaluation spécifiques aux approches de clustering basées sur des grilles. Avant de procéder à une analyse comparative, il est utile de récapituler les principes d’évaluation abordés précédemment dans le chapitre 2. Nous présentons d’abord un aperçu des méthodes de fusion de données GPS par clustering, puis nous comparons systématiquement notre méthode à ces approches en utilisant divers jeux de données.

Il est important de souligner que les travaux discutés dans cette section ont été menés en 2020. Par conséquent, ils ne couvrent que les méthodes et métriques disponibles jusqu’à cette date. De plus, l’objectif initial de ces travaux était de se familiariser avec les techniques de fusion de traces GPS, avant d’avoir accès aux données spécifiques de Visorando. C’est pourquoi, bien que cette section se termine par une discussion sur les données de Visorando, l’analyse se concentre principalement sur des données non représentatives de l’objectif initial de la thèse, à savoir des données urbaines plutôt que des données de randonnée.

3.3.1 Rappel des méthodes d’évaluation

3.3.1.1 Les métriques

Au cours de cette recherche, plusieurs métriques ont été développées pour évaluer le graphe obtenu à partir de la fusion des traces GPS. Pour les segments, l’évaluation se base sur le calcul de la distance moyenne entre un segment donné et tous

les segments de la vérité terrain, formant ainsi la métrique d'**imprécision**. Le segment le plus proche de la vérité terrain est sélectionné pour la comparaison. Cette approche assure qu'un segment évalué trouve systématiquement un appariement, tout en acceptant la possibilité que certains segments de la vérité terrain ne soient pas appariés. Chaque segment de la vérité terrain est apparié une seule fois. Les points structurels des segments générés sont comparés à ceux des segments de la vérité terrain. Le **FScore**, basé sur l'association de paires, est utilisé pour évaluer la précision et l'exactitude de ces appariements. Plus de détails sont disponibles dans la section dédiée 2.4.1.1.

En ce qui concerne les intersections, elles sont évaluées en les appariant avec celles de la carte de référence, en se basant sur un seuil de distance prédéfini. Après cet appariement, le **FScore** est à nouveau employé pour mesurer la qualité des intersections appariées. Une métrique supplémentaire, nommée **Imprécision**, a été introduite pour analyser l'impact du seuil de distance sur le FScore. Cependant, cette métrique n'a pas été utilisée avec les techniques de deep learning pour éviter une surcharge d'informations. Dans tous les cas, une intersection calculée est strictement appariée à une seule intersection de la vérité terrain, afin de préserver l'intégrité du FScore. Plus d'informations sont disponibles dans la section 2.4.1.2. Nous utilisons donc un total de quatre métriques distinctes pour évaluer le graphe généré.

3.3.1.2 Les jeux de données et de référence

Pour l'évaluation de notre algorithme, nous avons utilisé plusieurs jeux de données. Cet ensemble a été décrit dans la section 2.4.2.1 de façon détaillée. Nous avons d'abord introduit le jeu de données conventionnel de Chicago, puis, pour tester la polyvalence de notre méthode face à des traces de qualités variées, nous nous sommes tournés vers le testbed d'Hashemi, en excluant les autoroutes à plusieurs voies non adaptées au contexte de randonnée. De ce testbed, six ensembles ont été sélectionnés, illustrant différentes précisions. En outre, un jeu de données distinct, Blaesheim, a été intégré pour émuler les conditions de randonnée en montagne, offrant une perspective unique grâce à ses 39 traces centrées sur un village français. Ces choix de jeux de données mettent en lumière les différences notables entre des contextes urbains, des situations avec des données de qualités diverses, et un environnement de randonnée typique. Pour les jeux de données associés à Chicago et à Mehdi Hashemi, la carte de référence a été extraite de OpenStreetMap (OSM) [58], un standard largement adopté dans les études précédentes. En revanche, pour le jeu de données Blaesheim, une annotation manuelle a été réalisée pour créer une carte de référence, capturant ainsi les spécificités topographiques non indexées par les référentiels conventionnels comme OSM.

3.3.1.3 Références de notre analyse comparative

Notre étude se distingue par une comparaison rigoureuse avec cinq travaux majeurs de la littérature, à savoir ceux d'Edelkamp [25], Cao [14], Ahmed et Mahmuda [5], Stanojevic [72] et Guo [32]. La transparence exceptionnelle de ces cinq études, qui ont rendu leur code accessible, a facilité leur réimplémentation. Cette approche, emblématique d'une recherche ouverte, assure des comparaisons solides et renforce la confiance dans les résultats dans le domaine de la cartographie basée sur des traces

GPS. En complément, nous avons examiné les études où nous avons pu récupérer les graphes générés plutôt que d'accéder directement aux codes. Ces graphes ont ensuite été évalués selon notre propre cadre d'évaluation. Bien que l'absence de code source limite notre capacité à vérifier en détail leurs méthodologies, l'intégration de ces graphes dans notre analyse témoigne de notre volonté d'avoir une perspective aussi complète et comparative que possible sur les performances dans ce domaine.

À cet égard, nous avons extrait des informations pertinentes des graphes liés à l'évaluation du jeu de données de Chicago des articles [21, 13, 56] disponibles sur <http://mapconstruction.org/>, et des jeux de données d'Hashemi pour les articles [21, 91, 34], récupérant les valeurs d'imprécision et de rappel directement de [34]. Il est à noter que dans ce dernier cas, il n'est pas possible de faire une comparaison sur la métrique du FScore, en raison de l'absence de la métrique de précision dans l'étude.

3.3.2 Évaluation sur le jeu de données de Chicago

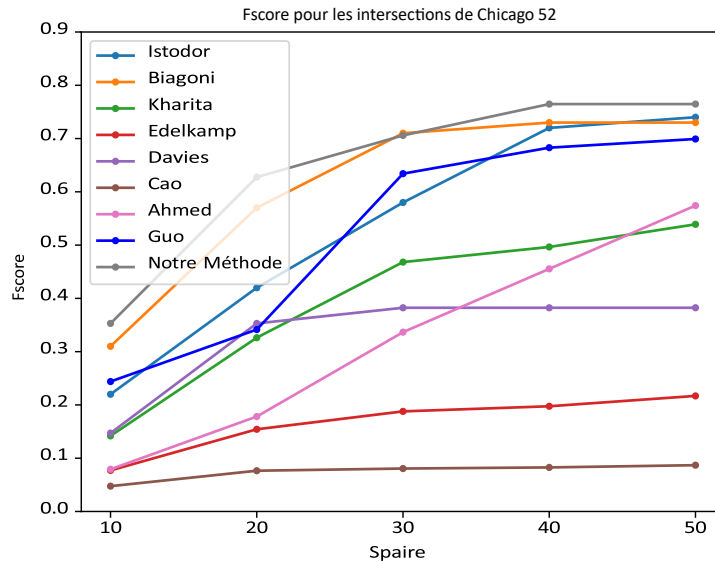


FIGURE 3.10 – Évaluation du FScore sur les intersections pour le jeu de données Chicago pour 5 valeurs du paramètre s_{paire} différentes.

Nous allons ici évaluer la qualité des intersections (Voir section 2.4.1.2) pour le jeu de données de Chicago. Pour une valeur de paramètre s_{paire} fixée à $50m$, qui est la valeur conventionnelle, quatre méthodes semblent se distinguer par leur performance illustrée sur la Figure 3.10. Parmi celles-ci, les travaux de Guo [32], Istodor [56], Biagoni [13] et la nôtre méritent une attention particulière. Il est à noter que, dans cette comparaison, c'est notre méthode qui présente la meilleure performance, surpassant les autres par une marge de plus de 3% en termes de FScore. Lorsque la valeur du paramètre "Spare" est réduite, seule la méthode de Biagoni continue de montrer une robustesse relative, bien que sa performance reste inférieure à la nôtre de 3%, sauf dans le cas où s_{paire} est égal à $30m$. Les performances des méthodes Guo et Istodor, en revanche, subissent une chute significative lorsque la

valeur de s_{paire} est diminuée. Les autres études, [21, 72, 25, 14, 21, 5], ont montré des résultats qui suggèrent que la qualité de leur détection d'intersection est nettement inférieure. Ces observations soulignent l'importance de la robustesse des méthodes de détection d'intersection face aux variations des paramètres, et plaident en faveur de la supériorité de notre approche dans des conditions conventionnelles et modifiées.

TABLE 3.2 Évaluation des segments sur le jeu de données Chicago. L'imprécision est exprimée en mètres.

Méthode	Imprécision	Précision	Rappel	FScore
Edelkamp [25]	23.7m	0.10	0.93	0.18
Cao [14]	21.9m	0.04	0.85	0.08
Ahmed [5]	21.4m	0.72	0.75	0.74
Kharita [72]	16.9m	0.48	0.92	0.63
Guo [32]	15.2m	0.65	0.82	0.74
Davies [21]	47.4m	0.92	0.25	0.39
Biagoni [13]	27.6m	0.88	0.65	0.75
Istodor [56]	30.9m	0.79	0.82	0.81
Notre méthode	16.9m	0.80	0.80	0.80

Le Tableau 3.2 illustre les performances de différentes méthodes de détection de segments sur le jeu de données Chicago. En examinant de près ces résultats, notre méthode émerge clairement comme la plus équilibrée et robuste, offrant un excellent compromis entre imprécision (16.9m), précision, rappel et FScore (0.80). Lorsque nous combinons toutes ces métriques, elle surpasse clairement les autres études. Guo [32], avec la plus faible imprécision à 15.2m et un FScore honorable de 0.74, s'en sort également bien, bien que notre méthode ait montré une meilleure combinaison globale de performances. Istodor [56], avec le FScore le plus élevé à 0.81, mérite également une mention spéciale pour sa capacité à équilibrer précision et rappel. Cependant, certaines méthodes présentent des faiblesses notables. Par exemple, bien que Davies [21] détienne la meilleure précision à 0.92, son faible rappel à 0.25 indique une propension à omettre de nombreuses intersections réelles. De plus, Cao [14], malgré un rappel assez élevé, affiche une précision et un FScore nettement inférieurs, suggérant une abondance de faux positifs.

En conclusion, les résultats obtenus indiquent que notre méthode affiche des performances élevées sur l'ensemble des métriques évaluées. Cette constatation suggère que notre approche se positionne favorablement par rapport aux autres méthodes examinées dans cette étude. Il apparaît également que certaines méthodes existantes devraient bénéficier d'améliorations pour atteindre un niveau de robustesse similaire.

3.3.3 Inclusion de diversité avec l'évaluation sur les jeux de données de Mahdi Hashemi

Une partie conséquente de notre évaluation sur les jeux de données repose sur l'étude réalisée par Mahdi Hashemi. Cependant, contrairement à son approche, nous avons choisi d'inclure une évaluation des intersections. Pour éviter une surcharge d'informations dans cette section, nous nous sommes limités à une évaluation sur le




FIGURE 3.11 – Évaluation du FScore pour la détection des intersections sur GPS7.

premier jeu de données, en se concentrant uniquement sur les méthodes que nous avons pu réimplémenter. La Figure 3.11 témoigne de l'excellence de notre méthode. Indépendamment de la valeur de s_{paire} , nos résultats surpassent nettement ceux obtenus par Guo [32], Cao [14], Ahmed [5], Edelkamp [25], et Kharita [72].

L'analyse détaillée des résultats pour les jeux de données GPS7 à GPS12 révèle des observations critiques concernant l'évaluation de la reconstruction des segments. Un aspect crucial est l'interaction entre la précision et le rappel dans l'évaluation des performances des méthodes de reconstruction des traces GPS. Par exemple, la méthode de Zhang [91] montre d'excellentes performances en termes de rappel et d'imprécision sur plusieurs jeux de données (avec un rappel de 1.00 pour GPS08 et une imprécision minimale de 2.7m). Cependant, l'absence de données de précision limite la possibilité d'évaluer complètement la qualité et la fiabilité de cette approche. Sans une mesure de la précision, il reste imprudent de conclure définitivement sur l'efficacité globale de cette méthode, malgré ses performances apparentes.

L'analyse transversale des performances des différentes méthodes sur les jeux de données GPS7 à GPS12 révèle une tendance à la résistance au bruit et à la dégradation de la qualité des traces GPS. Des méthodes comme celle de Cao [32] et Ahmed [91] affichent une stabilité dans leurs valeurs d'imprécision à travers les différents jeux de données, ce qui pourrait indiquer une robustesse face au bruit et une détérioration de la qualité des traces. Toutefois, leurs FScores restent modestes. En contraste, notre méthode se distingue par une imprécision faible et des FScores élevés, traduisant un équilibre entre précision et rappel. Alors que la qualité des traces GPS tend à diminuer de GPS7 à GPS12, notre méthode conserve des performances robustes, suggérant une résilience face aux données bruitées et une applicabilité accrue dans des scénarios réels où les données parfaites sont peu fréquentes.

3.3.4 Évaluation sur un jeu de données plus proche de la réalité : Blaesheim

La comparaison des méthodes sur le jeu de données de Blaesheim, dont nous détenons les droits, ne peut être effectuée qu'avec les méthodes que nous avons réussi

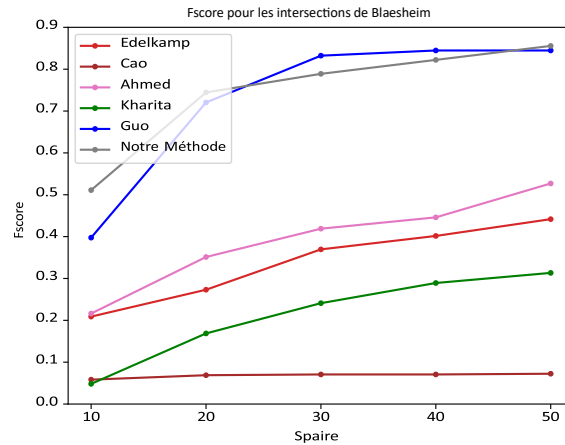
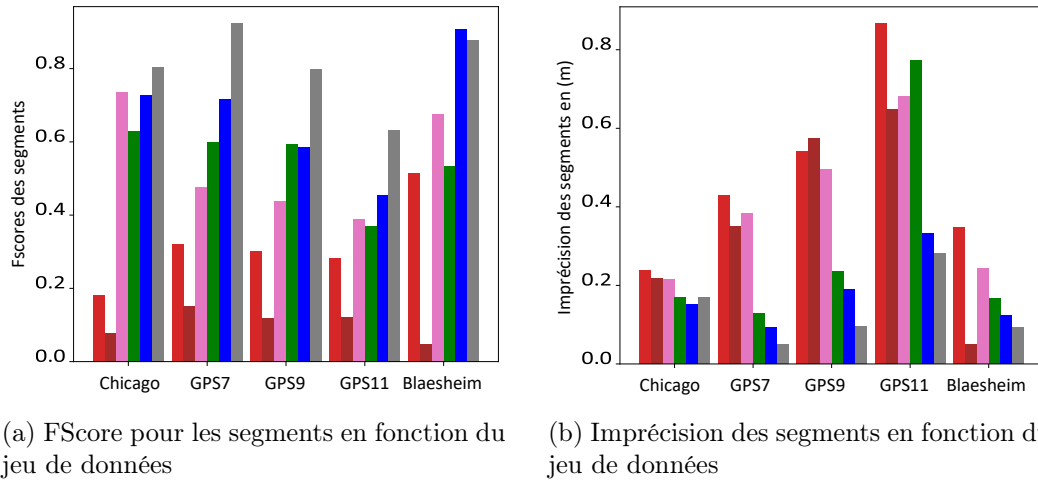


FIGURE 3.12 – Évaluation de la détection des intersections sur le jeu de données de Blaesheim selon différentes valeurs de s_{paire}

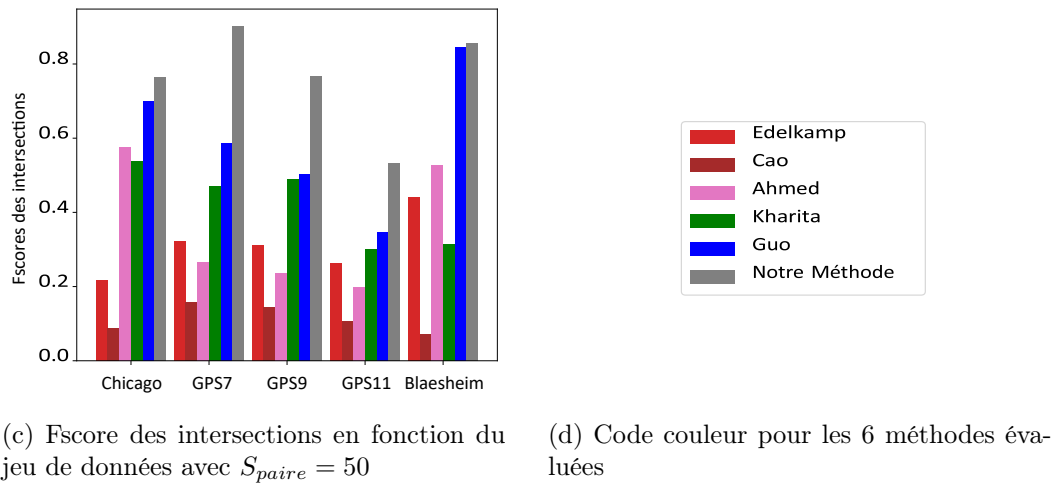
à réimplémenter. En ce qui concerne la qualité des intersections, indépendamment de la valeur de s_{paire} , il est à noter que la majorité des méthodes testées ne parviennent pas à produire des résultats satisfaisants. Seules notre méthode et celle proposée par Guo [32] se distinguent. L'analyse révèle que notre méthode surpasse celle de Guo aux valeurs extrêmes de s_{paire} , soit 10, 20 et 50. En revanche, la méthode de Guo semble avoir un avantage lorsque s_{paire} est fixé à 30 et 40. Sur la base de ces observations, nous concluons que, bien que les deux méthodes présentent des atouts distincts, notre approche montre une efficacité légèrement supérieure dans ce contexte précis.

Le Tableau 3.4 présente une évaluation de la reconstruction de segments sur le jeu de données de Blaesheim. Plusieurs méthodes ont été évaluées et comparées en termes d'imprécision, de précision, de rappel et de FScore. La méthode de Guo [32] affiche une remarquable précision avec un score de 0.94, le plus élevé parmi toutes les méthodes évaluées. Elle présente également une imprécision de 12.4m, ce qui est nettement meilleur que la plupart des autres méthodes, à l'exception de Cao [14] qui a une imprécision minimale de 4.9m mais avec un FScore nettement inférieur à 0.06. Notre méthode se distingue particulièrement en termes de rappel, atteignant un score impressionnant de 0.95, le plus élevé du tableau. Bien que sa précision de 0.82 soit légèrement inférieure à celle de Guo, elle affiche un FScore très compétitif de 0.88, ce qui n'est surpassé que de peu par Guo. De plus, avec une imprécision de 9.3m, notre méthode surpasse Guo dans ce domaine. En synthèse, bien que la méthode de Guo se soit avérée exceptionnellement précise, notre méthode présente un équilibre très légèrement supérieur entre imprécision, précision, rappel et FScore. Cette combinaison de performances démontre la robustesse et l'efficacité de notre approche, en particulier lorsque l'on considère l'importance du rappel dans la reconstruction de segments.



(a) FScore pour les segments en fonction du jeu de données

(b) Imprécision des segments en fonction du jeu de données

(c) Fscore des intersections en fonction du jeu de données avec $S_{paire} = 50$

(d) Code couleur pour les 6 méthodes évaluées

FIGURE 3.13 – Vue globale des résultats sur l'ensemble des jeux de données

3.3.5 Résumé des résultats

Dans notre étude, six algorithmes différents ont été testés sur divers jeux de données, et les résultats détaillés sont présentés dans la Figure 3.13. Globalement, et ce, indépendamment du jeu de données considéré, les résultats indiquent que notre méthode affiche des performances notables. En particulier, la précision mesurée en mètres de notre méthode s'est révélée être significative. Il convient de mentionner que l'approche de Guo [32] a également montré des résultats appréciables, en particulier avec le jeu de données de Blaesheim. Cependant, cette méthode montre certaines limites avec d'autres ensembles de données, où elle se positionne légèrement derrière notre approche.

Une observation intéressante est que, de manière générale, les algorithmes testés semblent être plus performants dans la détection et la reconstruction des segments que dans la détection des intersections. Cette différence de performance suggère une opportunité d'amélioration dans le domaine de la détection des intersections. En conclusion, bien que chaque algorithme présente ses propres forces et faiblesses, notre méthode se distingue par sa robustesse, sa précision et sa résilience au bruit, la

plaçant ainsi dans une position favorable par rapport aux autres méthodes testées.

3.3.6 Visorando

Bien que l'objectif de ce premier travail était de créer une méthode compétitive avec celles de la communauté scientifique sur des jeux de données de celle-ci, nous ajoutons dans cette section un aperçu des résultats que nous pourrions obtenir sur les données Visorando. Nous ferons ici l'analyse des résultats de notre méthode sur un jeu de données issu de la base Visorando, se concentrant sur 148 traces localisées dans le parc du "Ballon d'Alsace". Ces traces, capturées par divers appareils (smartphones, montres, GPS, etc.), présentent des variations dues aux paramètres de l'appareil et à la vitesse de l'utilisateur. La Figure 3.14 montre un extrait de ces données sur une carte OSM. L'examen de cet échantillon a révélé la présence de lignes reliant deux points éloignés, potentiellement causées par des interruptions dans l'enregistrement de la trace. Parmi les algorithmes testés, seuls Kharita et notre méthode ont traité efficacement ces anomalies, indiquant un manque de prétraitement dans les autres algorithmes.

Nous avons également observé que certaines traces présentaient un écart significatif entre leurs points de départ et d'arrivée (par exemple, de l'Alsace à Paris). Alors que la plupart des algorithmes ont géré cet écart, l'algorithme de Guo a rencontré des problèmes de mémoire RAM, nécessitant l'exclusion de 2 traces avec cette caractéristique. Edelkamp [25] et Kharita [72] tendent à produire un nombre excessif de segments sur d'autres jeux de données, ce qui peut affecter la précision des résultats. De son côté, l'approche d'Ahmed, tout en conservant une forme fidèle à la réalité, omet parfois de nombreuses sections de trace. Guo et notre méthode rencontrent des défis avec des traces très proches, mais notre approche montre une meilleure performance en termes de rappel et de connectivité.

En résumé, bien que notre méthode rencontre des défis similaires à ceux des autres algorithmes, elle présente des avantages en matière de traitement des anomalies et de connectivité. Ces résultats démontrent notre capacité à offrir une solution équilibrée et efficace pour l'analyse de telles données, soulignant ainsi la pertinence et l'originalité de notre contribution dans ce domaine de recherche.

3.3.7 Temps de calcul

Notre algorithme est conçu pour traiter efficacement de vastes territoires. Ainsi, il est crucial que notre méthode affiche une bonne efficacité temporelle, surtout lors du traitement de petits jeux de données tels que Blaesheim, GPS7 ou Chicago. Une caractéristique intéressante de notre approche est sa complexité, qui tend à être linéaire en fonction de l'augmentation du nombre de traces. Cette propriété contraste avec certains algorithmes dont la complexité évolue de manière exponentielle. Le Tableau 3.5 présente un résumé des temps d'exécution pour les algorithmes que nous avons réimplémentés. Selon ces résultats, notre méthode affiche des performances comparables à celles de l'approche de Guo et se distingue favorablement par rapport aux autres méthodes évaluées.

Les tests d'exécution ont été réalisés en utilisant Python 3.9 et Python 3.7 sur un ordinateur équipé d'un processeur Intel Core i9-10885h à 2,40 GHz et de 32 Go

de mémoire RAM. Cette configuration matériel et logiciel a permis une évaluation rigoureuse et représentative de la performance temporelle de chaque algorithme.

En général, les temps d'exécution sont plus longs lorsque l'ensemble de données d'entrée est Chicago. Cela est dû à son nombre beaucoup plus élevé de traces. Cependant, le nombre de traces n'est pas suffisant pour justifier les différences de performances entre les méthodes. Pour mieux comprendre ces inconstances, nous avons résumé les caractéristiques du jeu de données dans le Tableau 3.5. Ainsi, il est possible d'estimer quelle métrique de la longueur, du nombre de points ou du nombre de traces est proportionnelle au coût de chaque méthode. Par exemple, le temps d'exécution de la méthode de Cao [14] semble dépendre du nombre de points, alors que celui de Guo [32] semble dépendre davantage de la longueur totale. Notre méthode est influencée par le nombre de traces et par leurs longueurs.

3.4 Discussion

L'analyse des traces GPS représente un défi complexe qui exige une approche nuancée et adaptable. Cette étude cherche à évaluer l'efficacité des méthodes de clustering dans le traitement de telles données, en les comparant à des techniques de pointe, dont la méthode basée sur une carte de chaleur présentée par [32].

Les méthodes de clustering ont démontré leur compétitivité dans l'analyse des traces GPS. Notre contribution principale réside dans le développement d'une procédure de prétraitement efficace et la mise en place d'un mécanisme de segmentation basé sur une grille, réduisant le besoin de post-traitement. Cette approche novatrice promet une amélioration de la performance et une adaptabilité à différents jeux de données.

Conformément aux standards de l'état de l'art, notre étude a comparé notre méthode à d'autres techniques reconnues. Notre objectif était de vérifier l'efficacité de notre algorithme dans le traitement de terrains naturels. Nous avons constaté une adaptabilité remarquable de notre méthode à divers scénarios, allant des zones urbaines structurées, comme Chicago, à des territoires plus accidentés.

Cependant, notre étude fait face à des défis. La comparaison avec d'autres travaux est limitée par le manque de codes sources dans plusieurs études. De plus, bien que nos résultats initiaux sur des terrains accidentés soient prometteurs, ils ne satisfont pas encore pleinement aux exigences professionnelles, nécessitant ainsi des recherches supplémentaires pour gérer des volumes de données plus importants et des terrains variés. Un autre point critique de notre méthode est le nombre élevé de paramètres à ajuster en fonction du type de données, ce qui peut être perçu comme un inconvénient.

Bien que l'objectif soit de développer une méthode auto-adaptative capable de traiter différents types de données, des efforts supplémentaires sont requis. En outre, malgré les améliorations apportées dans le prétraitement, les données GPS présentent toujours des défis, tels que les motifs en losange typiques de ces données. Néanmoins, le potentiel des méthodes de clustering reste indéniable. Malgré les difficultés liées aux données bruitées et aux paramètres complexes, ces approches offrent des perspectives prometteuses qui méritent une exploration plus approfondie.

Conclusion

Dans le contexte de notre recherche sur la construction cartographique à partir de traces GPS, nous proposons un algorithme innovant qui se caractérise par son efficacité, sa modularité et sa facilité de mise en œuvre. L'aspect distinctif de cette méthode réside dans un regroupement stratégique des traces par l'application répétée d'une grille. Sa capacité à segmenter les données et sa compétence en matière de détection d'intersections la différencient des approches existantes. Comparativement à ces dernières, notre algorithme a montré une meilleure précision dans la détection des intersections et l'inférence de trajectoires à partir des traces GPS. Cette efficacité est due à l'analyse exhaustive des informations de trace, ainsi qu'à une capacité robuste à identifier et à corriger les erreurs.

Notre algorithme est particulièrement apte à traiter des segments de routes linéaires et des itinéraires sinueux, typiques des parcours de randonnée. Néanmoins, il présente certaines limitations, en particulier face à des données fortement perturbées, comme dans les cas où l'erreur GPS dépasse la taille des cellules de la grille ou lors de résolutions temporelles d'acquisition réduites. Malgré ces défis, l'un des avantages majeurs de notre méthode est sa simplicité d'application, ce qui la rend adaptée au traitement de grands volumes de données et la positionne comme un outil potentiellement utile pour des applications telles que la mise à jour automatique de cartes. Dans les sections suivantes, nous exposerons une technique capable de traiter les données brutes sans prétraitement nécessaire et avec moins de contraintes significatives en termes de paramétrage.

TABLE 3.3 Évaluation de la reconstruction des segments pour les jeux de données GPS7 à GPS12.

Données	Méthodes	Imprécision	Précision	Rappel	FScore
GPS7	Hashemi [34]	12.6m		0.94	
	Davies [21]	15.5m		0.78	
	Zhang [91]	4.5m		0.92	
	Edelkamp [25]	43.0m	0.30	0.34	0.32
	Cao [14]	35.1m	0.27	0.11	0.15
	Ahmed [5]	38.2m	0.72	0.36	0.48
	Kharita [72]	12.8m	0.49	0.78	0.60
	Guo [32]	9.3m	0.75	0.69	0.72
	Notre méthode	4.9m	0.91	0.94	0.92
GPS08	Hashemi [34]	12.8m		0.88	
	Davies [21]	15.5m		0.83	
	Zhang [91]	2.7m		1.00	
	Edelkamp [25]	39.5m	0.31	0.33	0.32
	Cao [14]	41.1m	0.27	0.11	0.15
	Ahmed [5]	34.4m	0.73	0.38	0.50
	Kharita [72]	12.2m	0.45	0.77	0.57
	Guo [32]	11.3m	0.91	0.59	0.71
	Notre méthode	3.1m	0.93	0.96	0.95
GPS09	Hashemi [34]	12.8m		0.90	
	Davies [21]	16.1m		0.75	
	Zhang [91]	6.7m		0.95	
	Edelkamp [25]	54.2m	0.27	0.34	0.30
	Cao [14]	57.5	0.27m	0.08	0.12
	Ahmed [5]	49.6m	0.73	0.31	0.44
	Kharita [72]	23.5m	0.58	0.60	0.59
	Guo [32]	19.1m	0.77	0.47	0.58
	Notre méthode	9.4m	0.75	0.86	0.80
GPS10	Hashemi [34]	12.0m		0.92	
	Davies [21]	15.9m		0.76	
	Zhang [91]	5.2m		0.89	
	Edelkamp [25]	53.1m	0.26	0.31	0.28
	Cao [14]	63.3m	0.34	0.08	0.13
	Ahmed [5]	46.1m	0.73	0.32	0.45
	Kharita [72]	18.2m	0.58	0.57	0.58
	Guo [32]	18.8m	0.83	0.44	0.58
	Notre méthode	8.3m	0.79	0.89	0.84
GPS11	Hashemi [34]	16.3m		0.80	
	Davies [21]	fail		fail	
	Zhang [91]	19.6m		0.74	
	Edelkamp [25]	86.6m	0.33	0.25	0.28
	Cao [14]	64.8m	0.41	0.07	0.12
	Ahmed [5]	68.1m	0.73	0.26	0.39
	Kharita [72]	77.4m	0.51	0.29	0.37
	Guo [32]	33.4m	0.48	0.43	0.46
	Notre méthode	28.1m	0.81	0.52	0.63
GPS12	Hashemi [34]	15.66m		0.80	
	Davies [21]	fail		fail	
	Zhang [91]	18.6m		0.74	
	Edelkamp [25]	84.3m	0.31	0.25	0.28
	Cao [14]	67.4m	0.37	0.06	0.10
	Ahmed [5]	64.3m	0.72	0.27	0.39
	Kharita [72]	65.7m	0.57	0.30	0.39
	Guo [32]	31.9m	0.49	0.42	0.46
	Notre méthode	26.8m	0.82	0.51	0.63

TABLE 3.4 Évaluation de reconstruction de segments sur le jeu de données de Blaesheim.

Méthodes	Imprécision	Précision	Rappel	FScore
Edelkamp [25]	34.8m	0.38	0.81	0.51
Cao [14]	4.9m	0.03	0.45	0.06
Ahmed [5]	24.2m	0.75	0.61	0.68
Kharita [72]	16.6m	0.42	0.73	0.53
Guo [32]	12.4m	0.94	0.86	0.91
Notre méthode	9.3m	0.82	0.95	0.88

TABLE 3.5 Temps d'exécution de chaque méthode pour les différents jeux de données (durée en secondes). Les caractéristiques de chaque jeux de données sont également répertoriées à des fins de comparaison.

Méthodes	Chicago	GPS7	Blaesheim
Edelkamp [25]	2181s	121s	67s
Cao [14]	4860s	43s	3744s
Ahmed [5]	198s	26s	1150s
Guo [32]	78s	11s	7s
notre méthode	75s	8s	13s
#traces	889	224	39
distances	3499km	367km	371km
#points	118364	7745	100009

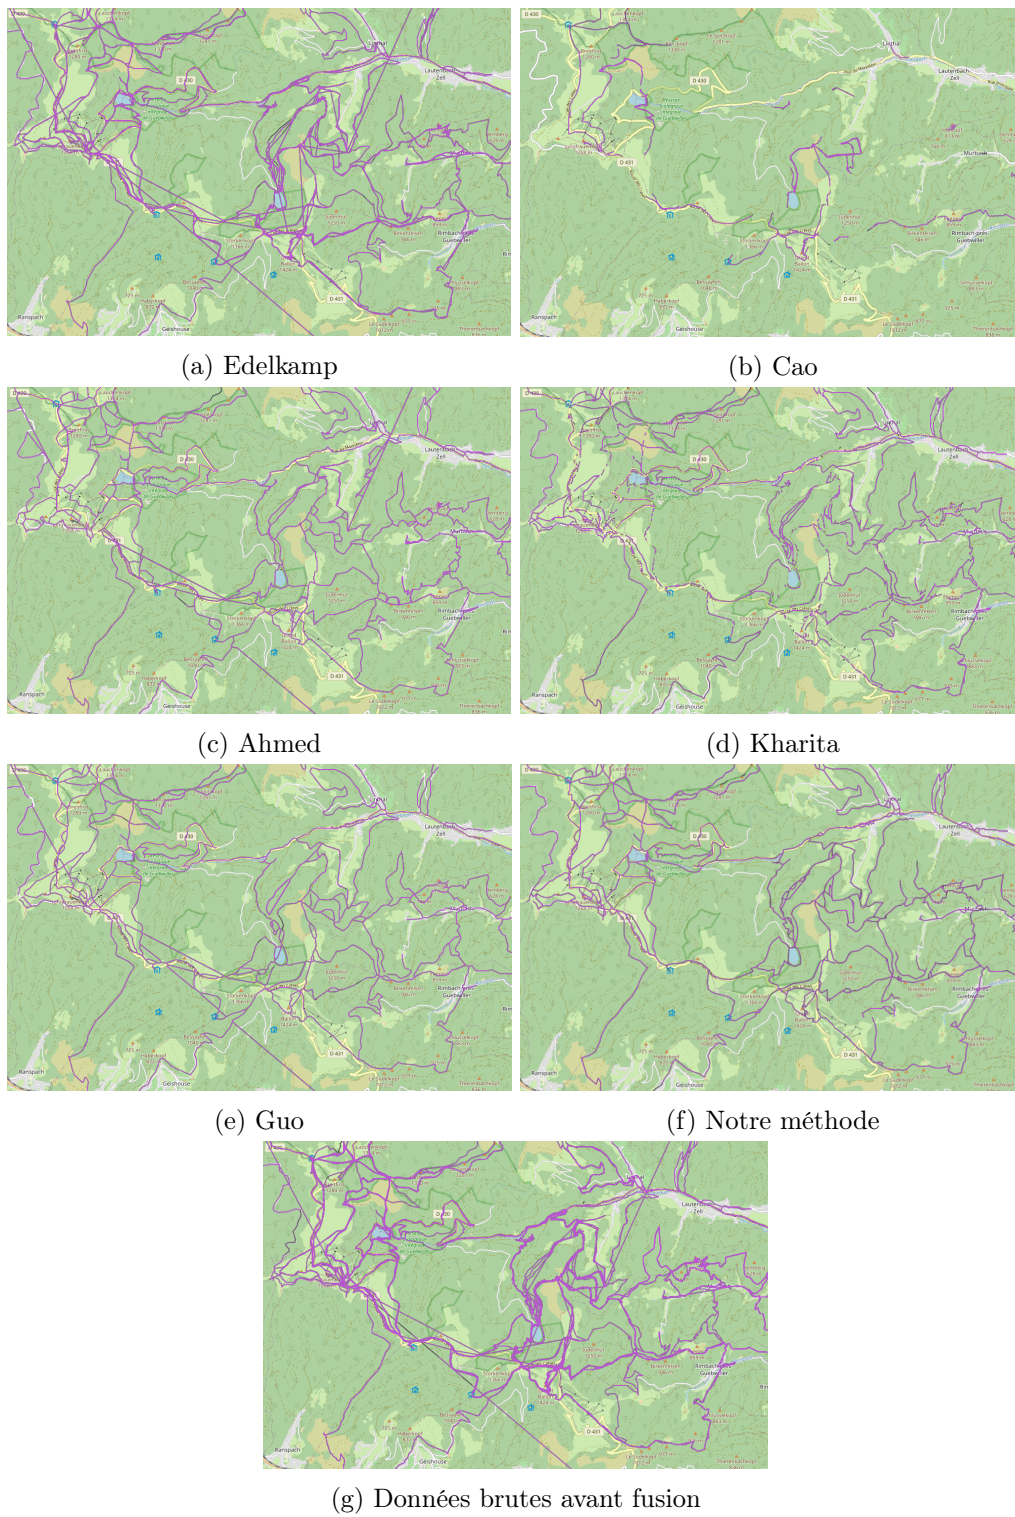


FIGURE 3.14 – Résultats visuels sur un jeu de données extrait de Visorando

Approche par extraction de ligne centrale

Introduction

Au chapitre précédent, nous avons présenté et développé une méthode de regroupement innovante, identifiant en même temps des opportunités d'amélioration. Devant ce potentiel, nous avons choisi d'explorer une approche moins conventionnelle dans notre secteur. Plutôt que de nous limiter aux méthodes traditionnelles de regroupement, nous avons exploré le domaine complexe de l'apprentissage profond. Cette orientation stratégique répond à deux motivations principales. Premièrement, compte tenu de la nature souvent bruitée et irrégulière des traces GPS, nous cherchions une méthode capable de gérer ce bruit de manière plus efficace. L'apprentissage profond, avec sa capacité d'auto-ajustement, nous est apparu comme une approche prometteuse pour minimiser l'impact du bruit, sans dépendre de techniques de prétraitement complexes. Deuxièmement, nous aspirions à développer une méthode universelle, indépendante au maximum de paramètres subjectifs, susceptibles de biaiser les résultats.

Toutefois, l'application de l'apprentissage profond à la fusion de traces GPS reste un domaine naissant. Nous avons constaté que les fondations existantes dans ce domaine n'étaient pas toujours suffisantes pour assurer une compréhension approfondie du comportement des réseaux de neurones lorsqu'ils traitent de telles données en entrée, nous amenant à réviser notre objectif initial. Notre nouvelle orientation vise non seulement à développer une technique innovante, mais aussi à établir des bases solides pour les recherches futures dans ce domaine. Dans les sections suivantes de ce chapitre, nous décrirons en détail le processus de conversion des données GPS brutes en un format adapté aux réseaux de neurones. Nous mettrons l'accent sur les aspects des données qui, d'après nos expérimentations, influencent le plus la performance des réseaux. Une exploration méthodologique sera présentée, exposant les étapes clés et les configurations optimales pour le traitement et l'interprétation des informations issues d'un réseau de neurones dans le cadre de la fusion de traces GPS.

4.1 Contexte

La fusion de traces GPS, et en particulier l'utilisation de techniques d'apprentissage profond, constitue un domaine de recherche en expansion dans la littérature scientifique actuelle. Plusieurs articles et études récents explorent diverses méthodes pour améliorer la précision et l'efficacité de cette fusion. Parmi les approches émergentes, certaines intègrent des images aériennes pour optimiser le processus de fusion. Cependant, après une analyse approfondie, nous avons décidé de ne pas utiliser ces informations dans notre méthode, pour des raisons que nous détaillerons ultérieurement.

Nos investigations ont révélé que nos objectifs initiaux, axés sur le développement d'une nouvelle méthode de fusion, nécessitaient d'être adaptés. Cette réorientation s'est imposée en raison de l'absence d'études exhaustives et rigoureuses, ainsi que des comparatifs de méthodes dans la littérature existante sur ce sujet spécifique. Par conséquent, nous avons choisi de rediriger nos efforts pour pallier ce manque. Notre recherche actuelle vise à intégrer les réseaux de neurones dans le domaine bien établi de la fusion de traces GPS. Cette démarche offre une perspective innovante et des approches potentiellement plus efficaces pour relever ce défi scientifique.

4.1.1 Émergence des techniques d'apprentissage profond pour la fusion de trace GPS

Notre examen du domaine de l'apprentissage profond appliqué à la fusion de traces GPS indique que cette problématique reste relativement peu explorée. La principale difficulté réside dans la représentation et la fusion complexes des séries temporelles, comme les traces GPS. Jusqu'à présent, aucune étude ne s'est concentrée sur l'utilisation directe de séries temporelles comme entrée pour de telles tâches. Les quelques tentatives existantes dans l'utilisation de l'apprentissage profond pour traiter ces données ont généralement converti les traces GPS en représentations bidimensionnelles, ce qui peut être considéré comme une forme de fusion.

Une étude de référence dans ce domaine est celle de [68], qui propose une méthode novatrice, DeepMG, pour générer des cartes routables à partir de trajectoires. Cette méthode se compose de deux modules principaux : la traduction géométrique, qui extrait les caractéristiques des trajectoires pour prédire les lignes centrales des routes, et la construction topologique, qui crée un graphe routier à partir de ces lignes centrales.

Une autre recherche pertinente [27] utilise un réseau neuronal convolutif U-net amélioré. Cette étude commence par le prétraitement des données de trajectoire pour les transformer en images raster, extrayant des caractéristiques telles que la vitesse et la direction, avant de les former avec une structure U-net améliorée. L'étude la plus récente au moment de nos travaux, [26], propose RING-Net, une méthode qui convertit également les données en images raster. Ces images, contenant des informations multibandes, servent d'entrée à un réseau de segmentation sémantique pour prédire la présence de routes. Nous avons décidé de ne pas se comparer aux approches de [83], car elle nécessite l'inclusion d'empreintes de bâtiments, ce qui ne correspond pas à notre cadre de recherche. De même, les méthodes de [84] et [41], basées sur des techniques non supervisées utilisant CycleGAN, diffèrent de

notre approche. Notre recherche se concentre sur le développement d'une méthode alternative, capitalisant sur les avancées actuelles tout en explorant de nouvelles avenues dans l'apprentissage profond pour la fusion de traces GPS.

4.1.2 Focus sur la donnée GPS

L'évolution récente dans le domaine de la construction automatique des cartes routières a été fortement influencée par l'avènement des techniques d'apprentissage profond. Un certain nombre d'études, notamment [94], [96] et [1], se sont concentrées sur l'utilisation des images aériennes pour cette tâche. D'autres recherches, telles que [74], [80], [50] et [49], ont opté pour une approche combinée, exploitant à la fois les données GPS et les images aériennes. Cette combinaison s'est avérée bénéfique pour améliorer la segmentation et l'inférence des routes, notamment par la superposition des données GPS avec des images aériennes.

Notre étude, en revanche, se concentre uniquement sur l'utilisation des données GPS, sans recourir à des images aériennes. Cette décision repose sur les limites inhérentes aux images aériennes, telles que les obstructions causées par des éléments naturels comme les forêts. Notre objectif est de traiter efficacement les données issues de l'application Visorando, qui couvre l'ensemble du territoire français, indépendamment du type de terrain, où l'utilisation d'informations aériennes peut être limitée.

Bien que les études centrées exclusivement sur les données GPS soient moins nombreuses, des recherches telles que [68], [27] et [26] ont prouvé que l'approche basée uniquement sur les données GPS est à la fois faisable et efficace. Ces travaux constituent des références clés pour notre recherche, et nous visons à apporter notre propre contribution à ce domaine émergent. Nous espérons enrichir le champ d'études en nous appuyant sur les avancées déjà réalisées et en explorant de nouvelles voies pour l'exploitation des données GPS dans la création de cartes routières automatiques.

4.1.3 Analyse critique des méthodologies existantes

Dans le cadre de notre examen approfondi de la littérature existante, nous avons détecté plusieurs lacunes notables liées à des aspects cruciaux de la recherche dans ce domaine. Nous avons relevé, en particulier, une absence de justifications explicites concernant le choix des données d'entrée, la conception des architectures neuronales et les protocoles d'évaluation utilisés. Bien que les sections ultérieures de ce chapitre soient dédiées à combler ces lacunes et à établir une méthodologie structurée pour les travaux futurs, il est impératif de souligner, dans cette section, l'impact de ces manques sur la reproductibilité des expérimentations et la possibilité de comparer les résultats des différentes approches.

4.1.3.1 Données d'entrée

Les données de la trace GPS, qui contiennent des informations géospatiales riches, enregistrent des coordonnées telles que la latitude et la longitude, associées à des instants temporels spécifiques. Dans le cadre de l'inférence basée sur les réseaux de neurones, l'état de l'art actuel met en évidence la conversion de ces données

brutes en plusieurs caractéristiques secondaires, apportant chacune des informations complémentaires. Parmi celles-ci, la vitesse, dérivée des paramètres de localisation et de temps, et l'orientation entre deux points successifs, fournissant des indications sur la trajectoire empruntée, sont particulièrement pertinentes. Le processus de calcul de ces caractéristiques sera détaillé dans la section 4.2. Cette section se propose de dresser un état des lieux des caractéristiques communément utilisées dans les recherches actuelles et d'explorer les raisons qui sous-tendent ces choix.

Eftelioglu et Al.[26] ont introduit une méthode de rasterisation utilisant 12 canaux distincts pour encoder des informations spécifiques aux trajectoires. Cette approche, centrée sur la densité de points, la vitesse moyenne, les variations de direction, l'accélération et la répartition des directions selon les huit points cardinaux, offre une analyse détaillée des comportements de conduite. La multiplicité des canaux suggère une tentative d'Eftelioglu [26] pour fournir une représentation exhaustive des caractéristiques des trajets.

Ruan [68], en revanche, met l'accent sur des éléments visuels tels que la carte de chaleur et le comptage des lignes. Sa méthode, bien que moins axée sur la multiplicité des canaux de données que celle d'Eftelioglu [26], se concentre sur l'utilisation de la vitesse comme indicateur principal pour l'identification de segments de route stables et l'orientation pour différencier les routes parallèles. Cette approche indique une priorité donnée à la simplicité et à la lisibilité des données.

Freng et al. [27] semblent adopter une voie médiane, combinant des éléments des méthodes d'Eftelioglu [26] et de Ruan [68]. En se concentrant sur des données de trajectoires basées sur des points individuels et des segments linéaires, ainsi que sur la vitesse et la direction dérivées, Freng [27] propose une approche qui vise à équilibrer la complexité et la clarté. Cette méthode semble viser une représentation complète des mouvements et comportements sans sacrifier la facilité d'interprétation. En cela, elle offre un compromis intéressant entre la richesse des données proposée par Eftelioglu et la simplicité visuelle de Ruan.

En conclusion, l'examen de la littérature existante révèle une préférence marquée pour des caractéristiques telles que la *carte de chaleur*, la *distance*, la *vitesse* ou l'*accélération* ainsi que l'*angularité* dans l'analyse des traces GPS. La fréquence de leur utilisation met en évidence leur pertinence perçue pour l'étude des données GPS. Cependant, il est à noter une carence de recherches expérimentales approfondies validant l'impact réel de ces caractéristiques sur la performance des modèles. Actuellement, les choix de ces caractéristiques semblent reposer davantage sur des hypothèses que sur des preuves théoriques, ou même empiriques, tangibles. Il apparaît donc important d'entreprendre une évaluation systématique de la contribution spécifique de chaque caractéristique afin d'optimiser efficacement la fusion des traces GPS via l'apprentissage profond. Cette démarche s'avère indispensable pour orienter nos futures recherches dans le domaine de la construction cartographique à partir de traces GPS.

4.1.3.2 Architecture du réseau de neurones

La fusion des traces GPS à l'aide de techniques d'apprentissage profond s'articule autour de deux phases essentielles : la préparation des données et l'élaboration de

l'architecture du réseau neuronal. Ayant abordé la sélection des données dans la section précédente, ce segment du document se penche sur les diverses architectures de réseaux de neurones utilisées dans les études existantes. Cette analyse vise à explorer les choix architecturaux spécifiques adoptés dans ces recherches, soulignant ainsi les tendances, les innovations et les défis associés à la conception de réseaux neuronaux pour l'analyse et la fusion des traces GPS. Cette démarche critique et méthodique vise non seulement à comprendre les stratégies actuelles mais aussi à identifier les opportunités d'amélioration et d'innovation dans ce domaine en expansion.

Ruan (2020) [68] Dans les travaux menés par Ruan [68], une architecture spécifique, nommée T2RNet, est introduite. L'évaluation de cette architecture a inclus des comparaisons avec des modèles reconnus tels que FCN et DeepLabV3+, qui se sont avérés moins performants en raison de limitations dans la reconstruction et la fusion des données. D'autres architectures basées sur un modèle encodeur-décodeur, notamment UNet, Linknet, et D-Linknet, ont montré de meilleurs résultats. T2RNet, améliorée par une tâche auxiliaire, a dépassé ces modèles en termes d'efficacité.

Freng (2020) [27] Dans l'étude de Freng [27], une version optimisée de l'architecture U-Net a été explorée. Cette version, appelée U-Net Plus, intègre des réseaux résiduels aux blocs de sous-échantillonnage pour prévenir l'overfitting et accélérer le processus d'entraînement. La comparaison entre U-Net et U-Net Plus a révélé que cette dernière offre des performances supérieures.

Eftelioglu (2022) [26] Dans l'approche RING-Net développée par Eftelioglu [26], l'architecture Dlinknet a été choisie pour sa performance élevée. Les auteurs ont intégré un mécanisme d'attention spatiale, visant à améliorer la contextualisation et la corrélation des caractéristiques à travers différentes zones. Toutefois, l'étude ne fournit pas de justification détaillée ou d'expérimentations pour étayer l'efficacité de cet ajout.

Dans le contexte de la cartographie automatique à partir de traces GPS en utilisant l'apprentissage profond, bien que l'architecture D-Linknet soit fréquemment recommandée, les justifications actuelles pour son adoption demeurent insuffisantes et nécessitent une évaluation plus approfondie. L'approche méthodologique adoptée par Ruan, qui consiste à comparer diverses architectures renommées spécifiquement pour cette tâche, est louable mais non exhaustive. Il existe une tendance dans la recherche actuelle à adapter ou modifier légèrement des architectures existantes pour répondre aux besoins spécifiques de la fusion de traces GPS. Toutefois, avant de procéder à de telles modifications, il serait plus rigoureux d'évaluer d'abord les performances des architectures standard dans leur forme originale pour cette application particulière.

4.1.3.3 Évaluation des méthodes

Dans le contexte de l'évaluation de méthodes de cartographie basées sur l'apprentissage profond à partir de traces GPS, la question de la reproductibilité et de la comparaison des résultats se pose de manière controversée. Eftelioglu (2022)

dans [26] souligne les défis de reproduire les résultats des études antérieures, notamment ceux de Biagioni et al. [13] et Ruan [68], en raison des variations dans les ensembles de données utilisés, certaines étant limitées géographiquement ou non disponibles publiquement. Plutôt que de voir ces défis comme insurmontables, les auteurs adoptent une approche alternative en se concentrant sur la comparaison avec les scores rapportés dans ces études. L'étude de [68] se distingue par sa comparaison des performances de son algorithme avec celles d'autres études réimplémentées. Cette démarche est similaire à celle que nous avons adoptée dans notre chapitre 3 avec notre méthode basée sur l'application multiple de grilles. Freng, en revanche, n'effectue pas de comparaison directe avec l'état actuel de la recherche [27]. Un point commun entre ces études est l'utilisation du jeu de données T-Drive pour les comparaisons. Cependant, compte tenu de la diversité des jeux de données disponibles, il semble insuffisant de se limiter uniquement à ce jeu de données. Il serait plus judicieux de diversifier les sources de données et surtout de mettre en place un cadre d'évaluation unifié, utilisant des métriques standardisées et des jeux de données communs pour toutes les études, afin de fournir une référence cohérente pour la communauté scientifique.

4.1.4 Contributions scientifiques

Le démarrage du travail sur l'apprentissage profond dans cette thèse s'est fait à mi-parcours. Après la première phase, il est devenu évident que les techniques basées sur les réseaux de neurones offraient un potentiel considérable, surpassant les performances des méthodes traditionnelles discutées dans ce manuscrit [68]. Bien que l'objectif initial fût de développer une nouvelle technique pour la fusion de traces GPS, une révision approfondie de la littérature récente a révélé des lacunes dans les méthodologies existantes, comme indiqué dans la section précédente 4.1.3. Cette découverte a conduit à une réorientation de la recherche. Au lieu de simplement appliquer les méthodes préexistantes, nous avons choisi de les examiner en détail, en fournissant les justifications et explications manquantes dans la littérature actuelle. Beaucoup de travaux actuels se concentrent sur des cas spécifiques, sans aborder en profondeur les principes fondamentaux. Aussi, nous nous proposons de réaliser une étude exhaustive des différents paramètres entrant en jeu lors de la construction de cartes à partir de données GPS. Nos contributions sur ce sujet sont structurées de la manière suivante :

- **Conduite d'expérimentations** pour identifier la meilleure combinaison de données à fournir au réseau de neurones, dans le but d'inférer des cartes routières les plus fidèles possibles à la réalité.
- **Développement de nouvelles caractéristiques** dérivées des traces GPS, destinées à améliorer les données d'entrée pour l'apprentissage du réseau de neurones.
- **Exploration approfondie** de l'architecture de réseau de neurones la plus appropriée pour cette tâche, en poursuivant les investigations initiées dans les travaux de Ruan [68].
- **Présentation des résultats obtenus**, mettant en lumière la meilleure combinaison et le formatage optimal des données, et soulignant l'importance cruciale de la phase de préparation des données.

- **Confirmation de nos découvertes** comme étant la méthode d'entraînement la plus efficace à ce jour pour cette application spécifique.
- **Établissement d'une méthodologie complète** pour la génération de cartes routières à partir de traces GPS.

4.2 Méthode

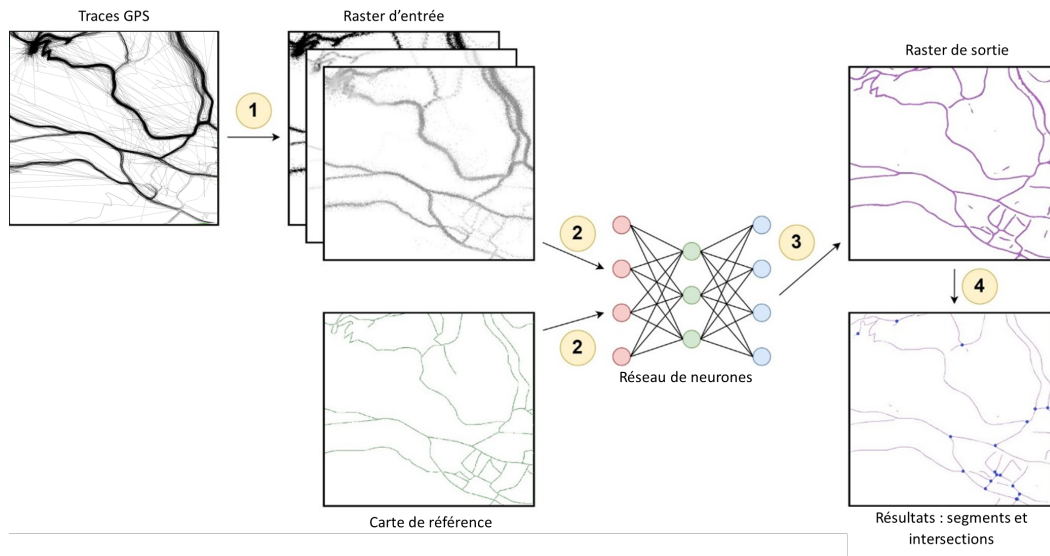


FIGURE 4.1 – Vue d'ensemble de notre approche : (1) conversion des données GPS vectorielle en images raster, (2) entraînement du réseau neuronal, (3) prédiction à partir du modèle, (4) conversion de la sortie du réseau en image vectoriel et extraction des intersections. Le format vectoriel est en vert et le format raster est en noir.

Cette section détaille une méthode novatrice pour le traitement des trajectoires GPS, visant à en extraire une représentation structurée en termes de segments, sous forme de graphe. Comme le montre le schéma sur la Figure 4.1, le processus se déroule en plusieurs étapes. La première consiste à transformer les données brutes de GPS en une image rastérisée, qui n'est pas une simple conversion mais une manière d'encoder diverses informations clés des trajectoires. La deuxième étape fait intervenir un réseau de neurones, formé sur ces données rastérisées enrichies, avec comme guide une carte de référence. Après cette phase d'apprentissage, le réseau génère une carte qui est convertie en un format vectoriel. Cette conversion est primordiale pour obtenir une représentation fidèle des itinéraires, notamment les segments et les intersections, formant ainsi un graphe.

Pour résumer, cette section sera organisée en sous-sections distinctes, chacune abordant un aspect spécifique de l'analyse des trajectoires. La première sous-section se concentrera sur la rastérisation des données de trajectoire GPS, une technique qui transforme les données de localisation en un format matriciel géoréférencé pour faciliter leur traitement. La deuxième sous-section détaillera la configuration et l'implémentation d'un réseau de neurones, exposant les méthodes employées pour en-

traîner le modèle à interpréter efficacement ces données rastérisées. Enfin, la dernière sous-section examinera le processus de reconversion des prédictions rastérisées du réseau de neurones en un format vectoriel.

4.2.1 Préparation des données

À ce jour, nous n'avons trouvé aucune étude ayant exploré la possibilité d'utiliser directement des séries temporelles, telles que les traces GPS, comme entrée pour un réseau de neurones dans le but de générer une série de points fusionnés représentant les données d'entrée opérant ainsi une fusion de traces GPS. Les méthodes courantes transforment systématiquement ces séries temporelles en images géoréférencées, souvent au format raster, qui est largement privilégié. Notre approche ne déroge pas à cette norme. Dans la section suivante, nous détaillerons comment nous avons optimisé cette conversion. En premier lieu, nous avons enrichi les traces GPS avec de nouvelles caractéristiques, qui ont permis par la suite de générer des informations supplémentaires lors de la création d'images.

4.2.1.1 Traces et caractéristiques

Cette introduction à la préparation des données vise à rappeler la définition d'une trace expliquée en introduction de ce manuscrit 1.2.1 et comment nous pouvons les enrichir pour contenir davantage d'informations qui seront utiles dans le reste de la méthode.

Soit $T = \{t_1, t_2, \dots, t_n\}$ une collection de traces GPS, où chaque trace t_i est une séquence de points GPS (**lat**, **lon**) telle que :

$$t_i = \{(\mathbf{lat}_{i,1}, \mathbf{lon}_{i,1}), (\mathbf{lat}_{i,2}, \mathbf{lon}_{i,2}), \dots, (\mathbf{lat}_{i,n}, \mathbf{lon}_{i,n})\}$$

La plupart du temps, les traces ont une troisième caractéristique désignée comme **temps** $_{i,j}$, qui est le moment précis lorsque le point a été enregistré. Si le temps est spécifié dans l'entrée, il est possible de calculer la vitesse et l'accélération dans une trace.

En comparant deux points consécutifs $p_{i,j-1} = (\mathbf{lat}_{i,j-1}, \mathbf{lon}_{i,j-1}, \mathbf{temps}_{i,j-1})$ et $p_{i,j} = (\mathbf{lat}_{i,j}, \mathbf{lon}_{i,j}, \mathbf{temps}_{i,j})$, la vitesse est la différence entre les positions des points et les temps :

$$\mathbf{vitesse}_{i,j} = \frac{\mathbf{distance}(p_{i,j-1}, p_{i,j})}{\Delta \mathbf{temps}(p_{i,j-1}, p_{i,j})}$$

En comparant ces deux points à un troisième, il est possible de calculer l'accélération :

$$\mathbf{accélération}_{i,j} = \frac{\Delta \mathbf{vitesse}(p_{i,j-1}, p_{i,j})}{\Delta \mathbf{temps}(p_{i,j-1}, p_{i,j})}$$

Nous pouvons également comparer deux points pour connaître la direction d'un point $\angle p_{i,j} p_{i,j+1}$. Les valeurs résultantes seront dans un intervalle $[-180; 180]$.

Enfin, à partir de ce calcul précédent, nous pouvons déduire une différence d'orientation entre les points avec l'équation suivante :

$$\angle p_{i,j} p_{i,j+1}^+ = \begin{cases} \angle p_{i,j} p_{i,j+1} + 360, & \text{si } \angle p_{i,j} p_{i,j+1} < 0 \\ \angle p_{i,j} p_{i,j+1}, & \text{sinon} \end{cases}$$

$$\Delta\angle p_{i,j} = \min \left(\left| \angle p_{i,j} p_{i,j+1}^+ - \angle p_{i,j-1} p_{i,j}^+ \right|, \left| 360 - \left| \angle p_{i,j} p_{i,j+1}^+ - \angle p_{i,j-1} p_{i,j}^+ \right| \right| \right)$$

4.2.1.2 Prétraitement

Pour améliorer la qualité et la fiabilité de l'analyse des trajectoires GPS, il est crucial de réduire le bruit initial présent dans les données T . Trois traitements sont utilisés pour cela.

Premièrement, nous appliquons une procédure pour supprimer les points GPS consécutifs ayant la même latitude et longitude, ce qui diminue la redondance pouvant affecter négativement la création des images par la suite.

Deuxièmement, un contrôle de distance est instauré pour détecter et éliminer les points dans la trace t_i où la distance entre deux points consécutifs excède 100 mètres. De telles variations importantes sont souvent le résultat d'erreurs GPS ou d'une perte de signal, et non de déplacements réels.

Enfin, nous imposons un filtre pour exclure les points dont la vitesse dépasse 10 km/h, afin de prévenir les impacts négatifs de sauts brusques de GPS sur une distance de 100 mètres sur l'analyse. Ces mesures contribuent à purifier les données GPS en amont de leur traitement, assurant ainsi une meilleure fiabilité des résultats d'analyse.

4.2.1.3 Canaux raster

Nous avons choisi le format raster pour deux raisons principales : c'est un format similaire à une image qui correspond parfaitement aux exigences d'entrée d'un réseau neuronal profond de type CNN, et il contient des informations de positionnement géographique. Comme nos sources de données sont initialement fournies au format vectoriel GPX, nous devons les convertir en raster. Nous visons à construire une image raster R de taille $W \times H \times C$, où W et H sont les dimensions de l'image, et C est le nombre de canaux. L'équation 4.1 montre comment calculer W et H à partir de T , avec r représentant la résolution choisie. L'équation 4.2 montre comment trouver la bonne position (x, y) dans R pour une latitude et une longitude données $(lat_{i,j}, lon_{i,j})$.

$$\begin{aligned} lon_{max} &= \max_{t_i \in T} \left(\max_{(lat, lon) \in t_i} (lon) \right) & lat_{max} &= \max_{t_i \in T} \left(\max_{(lat, lon) \in t_i} (lat) \right) \\ lon_{min} &= \min_{t_i \in T} \left(\min_{(lat, lon) \in t_i} (lon) \right) & lat_{min} &= \min_{t_i \in T} \left(\min_{(lat, lon) \in t_i} (lat) \right) \end{aligned} \quad (4.1)$$

$$W = \left\lceil \frac{lon_{max} - lon_{min}}{r} \right\rceil \quad H = \left\lceil \frac{lat_{max} - lat_{min}}{r} \right\rceil$$

$$\begin{aligned} x &= \left\lfloor \frac{lon_{i,j} - lon_{min}}{r} \right\rfloor \\ y &= \left\lfloor \frac{lat_{i,j} - lat_{min}}{r} \right\rfloor \end{aligned} \quad (4.2)$$

Cette section donne un aperçu complet des différents canaux d'entrée couramment trouvés dans la littérature existante, ainsi que nos nouvelles contributions.

Le canal le plus simple à calculer est le **1.Binaire**, où pour chaque $p_{i,j} \in t_i \in T$ la position respective dans $R(x, y)$ sera égale à 1. Ce canal a été utilisé par [90] dans leur approche aérienne, mais n'a jamais été utilisé dans une approche basée uniquement sur la trajectoire GPS.

2.Carte de chaleur est le canal le plus utilisé [26, 68, 27, 74] et est calculé en comptant le nombre de points à chaque position.

Comme montré dans la Section 4.2.1.1, selon la présence d'un timestamp, nous pouvons calculer la distance, la vitesse, et l'accélération en comparant les points.

3.Distance, **4.Vitesse** [26, 68, 27] et **5.Accélération** [26] peuvent ensuite être construits en faisant la moyenne des valeurs de chaque caractéristique pour chaque position (x, y) dans R .

Pour les deux canaux suivants, nous avons supposé que la prise en compte de l'altitude dans notre ensemble de données serait utile, étant donné qu'elle affecte clairement le comportement de nos traces d'entrée T . Nous avons ainsi ajouté **6.Altitude**, qui est une extraction du Modèle Numérique de Terrain (MNT) d'un site web de Géoservice français¹ et **7.Pente**, qui est calculé sur la base des données du MNT. La pente représente l'inclinaison du terrain à chaque position (x, y) .

Les 10 canaux restants sont axés sur les angles entre les points. En calculant $\angle p_{i,j} p_{i,j+1}$, nous pouvons construire **8-15.Direction** [26, 68, 27], la proportion de points se dirigeant vers les huit cardinaux possibles. Par exemple, si 15% des points se dirigent vers l'est pour un (x, y) donné, alors le canal Est sera égal à 0.15.

Nous avons également introduit **16.Diversité directionnelle** qui mesure l'imprévisibilité des directions à partir d'une position (x, y) en utilisant des calculs d'entropie sur les huit directions cardinales possibles. L'entropie, notée E , est calculée comme suit :

$$E(x, y) = - \sum_{p_{i,j} \in (x,y)} \angle p_{i,j} p_{i,j+1} \cdot \log_2(\angle p_{i,j} p_{i,j+1})$$

où la somme est sur toutes les proportions non nulles $\angle p_{i,j} p_{i,j+1}$ pour chaque direction. Enfin, nous avons recréé le **17.Différence de Direction** de [26], qui est la moyenne de chaque différence de direction $\Delta \angle p_{i,j}$ pour chaque point à une position (x, y) . La Figure 4.2 donne un aperçu visuel des différents canaux calculés à partir des traces GPS.

4.2.2 Entraînement et prédictions d'un réseau de neurones

Cette section se consacre aux processus nécessaires pour la préparation et l'entraînement d'un réseau neuronal dédié à la segmentation sémantique d'images. Les étapes clés incluent le traitement préliminaire des données, telles que la segmentation, la normalisation et l'augmentation des données. L'importance d'avoir une donnée de référence de haute précision pour l'entraînement du modèle est également mise en évidence. Un point central de cette discussion sera le choix d'une fonction de coût adéquate, essentielle pour optimiser les performances du modèle. Enfin, nous examinerons la méthode de conversion des prédictions du modèle en un format

1. <https://geoservices.ign.fr/telechargement>

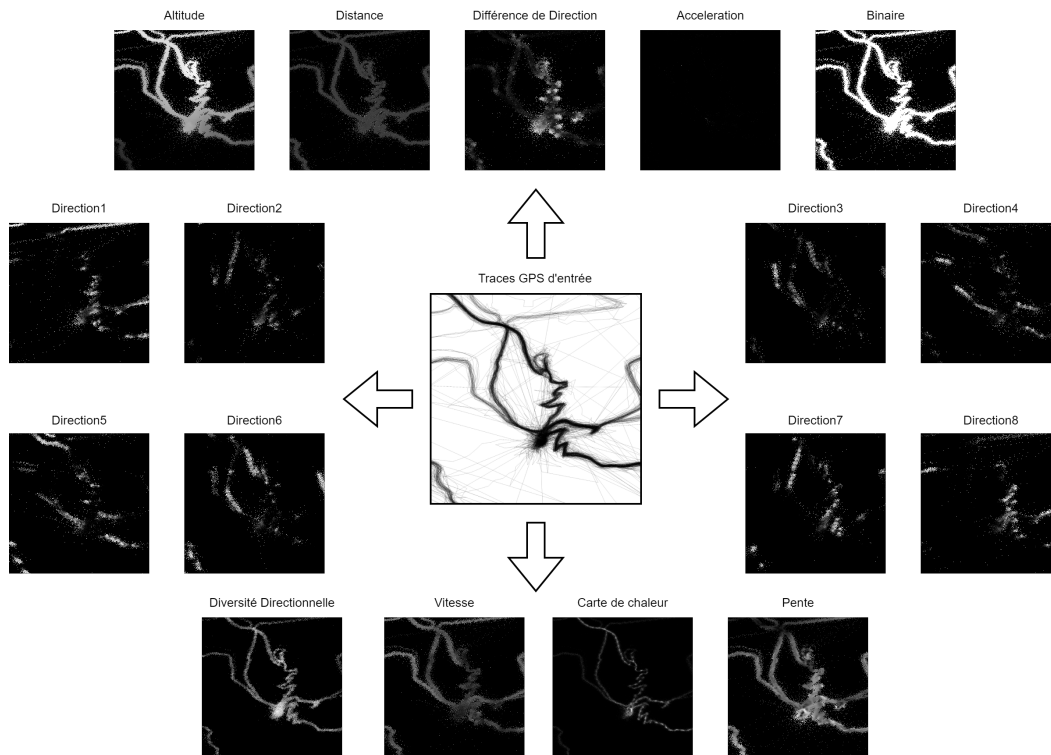


FIGURE 4.2 – Illustration des différents canaux d’entrée pour l’analyse des trajectoires GPS.

pratique pour des utilisations futures. Cette introduction servira de base pour comprendre les composantes fondamentales impliquées dans l’entraînement d’un réseau neuronal pour la segmentation sémantique dans des applications de cartographie.

4.2.2.1 Préparation des données d’entrée : découpage, normalisation et augmentation

Avant l’entraînement du réseau de neurones, un prétraitement des données est nécessaire. Cette étape implique la division des données en segments d’image, appelés **patches**, de dimensions uniformes pour répondre aux exigences de format des réseaux de neurones. La taille de ces **patches** varie selon la technique employée, avec des dimensions fréquemment utilisées telles que 256×256 ou 512×512 pixels. Ces dimensions sont choisies pour s’aligner avec les architectures de réseau qui comportent un nombre variable de couches de réduction dimensionnelle. Suite à cette segmentation, une étape cruciale de normalisation est effectuée. Elle implique l’ajustement des valeurs de tous les canaux de l’image à une échelle minimum-maximum. Ce processus est crucial pour assurer l’uniformité à travers l’ensemble de données, rééquilibrant les valeurs dans une plage allant de 0 à 1. Cette normalisation garantit une cohérence des données alimentées au réseau, facilitant ainsi le processus

d'apprentissage.

La **normalisation** au minimum-maximum est un procédé important en traitement d'image et en apprentissage profond, car elle permet de mettre toutes les valeurs des pixels sur une échelle commune, améliorant ainsi la stabilité et la performance du modèle d'apprentissage. Cette technique consiste à soustraire la valeur minimale de l'ensemble de données à chaque valeur individuelle, puis à diviser le résultat par la différence entre les valeurs maximale et minimale. L'équation de cette transformation est la suivante :

$$V_{\text{normalisé}} = \frac{V - V_{\min}}{V_{\max} - V_{\min}} \quad (4.3)$$

où

- V est la valeur d'origine du pixel appartenant à un canal d'un patch,
- V_{\min} et V_{\max} sont respectivement les valeurs minimale et maximale de l'ensemble des pixels du canal du patch choisi,
- $V_{\text{normalisé}}$ est la valeur normalisée du pixel, se situant dans l'intervalle $[0, 1]$.

Cette transformation assure que toutes les valeurs de pixels contribuent de manière équitable à l'apprentissage du modèle, ce qui est crucial pour obtenir de bonnes performances, en particulier lorsque les données d'origine peuvent avoir des échelles très différentes.

En ce qui concerne l'**augmentation des données**, permettant d'étendre les ensembles de données d'apprentissage en y ajoutant des données générées à partir de l'ensemble de départ, nous mettons en œuvre deux types d'augmentations. Tout d'abord, nous introduisons une technique originale qui vise à générer plusieurs ensembles de données (et la vérité terrain associée) à différentes résolutions. Ceci est rendu possible car les données initiales sont sous format vectoriel. Les canaux raster contiendront nécessairement des informations différentes, à condition que les résolutions choisies soient suffisamment distinctes. Nous utilisons également une technique classique d'augmentation des données par rotation des images, qui nous permet de quadrupler la taille de notre ensemble de données en faisant pivoter les patches de 90, 180 et 270 degrés. Ici, seule la rotation à angle droit est possible si on souhaite conserver la valeurs initiales des pixels sans avoir à en rajouter. Dans la même logique nous ne souhaitons pas intégrer à notre protocole des augmentations de données impliquant la modification des valeurs de pixels puisque l'information contenue doit rester la même dans tout l'ensemble de données. Pour illustrer, prenons l'exemple d'une augmentation qui augmenterait le contraste d'un patch. Une telle modification entraînerait une variation dans le nombre de points par pixel sur la **2. Carte de chaleur**. Cela signifierait que les valeurs représentées sur cette carte ne seraient plus uniformément comparables à travers l'ensemble du jeu de données, brisant ainsi la cohérence nécessaire pour un apprentissage efficace et précis par le modèle en plus de perdre la véritable information sur le passage des utilisateurs. Il est donc essentiel de maintenir une constance dans les valeurs de pixels pour assurer la fiabilité et l'intégrité des données utilisées dans l'apprentissage.

4.2.2.2 La donnée de référence ou vérité terrain.

Dans le cadre de l'apprentissage automatique, l'accès à des jeux de données de référence précis et de haute qualité est primordial pour le développement d'un modèle performant. Durant notre recherche, nous avons identifié des défis liés à l'alignement des données de vérité terrain, souvent issues de sources traditionnelles comme OpenStreetMap (OSM), avec les données que nous avons utilisées. Comme illustré dans la Figure 2.5 du Chapitre 2 sur l'évaluation, il existe des discordances entre les pixels représentant les traces GPS et la carte de référence OSM, suggérant une superposition imparfaite. Un alignement précis entre les données d'entrée et la référence est important pour un modèle basé sur un réseau de neurones, afin de recalculer efficacement les poids lors de la rétropropagation.

Face à ces constatations, nous avons décidé de ne pas utiliser les données OSM, partielles ou complètes, en raison de leur inadéquation potentielle avec nos besoins. Les cartes OSM pourraient omettre certains segments utilisés par les randonneurs de Visorando, segments essentiels à notre objectif de générer une carte enrichie de nouvelles routes inconnues des cartes publiques. Afin de surmonter ces limitations, mentionnées dans la Section 2.1.2.4, nous avons opté pour une méthode d'annotation manuelle, visant à créer une carte spécifiquement conçue pour les besoins des randonneurs et intégrant ces segments inédits [50]. Cette approche d'annotation manuelle vise à fournir un « vecteur de vérité » très précis, permettant au modèle de généraliser efficacement à partir des données d'apprentissage et d'améliorer ses capacités de prédiction face à de nouvelles données. Nous sommes convaincus que cette méthode assure une représentation fiable des données pour le réseau de neurones, contribuant ainsi à minimiser les erreurs de présentation, à l'exception des erreurs humaines potentielles lors de l'annotation.

4.2.2.3 La fonction de coût ou de perte

La fonction de coût, ou fonction de perte, joue un rôle essentiel dans l'entraînement des modèles d'apprentissage automatique. Elle évalue l'écart entre les prédictions du modèle et les données réelles, avec pour but de le réduire afin d'optimiser la précision du modèle. Dans le contexte de la segmentation sémantique, le choix d'une fonction de coût appropriée est d'une importance capitale, car il doit répondre aux particularités de la tâche, notamment le déséquilibre des classes et la nécessité d'une précision au niveau du pixel.

Parmi les fonctions de perte, la fonction Dice [73] est fréquemment utilisée dans notre domaine, comme le montrent les études de [68] et [27]. Nous avons décidé de suivre cette tendance de l'état de l'art, tout en envisageant une exploration plus approfondie de ses applications spécifiques dans le futur. La fonction Dice est utilisée pour comparer la similitude entre deux échantillons de données. Dans notre cas, Y_{ref} représente l'image de référence en format binaire, illustrant les segments et intersections, tandis que Y_{pred} désigne la prédiction du modèle, avec des valeurs de pixels fluctuant entre 0 et 1. Le Coefficient Dice (CD) est calculé selon la formule suivante :

$$DC = \frac{2|Y_{ref} \cap Y_{pred}|}{|Y_{ref}| + |Y_{pred}|} \quad (4.4)$$

où Y_{ref} et Y_{pred} sont respectivement l'image de référence et la prédiction. Cette formule permet de mesurer l'overlap entre la prédiction du modèle et la référence, en accordant une attention particulière à la précision et à la pertinence des prédictions sur les segments et intersections. En maximisant le Coefficient Dice, nous cherchons à affiner la précision de notre modèle dans la segmentation des itinéraires GPS.

La perte Dice est ensuite calculée comme $PD = 1 - DC$. Cette fonction de perte est particulièrement utile pour traiter les déséquilibres entre les classes, en mettant l'accent sur une détection précise des pixels des objets d'intérêt et en pénalisant les faux positifs.

4.2.3 Conversion d'une image raster résultat en graphe

Après l'entraînement, notre modèle est apte à prédire des images de taille définie, par exemple 256×256 pixels. Pour analyser une zone géographique complète avec ce modèle, il est donc nécessaire de diviser le raster complet en multiples fragments (patches) de cette taille. Nous avons constaté une diminution des performances du modèle, particulièrement aux bords des patches prédits. Pour remédier à cela, nous avons choisi de ne prendre en compte que la partie centrale de chaque patch, en excluant une marge de 20 pixels sur chaque bord.

Notre processus de division des données en patches assure que chaque section de la zone géographique est prédite à plusieurs reprises. Les patches sont sélectionnés tous les 64 pixels ($256/4$) et sont ensuite assemblés dans un raster vierge, correspondant aux dimensions du raster d'origine (la zone complète). Ce processus de prédiction et de fusion des patches est illustré dans la Figure 4.3.

Après avoir réalisé les prédictions, nous appliquons l'algorithme de conversion d'image en niveaux de gris en squelette, tel que décrit dans [77], afin d'extraire les lignes centrales des routes. La dernière étape consiste à convertir ce raster en un format vectoriel, à partir duquel nous pouvons déduire les segments et les intersections. Cette segmentation est réalisée en utilisant l'algorithme que nous avons développé dans nos travaux antérieurs sur la fusion de traces GPS par applications multiples de grilles, présenté dans la section 3.2.3 de notre thèse. Cette démarche de segmentation permet de finaliser le processus de conversion des données prédites par le réseau de neurones en une représentation structurée et utilisable des itinéraires.

4.3 Résultats, analyse et perspectives

4.3.1 Cadre et configuration des expériences

4.3.1.1 Plan d'expérimentation : une stratégie d'exploration progressive

La qualité des résultats obtenus par un réseau de neurones est fortement influencée par les données qui lui sont fournies. Reconnaissant cette importance, nous avons décidé de porter une attention particulière aux données d'entrée en début de notre étude. Notre but était de déterminer quelles informations seraient les plus bénéfiques à fournir à un réseau de neurones pour optimiser les résultats. Jusqu'à présent, cette question n'avait pas été suffisamment explorée dans la littérature.

Dans notre recherche, nous avons choisi d'utiliser UNet, une architecture de réseau de neurones convolutif très réputée [65], comme point de départ. Pour enri-

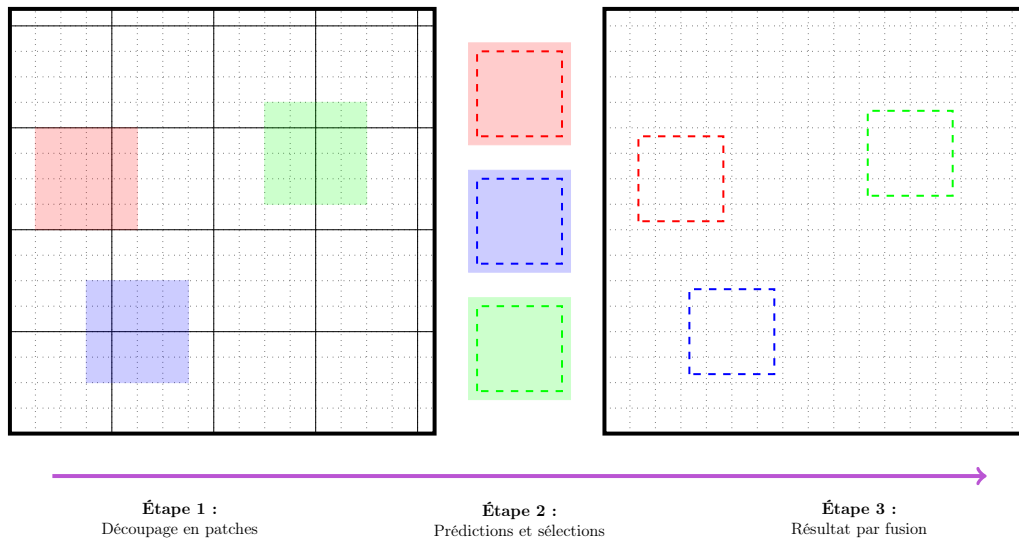



FIGURE 4.3 – Illustration du processus de prédiction et de fusion d’images avec chevauchement des patches.

chir notre étude, nous avons également examiné d’autres architectures de réseaux de neurones convolutifs largement utilisées. Parmi celles-ci figurent ResUNet [36], DeepLabV3Plus [18], HRNet [78], DLinkNet [94], SegNet [11], DenseNet [39], et Inception [62].

L’objectif de cette analyse comparative n’était pas seulement de sélectionner l’architecture la plus adaptée pour notre tâche spécifique, mais aussi de comprendre si certaines architectures avaient une préférence pour certains types d’informations d’entrée. En d’autres termes, nous voulions savoir si une combinaison particulière d’informations d’entrée serait plus efficace avec une architecture spécifique qu’avec une autre. Cela nous aiderait à mieux comprendre les interactions entre les caractéristiques des données et les architectures de réseaux de neurones, et à affiner notre approche pour optimiser les performances du réseau dans notre tâche de fusion de traces GPS.



4.3.1.2 Constitution du jeu de donnée

Notre étude se focalise sur l’exploitation des données provenant de la base Visorando, comprenant des traces GPS collectées par les utilisateurs lors de leurs randonnées, en utilisant divers dispositifs tels que des montres et smartphones. Les données sont extraites directement de cette base, pour lesquelles nous avons constitué et étiqueté six jeux de données distincts. Chacun de ces ensembles couvre différentes zones de l’Alsace en France, région choisie pour sa proximité avec le siège de Visorando, ce qui nous offre une connaissance directe du terrain.

Comme indiqué dans le Tableau 4.1, nous avons veillé à diversifier les types de terrains dans nos jeux de données d’entraînement. Cette diversité est cruciale, car elle reflète la variabilité des comportements de traces GPS, rendant ainsi le processus d’entraînement plus exigeant. Par exemple, les comportements des randonneurs en montagne diffèrent considérablement de ceux évoluant dans des zones planes.

Il est important de noter que limiter notre étude à la région alsacienne pourrait influencer la capacité du modèle à généraliser ses prédictions à d’autres régions en France ou dans le monde. Toutefois, l’objectif principal est d’établir une méthodologie solide pour l’entraînement de modèles destinés à l’inférence de cartes basées sur les traces GPS. L’ambition est de fournir à la communauté scientifique une base sur laquelle s’appuyer pour adapter ces concepts fondamentaux à d’autres jeux de données, potentiellement plus vastes en termes de diversité géographique et de taille.

TABLE 4.1 Description de tous les ensembles de données utilisés dans les expériences de ce chapitre

Ensemble de données	Nombre de traces	Terrain	Nombre de patches par tailles						Utilisation
			192	256	320	384	448	512	
Labaroche	292	montagne	1060	652	436	320	248	208	Entraînement
Hunawilhr	183	vignoble	708	428	292	224	180	144	
Linthal	3509	montagne	4636	3372	2284	1616	1216	956	
Blaesheim	137	plaine	1108	688	480	360	284	220	
Haguenau	1676	plaine	7408	4536	2068	2248	1684	1336	
Total	5797	vignoble	14920	9676	5560	4768	3612	2864	
Ribeauville	2519	vignoble	232	132	85	56	42	33	Test

Nos expérimentations sont structurées autour de divers types de terrains : environ 55% de terrain plat, 40% de montagneux, et 5% de vignoble, ce dernier combinant des caractéristiques de terrain plat et montagneux. Nous avons sélectionné les ensembles de données de Blaesheim, Hunawilhr, Labaroche, Haguenau et Linthal pour l’entraînement et la validation de notre modèle, tandis que l’ensemble de Ribeauvillé est dédié exclusivement aux tests, garantissant ainsi qu’aucune donnée de test n’ait été utilisée durant l’entraînement. Il est important de noter que, dans notre domaine, nous évaluons nos modèles sur la carte générée d’une zone de plusieurs kilomètres, rendant une évaluation par patche obsolète. Un patche est trop petit pour représenter un ensemble de segments et d’intersections d’un ordre de grandeur similaire à ceux évalués dans la littérature. Nous ne pouvons donc pas créer un ensemble de données pour Blaesheim, Hunawilhr, Labaroche, Haguenau, Linthal et Ribeauvillé, et tester nos modèles sur 20% des patches de cet ensemble, bien que cette pratique soit plus courante.

Pour augmenter nos données d’entraînement, nous avons employé des techniques de rotation et de génération multi-résolutions, comme décrit dans la Section 4.2.2.1. Nous avons travaillé avec des résolutions de 2,2 m, 2,7 m et 3,1 m. Il est important de noter que le nombre de patches pour l’ensemble de test est moins élevé, car ces données n’ont pas été soumises à l’augmentation. Comme le montre le Tableau 4.1, le nombre d’images d’entraînement diminue de 14 920 (pour une taille de patch de 192) à 2 864 (pour une taille de patch de 512). Cependant, nous estimons que même le nombre réduit d’images devrait suffire à minimiser l’impact sur les résultats de l’expérience.

4.3.1.3 Configuration et environnement d'entraînement

Dans notre mise en œuvre, nous avons adopté la technique de l'arrêt précoce, utilisant le callback *EarlyStopping* de TensorFlow, pour contrôler le surapprentissage et améliorer la généralisation du modèle sur de nouvelles données. Ce callback surveille la perte de l'ensemble de validation durant l'entraînement, avec une patience fixée à 5 époques, signifiant que l'entraînement s'arrête si aucune amélioration n'est observée sur la perte de validation pendant 5 époques consécutives. En outre, le callback restaure les poids du modèle à ceux ayant obtenu les meilleurs résultats sur l'ensemble de validation, assurant ainsi la performance optimale du modèle.

L'usage de l'arrêt précoce a permis de réduire le temps d'entraînement tout en garantissant une bonne généralisation. Nous avons ainsi fixé le nombre d'époques à 200, avec un lot de 4 images (`batch_size`), et une répartition de 80% des données pour l'entraînement et 20% pour la validation.

L'entraînement de nos réseaux a bénéficié des ressources du Centre de Calcul de l'Université de Strasbourg (CCUS), l'un des centres de calcul régionaux les plus avancés en France. Ce centre dispose d'une infrastructure impressionnante, avec 13,600 cœurs de processeur, 68 To de mémoire vive, 2,6 Po de stockage, et plus de 290 accélérateurs GPU. La puissance de calcul disponible nous a permis de multiplier par dix chaque entraînement nécessaire pour notre expérience et de calculer une moyenne des résultats, réduisant l'aléatoire inhérent aux réseaux de neurones. Cette démarche a significativement augmenté nos capacités de calcul et nos possibilités d'expérimentation.

4.3.1.4 Rappel de la stratégie d'évaluation

Dans le cadre de notre recherche, l'évaluation des résultats, décrite en détail dans la section 2.4.1, a été conduite en utilisant diverses métriques spécifiquement adaptées à notre méthode. Notre approche s'écarte des méthodes traditionnelles d'abstraction de route et se concentre sur l'utilisation de la métrique TOPO, révisée pour s'aligner avec les méthodes modernes basées sur l'imagerie et les réseaux de neurones, et adaptée au format raster. Cette adaptation permet d'évaluer les segments en réduisant l'impact des déconnexions, tout en fournissant une évaluation détaillée des performances de notre modèle à travers des métriques telles que la Précision, le Rappel et le FScore.

Notre évaluation prend également en compte les intersections et la connectivité. Pour les intersections, nous avons comparé les intersections annotées sur la carte de référence avec celles générées par notre modèle, en utilisant un seuil de distance prédéfini. Cette comparaison nous a permis de calculer le FScore pour mesurer la qualité des intersections. En ce qui concerne la connectivité, nous avons incorporé une métrique spécifique, ITOPO, pour examiner si les segments détectés sont interconnectés de manière similaire à ceux de la carte de référence.

L'inclusion de ces deux aspects cruciaux dans notre système d'évaluation renforce la pertinence et la fiabilité de notre analyse, en fournissant une compréhension globale de la performance du modèle sur plusieurs niveaux.

4.3.2 Apport des données d'entrée

Cette section débute notre exploration approfondie de l'utilisation de l'apprentissage profond pour la fusion de trajectoires GPS. Notre objectif est d'identifier la combinaison optimale de données d'entrée pour un réseau de neurones convolutif, en l'occurrence UNet, afin d'améliorer, si possible, les performances par rapport aux approches antérieures dans ce domaine. Notre processus est divisé en trois phases principales.

La première phase se concentre sur l'identification des informations les plus pertinentes et utiles pour le réseau. Nous avons examiné diverses caractéristiques et avons sélectionné 17 canaux raster différents, qui incluent des données issues de la littérature existante ainsi que nos propres ajouts, comme détaillé dans la sous-section 4.2.1.3.

La deuxième phase consiste à tester diverses combinaisons de ces informations pour déterminer celles qui produisent les meilleurs résultats. Cette expérimentation vise à évaluer l'efficacité de chaque combinaison en termes de performance du réseau de neurones. Les résultats sont présentés en sous-section 4.3.2.2.

Finalement, les résultats obtenus avec la meilleure combinaison est comparé avec des configurations utilisées dans des études précédentes de l'état de l'art. Ces résultats sont données en sous-section 4.3.2.3.

En optant pour UNet, nous avons choisi une architecture de réseau éprouvée et largement appréciée pour la segmentation d'images. Notre choix s'appuie sur la réputation et l'efficacité prouvée de ce réseau dans des tâches similaires, tout en restant ouverts à l'exploration d'autres architectures potentielles à l'avenir.

En résumé, notre démarche méthodique et structurée vise à maximiser la pertinence des données fournies au réseau de neurones, afin d'optimiser l'inférence de cartes à partir de traces GPS. Nos expérimentations et analyses sont guidées par le désir d'innover et d'améliorer continuellement les techniques de fusion de trajectoires GPS grâce à l'apprentissage profond.

4.3.2.1 Évaluation des 17 canaux

Pour identifier la combinaison de canaux la plus efficace pour notre réseau de neurones, nous avons initié une étude systématique dans la première phase de notre recherche. Nous avons commencé par entraîner le réseau de neurones en utilisant un ensemble complet de 17 canaux d'information disponibles 4.2.1.3. Cette approche exhaustive nous a permis de comprendre l'influence globale de l'ensemble des canaux sur les performances du modèle.

Ensuite, nous avons entrepris une série de 18 expériences de prédiction. La première expérience a utilisé les données brutes sans altération. Pour les 17 expériences suivantes, nous avons introduit des perturbations ciblées, une pour chaque canal. Ces perturbations consistaient à mélanger aléatoirement les pixels d'un canal spécifique, tout en maintenant l'intégrité des pixels des 16 autres canaux. Cette méthode de permutation a été appliquée successivement à chaque canal, résultant en 17 ensembles de données modifiés.

L'idée sous-jacente est que si un canal est particulièrement important pour le réseau, le désordre aléatoire de ses données entraînerait une baisse notable de la performance du modèle. Ainsi, en comparant les résultats de ces prédictions pertur-

bées, nous pouvons déduire l'importance relative de chaque canal. L'effet de chaque perturbation sur les performances du modèle offre un indicateur de l'impact du canal correspondant.

Cette méthode nous permet d'identifier de manière empirique les canaux qui sont les plus critiques pour la précision et l'efficacité du réseau de neurones, et donc de concentrer nos efforts sur l'optimisation de ces canaux particuliers dans les phases ultérieures de notre recherche.



FIGURE 4.4 – Moyenne des FScores pour les intersections (FINT), les segments (FTOP) et la connectivité par canal (FITO), *Base* étant la référence sans mélange de canal.

L'analyse des résultats de notre première expérience, illustrée dans la Figure 4.4, a révélé l'importance cruciale de trois canaux spécifiques pour notre réseau de neurones basé sur UNet. Parmi eux, **4.Vitesse** s'est avéré être le canal le plus significatif, influençant fortement toutes les métriques évaluées. Les canaux **1.Binaire** et **2.Carte de chaleur** ont également montré un impact notable, bien que leur

importance varie en fonction de la métrique spécifique.

Il est apparu que le canal **2.Carte de chaleur** joue un rôle clé dans l'identification des intersections et des segments, tandis que le canal **1.Binaire** est essentiel pour assurer une meilleure connectivité. Ces résultats suggèrent que les autres canaux, initialement inclus dans notre ensemble de 17 canaux, peuvent ne pas être nécessaires pour la segmentation sémantique. Leur élimination pourrait même améliorer la qualité globale des résultats, tout en réduisant les temps d'entraînement et de prédiction du modèle.

4.3.2.2 Optimisation de la combinaison de canaux avec UNet

Fort de ces constatations, nous nous sommes engagés dans une deuxième phase expérimentale visant à affiner notre compréhension de l'impact de ces trois canaux principaux sur le réseau de neurones UNet. L'objectif était de tester toutes les combinaisons possibles de ces canaux (**4.Vitesse**, **2.Carte de chaleur** et **1.Binaire**) pour identifier la combinaison optimale.

Dans cette expérience, nous avons procédé à l'entraînement et aux prédictions en considérant chaque configuration possible, en utilisant les mêmes bases de données que précédemment. L'intention était de déterminer non seulement la meilleure combinaison de canaux, mais aussi de comprendre quel canal contribue le plus à l'amélioration de chaque métrique spécifique.

Cette approche méthodique nous permettra de cerner précisément les atouts de chaque canal et de configurer de manière optimale notre réseau de neurones pour une performance maximale dans la segmentation sémantique des données GPS.

TABLE 4.2 Moyenne des FScores pour les combinaisons d'informations préférées du réseau UNet

Combinaisons	FINT	FTOP	FITO
Binaire	0.320	0.741	0.729
Carte de chaleur	0.365	0.785	0.781
Vitesse	0.355	0.757	0.748
Binaire & Carte de chaleur	0.352	0.763	0.762
Binaire & Vitesse	0.330	0.737	0.724
Carte de chaleur & Vitesse	0.350	0.769	0.770
Binaire & Carte de chaleur & Vitesse	0.343	0.762	0.760
Base (17 canaux)	0.324	0.752	0.742

Les résultats obtenus, présentés dans le Tableau 4.2, ont confirmé notre hypothèse initiale selon laquelle la simplification des canaux d'entrée à ceux les plus significatifs améliorerait les performances du modèle. Effectivement, sauf dans le cas où nous utilisons exclusivement le canal **1.Binaire**, les résultats ont systématiquement surpassé ceux obtenus avec l'ensemble des 17 canaux.

Cependant, une observation inattendue a émergé concernant la hiérarchie de l'importance entre les canaux **4.Vitesse** et **2.Carte de chaleur**. À la lumière des résultats actuels, qui sont issus d'un entraînement spécifiquement axé sur les canaux pertinents, le canal **2.Carte de chaleur** s'est avéré être plus significatif

que **4.Vitesse**. Cette découverte remet en question nos conclusions initiales basées sur la permutation des caractéristiques.

En conséquence, notre analyse finale conclut que l’entraînement avec le seul canal **2.Carte de chaleur** fournit de meilleures performances que toutes les autres combinaisons testées, notamment en ce qui concerne l’inférence des intersections, des segments et de la connectivité du graphe. De ce fait, il apparaît que le canal **2.Carte de chaleur**, utilisé de manière isolée, constitue la combinaison la plus efficace pour le modèle UNet, compte tenu de notre configuration spécifique, de nos données, et de notre objectif de fusionner efficacement les traces GPS.

4.3.2.3 Positionnement par rapport à l’état de l’art

Cette expérimentation a pour but de valider les résultats obtenus lors des deux premières expériences, en les confrontant aux combinaisons utilisées dans l’état de l’art. Cette section compare donc la combinaison de nos canaux avec celles issues de trois études notables. [26] a employé **2.Carte de chaleur**, **4.Vitesse**, **5.Accélération**, **19.Différence de direction** et **8-15.Directions**. De son côté, [68] a combiné **2.Carte de chaleur**, **4.Vitesse** et **8-15.Directions**, ainsi qu’un canal de ligne, que nous n’avons pas utilisé en raison de nos faibles résolutions, le rendant impraticable à implémenter correctement. Enfin, [27] a supposément utilisé **2.Carte de chaleur**, **4.Vitesse** et **8-15.Directions**, citant des informations limitées pour la conversion vectorielle en raster.

TABLE 4.3 Comparaison des FScores obtenus par notre combinaisons de canaux avec celles utilisées par l’état de l’art

Combinaisons	FINT	FTOP	FITO
Eftelioglu [26]	0.322	0.748	0.742
Ruan [68]	0.335	0.743	0.736
Freng [27]	0.335	0.743	0.736
Notre approche	0.365	0.785	0.781

Les résultats de cette étude sont regroupés dans le Tableau 4.3. En comparant notre combinaison de canaux avec deux nouvelles combinaisons issues de trois études références, nous constatons que l’entraînement sur **2.Carte de chaleur** seule offre des capacités de détection nettement améliorées pour les segments et les intersections. Même en termes de connectivité, nous observons une amélioration moyenne de 4% pour les trois mesures. Ces résultats indiquent clairement que le choix de canaux est un facteur important que la combinaison que nous proposons semble plus efficace que celles utilisées dans l’état de l’art. Ceci suggère que notre sélection de canaux, bien que plus simple, capture de manière plus précise les caractéristiques essentielles pour une détection améliorée des éléments routiers. Cette avancée constitue une étape importante dans la compréhension et l’analyse des réseaux routiers à partir de données géospatiales, et ouvre des perspectives pour des applications plus vastes et précises dans des domaines comme la planification urbaine, la gestion du trafic et la navigation.

4.3.3 Analyse comparative des architectures de réseaux neuronaux

Après nos premières études sur la réactivité du réseau U-Net à la fusion de traces GPS, nous avons décidé d’approfondir notre recherche en intégrant une réflexion sur les architectures de réseaux de neurones, tout en continuant notre exploration sur la préparation des données. Cette décision découle des résultats précédents, qui ont montré que U-Net, avec notre configuration et nos données, ne réussissait pas à combiner efficacement plusieurs informations d’entrée pour produire une carte optimale. Dans cette section, nous allons donc explorer si d’autres modèles issus de la littérature peuvent mieux accomplir cette tâche, et identifier le modèle le plus performant dans nos conditions spécifiques.

Notre méthode consistera à tester sept modèles différents de U-Net, en évaluant quel format de données d’entrée est le plus approprié pour notre objectif. Nous répéterons les expériences des sections 4.3.2.2 et 4.3.2.2 pour chaque modèle, afin de déterminer les données les plus pertinentes, la meilleure combinaison de ces données, et enfin le meilleur modèle en association avec la meilleure combinaison et format d’entrée. Cette approche méthodique nous permettra de tirer des conclusions solides et d’affiner notre compréhension des mécanismes impliqués, tout en apportant une contribution significative à la littérature scientifique dans ce domaine.

4.3.3.1 Cartographies des performances sur différentes tailles de patch

Dans notre première expérimentation, nous avons intégré sept modèles parmi les plus renommés pour évaluer l’efficacité de différentes tailles de patches dans la fusion de traces GPS, une approche encore peu explorée. En examinant la taille de patch idéale pour chaque architecture, nous espérons découvrir des avantages en termes de performance du modèle. Pour cette étude, nous avons entraîné nos huit modèles avec six tailles de patch différentes, couvrant une gamme largement représentée dans la littérature actuelle.

L’expérience a été réalisée en entraînant les modèles exclusivement sur des **2. Carte de chaleur**, en raison de leur utilisation fréquente et de leur capacité éprouvée à générer des cartes routières de manière autonome. Les scores présentés dans cette section sont la moyenne harmonique des scores FINT, FTOP et FITO, permettant une évaluation globale et équilibrée des performances des modèles sur différentes tailles de patch. Cette méthode nous offre une perspective unique sur l’impact de la taille des patches sur les capacités de chaque architecture de réseau neuronal, enrichissant ainsi notre compréhension des mécanismes optimaux pour la fusion des traces GPS.

Les résultats du Tableau 4.4, détaillant les scores moyens harmoniques, révèlent des informations cruciales sur l’interaction entre différents modèles architecturaux de réseaux de neurones et les tailles de patch. Pour DeepLabV3Plus, la performance optimale est obtenue avec un patch de taille 192, au-delà duquel le modèle devient moins efficace. Les modèles Inception et Unet montrent également de hauts niveaux de performance avec un patch de 192.

En ce qui concerne DLinkNet, HRNet et ResUNet, les résultats les plus probants sont observés avec un patch de 320. Pour DenseNet et SegNet, les tailles de patch recommandées sont respectivement de 384 et 256. Ces découvertes représentent une progression notable dans notre compréhension du domaine, soulignant deux aspects

TABLE 4.4 FScores harmoniques moyens pour différentes tailles de patch pour plusieurs architectures de réseaux. Les valeurs en gras indiquent le score le plus élevé obtenu pour chaque architecture à travers les différentes tailles de patche, tandis que la valeur soulignée représente le score le plus élevé parmi toutes les architectures et toutes les tailles de patch.

Architecture	Taille du Patch					
	192	256	320	384	448	512
DeeplabV3Plus	0.408	0.392	0.333	0.072	0	0
DenseNet	0.527	0.532	0.545	0.549	0.540	0.512
DLinkNet	0.555	0.559	0.569	0.547	0.542	0.546
HRNet	0.629	0.639	<u>0.641</u>	0.620	0.623	0.605
Inception	0.525	0.525	0.516	0.523	0.516	0.512
ResUnet	0.535	0.521	0.559	0.547	0.543	0.542
SegNet	0.198	0.199	0.162	0.158	0.117	0.158
UNet	0.560	0.557	0.555	0.551	0.537	0.524

principaux. Premièrement, HRNet se distingue comme le réseau le plus performant, surpassant les autres modèles testés, lorsqu'il est entraîné exclusivement avec une **2. Carte de chaleur**. Deuxièmement, il est remarquable que les trois modèles les plus performants de cette expérience ont tous obtenu leurs meilleurs résultats avec une taille de patch de 320, ce qui suggère que cette dimension est particulièrement adaptée pour la fusion des traces GPS.




FIGURE 4.5 – Résultats des modèles par taille de patche.

Sur la Figure 4.5, on remarque que certains modèles affichent des résultats sous la forme de courbes polynomiales. Cette tendance suggère que la taille de patch optimale pour ces modèles pourrait correspondre au sommet de ces courbes. Les

modèles DenseNet, DLinkNet, HRNet, ResUnet et SegNet illustrent ce phénomène.

Cependant, d'autres réseaux comme DeepLabV3Plus et UNet présentent des performances décroissantes avec l'augmentation de la taille du patch, indiquant que des tailles plus grandes pourraient nuire à l'efficacité du réseau. Il serait pertinent de mener des recherches supplémentaires pour vérifier si des résolutions inférieures à 192 pourraient offrir de meilleurs résultats. Inception, en revanche, montre une constance dans ses performances quelle que soit la taille du patch.

Enfin, il est observé que les tailles de patch de 448 et 512 entraînent systématiquement des performances inférieures par rapport aux tailles plus petites, ce qui remet en question les affirmations courantes dans l'état de l'art. Ces constats soulignent la nécessité d'une exploration plus approfondie des interactions entre la taille des patches et la performance des réseaux dans le cadre de la fusion des traces GPS.

4.3.3.2 Évaluation sur 17 canaux

Cette expérience se penche sur la capacité des huit architectures de réseaux de neurones à tirer parti des informations contenues dans les 17 canaux potentiels. L'objectif est d'évaluer l'impact de chaque canal sur la performance de chaque modèle. Pour ce faire, chaque modèle a été entraîné avec la taille de patch appropriée (référence 4.3.3.1) sur des images intégrant les 17 canaux. Puis, 17 prédictions distinctes ont été effectuées pour chaque modèle, en permutant systématiquement tous les pixels d'un canal spécifique à chaque fois.

L'évaluation de ces prédictions permet de mesurer la performance du modèle lorsque l'un des canaux est perturbé. Si la performance avec un canal perturbé est inférieure à celle obtenue sans perturbation, cela indique que le modèle dépend fortement de ce canal. Plus l'écart de performance est important par rapport au score de référence, plus le canal est considéré comme significatif pour le modèle.

Pour assurer la fiabilité des résultats, chaque configuration a été testée 10 fois, et les scores moyens ont été calculés pour FINT, FTOP et pour FITO. Cette méthode garantit une plus grande précision et permet d'obtenir une évaluation robuste de la signification de chaque canal pour les différents modèles testés.

TABLE 4.5 Comparaison des résultats en utilisant uniquement le carte de chaleur en entrée ou l'ensemble des 17 canaux pour différentes architectures

Architecture	Carte de chaleur	17 canaux
DeeplabV3Plus	0.41 (+6%)	0.35
DenseNet	0.55 (+10%)	0.45
DLinkNet	0.57 (+6%)	0.51
HRNet	0.64 (+5%)	0.59
Inception	0.53 (+8%)	0.45
ResUnet	0.56 (+9%)	0.47
SegNet	0.2 (+3%)	0.17
UNet	0.56 (+7%)	0.49

Cette introduction présente les résultats préliminaires de l'expérimentation, illustrés dans le Tableau 4.5, et met en lumière une tendance générale : l'inclusion d'informations supplémentaires dans les modèles semble diminuer la qualité des résultats

obtenus. Cette observation s’applique à toutes les architectures testées, indiquant qu’aucune d’entre elles n’est capable d’exploiter pleinement l’ensemble des données fournies. Il est probable que certains canaux n’apportent pas d’informations utiles pour le modèle, ce qui pourrait avoir un effet contre-productif en diminuant la qualité des résultats finaux. Dans ce contexte, les réseaux susceptibles de devenir confus en présence d’informations superflues seraient les moins performants.

Les modèles présentant la plus petite différence entre les performances obtenues avec des données minimales et maximales sont considérés comme les plus efficaces pour traiter des données supplémentaires. À la lumière de ces résultats, les modèles HRNet, DLinkNet et UNet, déjà identifiés comme performants dans la section 4.3.3.1, se confirment comme leaders dans cette expérimentation. DeeplabV3Plus et SegNet, bien que moins enclins à la confusion, affichent des performances inférieures comparées aux modèles leaders.

TABLE 4.6 Moyenne harmonique pour les 17 canaux et pour chaque permutation. Plus le contraste de couleur est fort, plus la différence entre le score obtenu et la référence est élevée.

Architectures	17 Canaux	Accélération	Altitude	Diversité direction.	Différence de direction	Direction1	Direction2	Direction3	Direction4	Direction5	Direction6	Direction7	Direction8	Binaire	Distance	Carte de chaleur	Pente	Vitesse
DeeplabV3Plus	0.35	0.35	0.34	0.34	0.35	0.34	0.35	0.35	0.35	0.35	0.35	0.36	0.36	0.30	0.34	0.32	0.34	0.25
DenseNet	0.45	0.45	0.42	0.41	0.39	0.40	0.43	0.43	0.43	0.44	0.43	0.43	0.33	0.41	0.39	0.44	0.44	0.30
DLinkNet	0.51	0.51	0.49	0.36	0.45	0.47	0.49	0.51	0.50	0.50	0.50	0.51	0.51	0.41	0.49	0.41	0.50	0.24
HRNet	0.59	0.58	0.57	0.50	0.56	0.54	0.58	0.58	0.57	0.58	0.57	0.57	0.58	0.45	0.57	0.50	0.54	0.34
Inception	0.45	0.45	0.43	0.39	0.35	0.43	0.43	0.45	0.44	0.44	0.46	0.46	0.43	0.35	0.40	0.38	0.43	0.30
ResUNet	0.47	0.47	0.45	0.42	0.40	0.44	0.45	0.47	0.45	0.47	0.45	0.46	0.45	0.35	0.43	0.41	0.45	0.30
Segnet	0.17	0.18	0.17	0.15	0.16	0.18	0.20	0.18	0.18	0.19	0.17	0.19	0.21	0.14	0.16	0.15	0.19	0.16
UNet	0.49	0.49	0.47	0.44	0.44	0.44	0.47	0.49	0.47	0.48	0.48	0.49	0.47	0.40	0.46	0.41	0.47	0.37

Le Tableau 4.6 présente une comparaison entre les performances de nos modèles en utilisant les 17 canaux et les résultats obtenus en brouillant individuellement chaque canal. D’après ces résultats, nous décidons d’exclure de nos futures analyses les canaux relatifs aux **8-15.Direction** (de 2 à 8), à l’**5.Accélération**, et à l’**6.Altitude**, en raison de leur utilité limitée pour les modèles. Cependant, la Direction1 fait exception, étant plus valorisée par les modèles que les autres directions. La **3.Distance**, quant à elle, est modérément utilisée, sauf par les deux réseaux les plus performants (HRNet et DLinkNet). Notamment, HRNet est le seul modèle à trouver une utilité au canal de **7.Pente**, ce qui pourrait contribuer à sa performance supérieure dans l’analyse des données.

L’observation clé de cette expérimentation est que, quel que soit le modèle, le canal de **4.Vitesse** est le plus important (avec une baisse pouvant atteindre 27% de la performance de DLinkNet en cas de brouillage du canal de **4.Vitesse**), suivi par le canal **1.Binaire** et la **2.Carte de chaleur**, bien que l’ordre d’importance varie selon le modèle. Les canaux incorporant des informations directionnelles (**17.Différence de Direction**, **16.Diversité directionnelle**) affichent également des résultats prometteurs, se rapprochant parfois des performances des canaux tels que la **2.Carte de chaleur**.

Ces résultats offriront à la communauté scientifique des informations importantes sur l’impact de chaque canal et sur la possibilité d’éliminer certains éléments de leurs protocoles d’entraînement. La préférence pour les canaux directionnels observée dans les études antérieures ne se reflète pas dans nos résultats, qui indiquent leur impact

négatif sur l'apprentissage. Ces conclusions suggèrent également que les réseaux peuvent avoir des préférences pour certains canaux, révélant que leur valeur n'est pas uniforme selon l'architecture utilisée. Nous espérons que cette expérimentation sera intégrée dans les recherches futures sur ce sujet, aidant ainsi à associer les canaux appropriés aux réseaux sélectionnés.

4.3.3.3 Comparatif global des performances

La dernière série d'expériences de cette étude vise à résoudre des questions clés : certains réseaux peuvent-ils exploiter ou fusionner d'autres canaux, en plus ou à la place de la **2.Carte de chaleur**, pour améliorer les performances ? Quelle combinaison de canaux sera la plus efficace et considérée comme l'état de l'art ? Compte tenu de l'immense nombre de combinaisons possibles, notre approche se concentre sur l'identification des combinaisons optimales pour chaque modèle, basée sur l'écart des performances observé dans le Tableau 4.6.

Nous avons procédé de manière séquentielle pour chaque modèle, en commençant par le canal le plus influent, puis en intégrant progressivement les autres canaux favoris du modèle. Cette méthode respecte les préférences de chaque architecture de réseau, et nous permet d'observer l'impact de l'ajout de chaque nouveau canal sur les performances. L'objectif est de trouver une combinaison qui surpasse les résultats obtenus avec la seule **2.Carte de chaleur**.

Finalement, nous comparons notre meilleure combinaison à celles identifiées dans les études de référence de l'état de l'art. Cette comparaison vise à établir notre proposition comme la nouvelle référence dans le domaine de la fusion des traces GPS via l'apprentissage profond, en démontrant une efficacité supérieure à celle des combinaisons existantes.

TABLE 4.7 Moyenne harmonique des modèles basée sur des combinaisons. Pour chaque modèle, nous ajoutons progressivement de nouveaux canaux dans les combinaisons. V=Vitesse, B=Binaire, C=Carte de chaleur, DDIR= Diversité directionnelle, DDIF=Différence de Direction, D1=Direction1 et P=Pente

Architecture	Combinaison						
DeeplabV3Plus	0.35 _V	0.33 _{+B}	0.36 _{+C}	-	-	-	-
DenseNet	0.41 _V	0.48 _{+B}	0.48 _{+DDIF}	0.49 _{+C}	0.50 _{+D1}	0.49 _{+D}	0.49 _{+DDIR}
DLinkNet	0.48 _V	0.49 _{+DDIR}	0.54 _{+C}	0.54 _{+B}	0.52 _{+DDIF}	0.55 _{+D1}	-
HRNet	0.59 _V	0.61 _{+B}	0.61 _{+C}	0.60 _{+DDIR}	0.61 _{+D1}	0.60 _{+P}	0.60 _{+DDIF}
Inception	0.46 _V	0.49 _{+B}	0.49 _{+DDIF}	0.50 _{+C}	0.49 _{+DDIR}	0.48 _{+D}	0.48 _{+P}
ResUnet	0.44 _V	0.50 _{+B}	0.50 _{+DDIF}	0.52 _{+C}	0.51 _{+DDIR}	0.51 _{+D}	0.52 _{+D1}
Segnet	0.21 _B	-	-	-	-	-	-
UNet	0.51 _V	0.49 _{+B}	0.51 _{+C}	0.51 _{+DDIR}	0.52 _{+DDIF}	0.52 _{+D1}	0.50 _{+D}

Le Tableau 4.7 révèle que certains modèles, notamment DenseNet, DLinkNet, Inception et ResUnet, répondent positivement à l'intégration de nouveaux facteurs dans leurs combinaisons de canaux. Ces modèles présentent une amélioration de plus de 5% de leur performance lors de l'ajout de la **4.Vitesse**, et dans certains cas, du **1.Binaire** ou de la **2.Carte de chaleur**. Cette amélioration suggère que ces modèles bénéficient de l'inclusion de leur canal le plus influent.

En revanche, des modèles comme UNet et HRNet ne montrent pas de change-

ment notable dans leurs performances lors de l'intégration progressive de différents canaux. Cette stabilité suggère une capacité supérieure de ces modèles à intégrer et fusionner les informations provenant de divers canaux.

En se concentrant uniquement sur les scores individuels de chaque modèle, il est clair que HRNet se distingue comme le modèle le plus performant, avec un avantage de 6% sur son plus proche concurrent. Cette performance exceptionnelle souligne l'efficacité de HRNet dans la tâche de fusion des traces GPS, affirmant ainsi sa position de leader dans ce domaine.

TABLE 4.8 Comparatif des moyennes harmoniques de FINT, FTOP et FITO pour de toutes les combinaisons évaluées.

Architecture	Combinaisons testées							Combinaisons de l'état de l'art	
	C	V	B	DDIF	DDIR	Meilleure combinaison 4.7	17 canaux	Eftelioglu [26]	Ruan [68] & Freng [27]
DeepLabV3Plus	0.41	0.35	0.36	0.38	0.44	0.36 _{V,B,C}	0.35	0.37 _{C,V,A,DDIF,B_x}	0.36 _{C,V,B_x}
DenseNet	0.54	0.41	0.49	0.49	0.48	0.50 _{V,B,DDIF,C,D1}	0.45	0.42 _{C,V,A,DDIF,B_x}	0.44 _{C,V,B_x}
DLinkNet	0.57	0.48	0.52	0.52	0.48	0.55 _{V,DDIR,C,B,DDIF,D1}	0.51	0.50 _{C,V,A,DDIF,B_x}	0.49 _{C,V,B_x}
HRNet	0.64	0.58	0.60	0.58	0.50	0.61 _{V,B}	0.59	0.59 _{C,V,A,DDIF,B_x}	0.56 _{C,V,B_x}
Inception	0.53	0.48	0.48	0.51	0.49	0.50 _{V,B,DDIF,C}	0.45	0.46 _{C,V,A,DDIF,B_x}	0.43 _{C,V,B_x}
ResUNet	0.56	0.44	0.51	0.48	0.49	0.52 _{V,B,DDIF,C,DDIR,D,D1}	0.47	0.45 _{C,V,A,DDIF,B_x}	0.42 _{C,V,B_x}
SegNet	0.20	0.20	0.21	0.23	0.26	0.21 _B	0.17	0.17 _{C,V,A,DDIF,B_x}	0.17 _{C,V,B_x}
UNet	0.56	0.51	0.50	0.52	0.49	0.52 _{V,B,C,DDIR,DDIF,D1}	0.49	0.48 _{C,V,A,DDIF,B_x}	0.48 _{C,V,B_x}

En conclusion, notre analyse globale des résultats révèle des insights significatifs sur les combinaisons de canaux pour la fusion de traces GPS par l'apprentissage profond. L'étude des résultats, comme indiqué dans le Tableau 4.7, montre que les combinaisons de deux canaux ou plus apportent des améliorations minimales. Ainsi, nous avons concentré notre analyse sur les performances obtenues en utilisant un seul canal parmi les cinq les plus performants, à savoir la **2.Carte de chaleur**, la **4.Vitesse**, le **1.Binaire**, la **17.Différence de Direction** et la **16.Diversité directionnelle**.

Le Tableau 4.8 illustre clairement que nos combinaisons uniques de canaux surpassent systématiquement celles établies dans la littérature actuelle, quelle que soit l'architecture du modèle. En particulier, l'utilisation exclusive de la **2.Carte de chaleur** s'est avérée être la plus efficace pour les six meilleurs modèles, un constat qui va à l'encontre de nos attentes initiales. Cette découverte souligne l'importance prédominante de la **2.Carte de chaleur** dans l'interprétation des données GPS par les réseaux de neurones.

De manière intéressante, DeepLabV3Plus et Segnet ont montré une sensibilité particulière au canal de **16.Diversité directionnelle**. Cette observation suggère que certaines architectures peuvent bénéficier de l'inclusion de canaux spécifiques, soulignant l'importance de sélectionner les bons canaux pour chaque modèle spécifique.

Ces résultats contribuent à une meilleure compréhension des mécanismes sous-jacents à la fusion de traces GPS et ouvrent la voie à des améliorations significatives dans ce domaine. Ils mettent également en lumière le potentiel d'optimisation des performances par la sélection appropriée des canaux d'information, en fonction des spécificités de chaque architecture de réseau de neurones.

4.4 Conclusion

Dans cette recherche, nous avons exploré l'efficacité de différentes architectures de réseaux neuronaux dans la fusion de traces GPS pour l'inférence cartographique, en nous focalisant particulièrement sur les données issues de Visorando. L'utilisation de réseaux de neurones dans ce domaine est encore peu courante, et les études existantes n'ont pas établi de fondements solides pour cette approche. Notre exploration a inclus plusieurs architectures populaires de réseaux de neurones, la plupart n'ayant jamais été appliquées auparavant à la fusion de traces GPS.

Nous avons constaté que la taille du patch joue un rôle crucial dans les performances des modèles, avec une taille de 320 s'avérant optimale pour la plupart des architectures, notamment HRNet, DLinkNet et ResUNet. L'étude des différents canaux d'information a mis en évidence l'importance de la **2.Carte de chaleur**, la **4.Vitesse**, le **1.Binaire** et la **16.Diversité directionnelle**, avec chaque modèle présentant ses propres préférences. Nos résultats montrent que la **2.Carte de chaleur** seule offre souvent de meilleurs résultats, notamment pour les modèles les plus performants. Cette découverte remet en question l'usage traditionnel de combiner la **2.Carte de chaleur** avec d'autres canaux. Cependant, certains modèles comme DeepLabV3Plus et Segnet réagissent mieux au canal de **16.Diversité directionnelle**.

Les résultats visuels dans des zones complexes mettent en évidence la supériorité de la **2.Carte de chaleur** seule pour déduire précisément les itinéraires. HRNet s'est distingué comme le modèle le plus performant, et la **2.Carte de chaleur** seule s'est révélée être la meilleure combinaison par rapport aux tentatives antérieures dans l'état de l'art.

Notre étude se concentre sur la région Alsace, mais ces concepts peuvent être adaptés dans d'autres régions avec d'autres données pour une généralisation plus large. Bien que notre travail soit significatif, nous reconnaissons qu'il ne couvre pas tous les aspects de ce domaine. Nous poursuivrons ces recherches au sein de Visorando, notamment sur la résolution idéale du raster d'entrée, un élément clé non exploré dans notre étude. Nos expérimentations ont été limitées aux données pédestres ou à vélo, et non aux données automobiles traditionnelles. Nous croyons qu'un algorithme devrait être capable de traiter toute trace GPS, et nous espérons que de futures recherches consolideront les fondements que nous avons établis.

Cette recherche apporte un éclairage important sur l'utilisation des traces GPS pour la génération de cartes, un sujet qui a capté l'attention croissante de la communauté scientifique ces dernières années. Notre étude enrichit la compréhension de l'inférence cartographique à partir des données GPS, en mettant l'accent sur des éléments clés tels que la taille optimale des patches, l'importance des différents canaux d'information et les combinaisons de canaux les plus efficaces. Ces aspects ont été minutieusement analysés et discutés dans une section dédiée, offrant une série d'observations et de pistes pour de futures explorations. Ces apports sont cruciaux pour la communauté scientifique qui continue d'avancer dans le domaine de la fusion de traces GPS via les réseaux de neurones.

Notre contribution ne se limite pas à ces découvertes techniques. Nous avons également établi un cadre méthodologique complet qui guide la conversion des don-

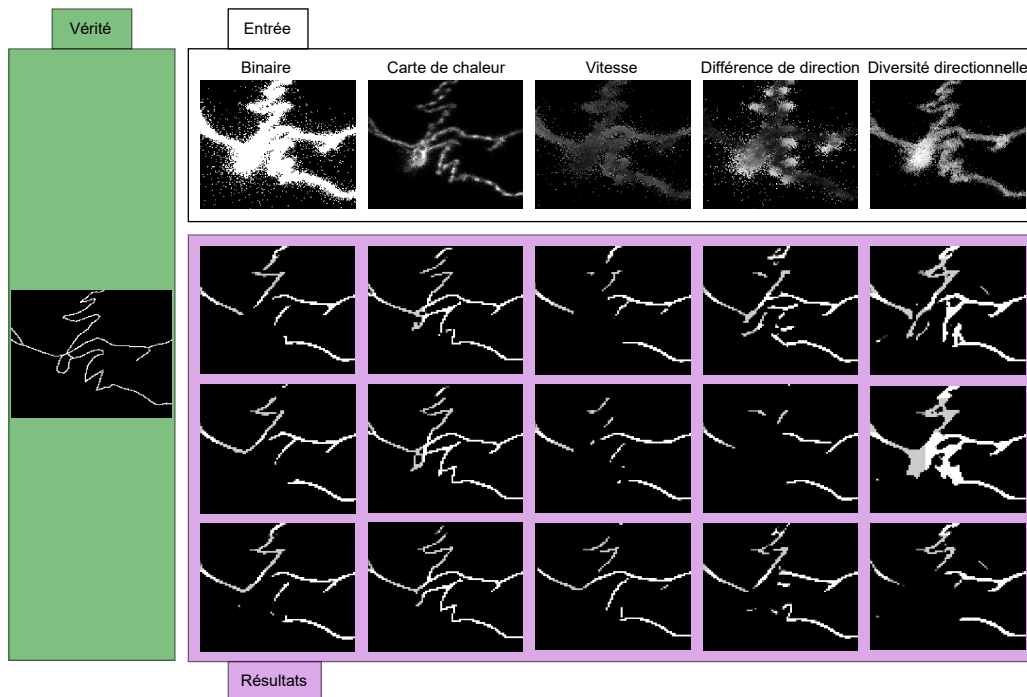


FIGURE 4.6 – Résultats visuels des 3 premières des 10 itérations d’apprentissage par canal d’entrée utilisant l’architecture HRNet et une taille de patche de 320.

nées GPS en images raster adaptées à l’entraînement des réseaux de neurones. Ce cadre comprend notre approche de prétraitement des données, de sélection des canaux pertinents et de combinaison de ces canaux pour optimiser les performances du modèle. En outre, nous avons mis en place une méthodologie d’évaluation rigoureuse pour quantifier et interpréter les résultats obtenus. Cet ensemble de techniques et d’approches représente une contribution significative au domaine, offrant des bases solides et structurées pour les recherches futures sur l’inférence cartographique à partir de traces GPS.

Conclusion

Évaluation critique et adaptation des méthodes d'analyse GPS

Cette thèse a significativement enrichi la compréhension des techniques d'analyse et de fusion de traces GPS, en mettant un accent particulier sur leur application dans la création automatique de cartes de randonnée. Le premier chapitre a posé les bases, présentant le concept de trace GPS et son potentiel remarquable pour divers usages. La question centrale de notre étude, à savoir la fusion de traces GPS, a été définie et a guidé l'ensemble de nos travaux.

Le deuxième chapitre s'est consacré à l'examen des méthodes existantes, soulignant un manque de consensus dans la communauté scientifique sur l'évaluation adéquate de ces techniques. L'importance de bien comprendre et interpréter les métriques utilisées a été mise en évidence, car elle affecte directement la perception des résultats obtenus.

Dans le troisième chapitre, nous avons introduit une nouvelle méthode de fusion de traces GPS, fondée sur l'application multiple de grilles et incluant des processus de prétraitement et de segmentation. Malgré ses promesses, cette méthode a révélé certaines limites, en particulier pour les données de randonnée, ce qui a stimulé notre quête pour des solutions plus avancées.

Le quatrième chapitre représente une étude complète de l'utilisation de l'apprentissage profond à notre problématique. Nous avons concentré nos efforts sur les données de Visorando, un choix stratégique compte tenu de leur représentativité du comportement des randonneurs. Nous avons étudié comment divers réseaux de neurones populaires réagissaient à cette tâche inédite, dans le but de développer une technique solide et adaptable à divers types de terrain et sources de données.

En somme, cette thèse a ouvert de nouvelles perspectives dans le domaine de l'inférence cartographique à partir de traces GPS, offrant des contributions importantes tant sur le plan théorique que pratique, et établissant une base solide pour les recherches futures dans ce domaine en pleine expansion.

Synthèse des résultats et positionnement par rapport à la problématique

Cette thèse a marqué des progrès notables dans l'analyse de traces GPS via des méthodes de clustering et l'utilisation des réseaux de neurones, alignant ainsi les résultats avec les objectifs de Visorando d'exploiter efficacement ses données. Deux

méthodes innovantes ont été développées, permettant la création de cartes dotées de graphes de haute qualité et offrant des possibilités d'application concrètes.

Nos recherches ont confirmé l'efficacité des techniques de clustering pour regrouper les traces GPS en vue d'obtenir une trace centrale optimale. En particulier, l'approche basée sur l'application multiple de grilles a prouvé sa robustesse, surpassant les performances d'autres méthodes de clustering existantes. Cette réussite confirme notre hypothèse initiale et suggère de nouvelles avenues pour l'amélioration et l'application de cette technique.

Parallèlement, nos travaux sur les réseaux de neurones ont mis en évidence leur aptitude à générer des graphes de haute qualité. La performance atteinte par ces modèles est jugée suffisante pour une multitude d'applications, soulignant ainsi le potentiel considérable de l'apprentissage profond dans l'analyse et la fusion des traces GPS.

En somme, cette thèse contribue significativement au domaine de l'analyse des traces GPS, offrant de nouvelles perspectives et méthodologies qui pourraient être largement adoptées dans des applications pratiques, notamment dans le cadre des objectifs de Visorando.

Dans le contexte scientifique actuel, ce manuscrit de thèse présente des contributions importantes et innovantes, articulées autour de trois axes majeurs, qui correspondent aux trois chapitres principaux de cette recherche.

Évaluation des environnements et des cartes générées par fusion de traces GPS Un aspect clé de notre étude a été l'analyse critique des environnements d'évaluation existants pour les cartes générées par la fusion de traces GPS. Nous avons mis en exergue des lacunes structurelles dans ces environnements, qui limitent la compréhension des imperfections dans les cartes produites. Cette analyse, au-delà de sa nature descriptive, constitue un éveil scientifique crucial sur cette question. De plus, nous avons élaboré et justifié un ensemble de métriques adaptées à la fois aux méthodes de clustering classiques et aux nouvelles approches basées sur l'apprentissage profond. Nous avons pris soin de clarifier la signification réelle de chaque métrique, qui peut parfois diverger de l'interprétation initiale.

Méthode de grilles pour l'analyse de traces GPS Le troisième chapitre se distingue par le développement d'une méthode innovante pour l'analyse des traces GPS, utilisant des techniques de clustering. Cette méthode est caractérisée par un processus de prétraitement efficace et un mécanisme de segmentation fondé sur l'utilisation de grilles, évitant ainsi le besoin de post-traitement. Cette approche a démontré sa compétitivité par rapport à l'état de l'art, notamment dans des contextes variés, allant de zones urbaines structurées à des terrains plus accidentés.

Techniques d'apprentissage profond pour la fusion de traces GPS Le dernier axe de nos contributions se concentre sur l'application des techniques d'apprentissage profond à la fusion de traces GPS. Nous proposons une nouvelle perspective basée sur des données pédestres, représentatives des comportements de randonneurs, un domaine peu exploré jusqu'à présent. Face à l'absence de fondations solides pour cette tâche spécifique appliquée aux réseaux de neurones, nous avons réorienté nos

recherches vers la préparation et la structuration de cette nouvelle approche. Le quatrième chapitre de notre étude se penche sur une évaluation approfondie des performances de différentes architectures de réseaux de neurones pour la fusion de données GPS, avec un accent particulier sur l'utilisation de la base de données Visorando. Nos travaux mettent en évidence l'importance de la taille des patches, démontrent la supériorité de certains canaux d'information, et révèlent que la "Carte de chaleur", utilisée seule, peut souvent surpasser des combinaisons de canaux plus complexes, y compris celles de l'état de l'art. Ces découvertes marquent un progrès significatif dans la compréhension et l'application optimales des différentes architectures et canaux d'information dans la fusion des données GPS. De plus, nous avons introduit de nouvelles variables, dérivées des traces GPS, qui ont prouvé leur utilité. En conclusion, nos recherches ont mis en avant le réseau de neurones HRNet à architectures hiérarchiques, qui, bien que jamais associé auparavant à la tâche de fusion de traces GPS, s'est avéré être le modèle le plus performant dans nos tests et sur les données Visorando. Cette découverte ouvre des perspectives prometteuses pour des recherches futures dans ce domaine spécifique.

Réflexion sur les limites de notre travail

La méthode basée sur le clustering présentée dans le premier chapitre a montré des résultats prometteurs, en particulier dans sa capacité à s'adapter à divers scénarios. Néanmoins, plusieurs limitations sont à souligner. Premièrement, le manque de disponibilité des codes sources dans d'autres études similaires a constitué un obstacle majeur pour une comparaison rigoureuse et précise. Cette situation a limité notre capacité à établir de manière définitive l'avantage de notre méthode par rapport à d'autres approches existantes. De plus, bien que notre méthode ait démontré une certaine efficacité dans le traitement des terrains accidentés, les résultats préliminaires n'ont pas encore atteint le niveau d'excellence requis par les entreprises. Cela souligne le besoin d'améliorations continues et de recherches supplémentaires pour améliorer la performance du modèle et notablement sur les jeux de données bruités. La complexité de la configuration de notre méthode constitue également une limitation non négligeable. Avec un total de six paramètres à ajuster, le processus peut s'avérer fastidieux et peut décourager son adoption, particulièrement pour les utilisateurs moins expérimentés. Une simplification du réglage des paramètres ou le développement d'une méthode auto-adaptative pourrait contribuer à pallier ce problème. Le quatrième chapitre a exploré l'utilisation des architectures de réseaux neuronaux pour la fusion des données GPS. Bien que cette approche ait montré son potentiel, elle n'est pas exempte de limitations. La taille du patche a été identifiée comme un facteur critique affectant les performances du modèle. Bien qu'une taille optimale ait été trouvée pour les modèles testés, cette découverte est spécifique au contexte de l'étude et peut ne pas être généralisable à d'autres scénarios ou types de données. De plus, bien que certaines architectures aient montré une préférence pour certains canaux d'information, il est crucial de noter que ces observations sont basées sur un ensemble de données spécifique et peuvent ne pas être applicables dans d'autres contextes.

Perspectives et pistes de recherche

Notre travail actuel, qui se manifeste par le développement d'algorithmes novateurs de fusion de traces GPS, offre à l'entreprise Visorando une opportunité unique d'enrichir son application avec des cartes détaillées et précises, directement accessibles à sa clientèle. Cette intégration promet d'améliorer considérablement l'expérience utilisateur en fournissant des cartes mises à jour et adaptées aux besoins spécifiques des randonneurs. Toutefois, conscient de certaines limitations inhérentes à nos méthodes actuelles, nous envisageons de poursuivre notre quête de progrès dans le domaine de la recherche scientifique.

Dans cette optique, nous allons explorer des pistes de recherche et des perspectives d'avenir. Un aspect fondamental concerne la nécessité de revisiter et de comprendre en profondeur les problèmes liés à l'environnement d'évaluation des techniques de fusion de traces GPS. Cela inclut une étude approfondie des métriques à utiliser et de leur signification réelle. Notre ambition est de proposer une approche d'évaluation standardisée et universellement acceptée par la communauté scientifique, basée sur un ensemble de données varié et représentatif des divers cas de fusion de traces GPS. Nous prévoyons de prendre l'initiative dans ce domaine, en développant des solutions exhaustives qui intègrent une analyse complète des métriques pertinentes.

En ce qui concerne les techniques de clustering, malgré les limites que nous avons identifiées, nous restons convaincus de leur potentiel pour la fusion efficace de traces GPS. Nous prévoyons donc de continuer à explorer ce domaine, tout en reconnaissant que nos résultats actuels avec les réseaux de neurones sont prometteurs. En conséquence, nous envisageons de concentrer nos futurs efforts de recherche sur l'exploration et l'optimisation des techniques basées sur les réseaux de neurones.

Un projet clé à l'avenir sera d'approfondir notre compréhension de l'impact de la résolution des données raster. Cette étude explorera la résolution idéale pour la conversion des traces GPS, initialement vectorielles, en données raster. Nous croyons que cet aspect est fondamental pour améliorer la précision des cartes générées et est intrinsèquement lié à notre recherche sur la taille optimale des patches.

En outre, il serait également instructif de comparer nos solutions optimales avec les architectures d'apprentissage profond spécifiques utilisées dans d'autres études pertinentes sur la fusion de traces GPS. Cette comparaison nécessiterait de travailler avec les jeux de données, les configurations, et les structures d'information utilisées dans ces études. Bien que nous n'ayons pas eu le temps de mener de telles expérimentations dans le cadre de cette thèse, ces analyses comparatives font partie de nos projets immédiats de recherche post-thèse.

En résumé, notre ambition est de continuer à pousser les frontières de la recherche dans le domaine de la fusion de traces GPS, en exploitant pleinement le potentiel des techniques avancées de clustering et d'apprentissage profond. Nous aspirons à fournir des contributions significatives et innovantes qui pourraient transformer la manière dont les données de traces GPS sont analysées et utilisées dans le domaine de la cartographie et au-delà.

Le bilan de l'entreprise par Arnaud Lecus

La thèse réalisée a constitué une avancée significative dans le domaine de l'analyse GPS, répondant ainsi aux attentes de l'entreprise Visorando, qui a financé la majorité de ce projet de recherche. Au terme de nos recherches, Visorando dispose désormais d'une méthode applicable directement à sa base de données de traces GPS. Cette technique permet de générer une carte de manière autonome, sans nécessiter d'interventions supplémentaires. La carte produite pourra être utilisée en interne et pourrait même être mise à disposition des utilisateurs de l'application. La méthode mise au point répond efficacement aux besoins de l'entreprise, offrant une solution rapide et suffisamment précise pour traiter cet ensemble conséquent de données GPS. Afin de souligner l'impact et la valeur de notre travail, nous souhaitons partager le témoignage de M. Lecus, Président-Directeur de Visorando, qui partage ses impressions et son expérience de notre collaboration :

Les données sont au coeur des services que nous proposons à nos utilisateurs : collecte, traitement et diffusion. Notre force est de diffuser des itinéraires de randonnée qualifiés par un processus de sélection très rigoureux. Cette approche nous a permis de devenir leader en France. Nous collectons aussi plusieurs millions de traces GPS chaque année. Ces traces ont pour nous une très grande valeur en ce sens qu'elles nous donnent des informations sur la pratique de la randonnée, en particulier sur les itinéraires suivis. Les traiter efficacement nous permettra de proposer des services innovants et ainsi garder une longueur d'avance sur nos concurrents. Et toujours au service de nos utilisateurs. C'était l'objectif de la thèse d'Olivier qui a été parfaitement rempli. Nous travaillons déjà sur le développement de ces nouveaux services. La collaboration avec les différentes universités et laboratoires impliqués dans le sujet de la thèse a ainsi été fructueuse. Le dispositif CIFRE nous a permis de concrétiser des idées de services, qui, il y a quelques années, nous paraissaient hors de portée de réalisation. Nous envisageons d'ailleurs de le renouveler au travers d'un nouveau projet.

Ce témoignage illustre l'importance de notre contribution et met en évidence la réussite de notre projet de recherche, soulignant l'efficacité de la méthode développée et son utilité pour l'entreprise Visorando.

Annexes

Algorithme 1 : Adapter les segments d'une carte OSM

Data : Segments extraits du fichier GeoJSON

Result : Segments adaptés

1 **Fonctions utilisées** :

2 **findIntersections(segments)** : Retourne les points qui sont présents 2 fois ou plus dans la carte.

3 **explodeSegmentByNode(segment, node)** : Divise le segment au niveau du point précisé.

4 **mergeSegmentsByNode(segments, node)** : Fusionne les segments en lien avec le point spécifié

5 **begin**

6 | intersections = **findIntersections**(segments);

7 | newSegments = list();

8 | **foreach** *seg* in segments **do**

9 | | inter = intersections intersected with seg excluding endpoints;

10 | | **if** *inter* is not empty **then**

11 | | | subsegs = **explodeSegmentByNode**(seg, inter);

12 | | | add subsegs to newSegments;

13 | | **else**

14 | | | add seg to newSegments;

15 | segments = newSegments;

16 | falseIntersections = extract false intersections from intersections using **findIntersections** on the new segments list;

17 | **while** *falseIntersections* is not empty **do**

18 | | segs = get segments containing falseIntersections[0];

19 | | **if** *length of segs* ≥ 2 **then**

20 | | | mergedSeg = **mergeSegmentsByNodes**(segs, falseIntersections[0]);

21 | | | remove the two original segments;

22 | | | add the merged segment;

23 | | | remove falseIntersections[0] from falseIntersections;

24 | **return** segments;

Algorithme 2 : Filtre d'une liste de vecteurs en fonction de sa similarité avec une image Binaire representant les traces GPS

```

1 Function CoordsToRowCol(raster, x, y)
2    $col \leftarrow \frac{x - raster.x_{bound}}{resolution}$ ;
3    $row \leftarrow \frac{raster.y_{bound} - y}{resolution}$ ;
4   return row, col;

5 Function CheckSimilarity(raster, x, y)
6   row, col  $\leftarrow$  CoordsToRowCol(raster, x, y);
7   neighborhood  $\leftarrow$  raster.data[row - 2 : row + 3, col - 2 : col + 3];
8   return count(neighborhood)  $\geq$  1;

9 Function SegmentSimilarity(raster, segment)
10  total_points, similar_points  $\leftarrow$  0;
11  for (x, y)  $\in$  segment do
12    if CheckSimilarity (raster, x, y) then
13      similar_points ++;
14    total_points ++;
15  return  $\frac{similar\_points}{total\_points}$ ;

16 raster  $\leftarrow$  open(path);
17 Cr  $\leftarrow$  open(path);
18 to_keep  $\leftarrow$  array([ ]);
19 for segment  $\in$  Cr do
20   similarity  $\leftarrow$  SegmentSimilarity(raster, segment);
21   to_keep.append(similarity  $\geq$  target_similarity);
22 return Cr[to_keep];

```

Bibliographie

- [1] Abolfazl Abdollahi, Biswajeet Pradhan, Nagesh Shukla, Subrata Chakraborty, and Abdullah Alamri. Deep learning approaches applied to remote sensing datasets for road extraction : A state-of-the-art review. *Remote Sensing*, 12(9) :1444, 2020.
- [2] Mahmuda Ahmed, Brittany Terese Fasy, Kyle S Hickmann, and Carola Wenk. A path-based distance for street map comparison. *ACM Transactions on Spatial Algorithms and Systems (TSAS)*, 1(1) :1–28, 2015.
- [3] Mahmuda Ahmed, Sophia Karagiorgou, Dieter Pfoser, and Carola Wenk. A comparison and evaluation of map construction algorithms using vehicle tracking data. *GeoInformatica*, 19 :601–632, 2015.
- [4] Mahmuda Ahmed, Sophia Karagiorgou, Dieter Pfoser, Carola Wenk, Mahmuda Ahmed, Sophia Karagiorgou, Dieter Pfoser, and Carola Wenk. *Map construction algorithms*. Springer, 2015.
- [5] Mahmuda Ahmed and Carola Wenk. Constructing street networks from gps trajectories. In *Algorithms–ESA 2012 : 20th Annual European Symposium, Ljubljana, Slovenia, September 10-12, 2012. Proceedings 20*, pages 60–71. Springer, 2012.
- [6] Tariq Alsahfi, Mousa Almotairi, Ramez Elmasri, and Bader Alshemaimri. Road map generation and feature extraction from gps trajectories data. In *Proceedings of the 12th ACM SIGSPATIAL International Workshop on Computational Transportation Science*, pages 1–10, 2019.
- [7] Tariq Alsahfi et al. *Road map generation and feature extraction algorithms from GPS trajectories and Trajectories Data warehousing*. PhD thesis, 2020.
- [8] Mohammad Ali Arman and Chris MJ Tampère. Road centreline and lane reconstruction from pervasive gps tracking on motorways. *Procedia Computer Science*, 170 :434–441, 2020.
- [9] Mohammad Ali Arman and Chris MJ Tampère. Lane-level routable digital map reconstruction for motorway networks using low-precision gps data. *Transportation Research Part C : Emerging Technologies*, 129 :103234, 2021.
- [10] Adham Badran, Ahmed El-Geneidy, and Luis Miranda-Moreno. A review of techniques to extract road network features from global positioning system data for transport modelling. *Transport Reviews*, pages 1–16, 2023.

- [11] Vijay Badrinarayanan, Alex Kendall, and Roberto Cipolla. Segnet : A deep convolutional encoder-decoder architecture for image segmentation. *IEEE transactions on pattern analysis and machine intelligence*, 39(12) :2481–2495, 2017.
- [12] James Biagioni and Jakob Eriksson. Inferring road maps from global positioning system traces : Survey and comparative evaluation. *Transportation research record*, 2291(1) :61–71, 2012.
- [13] James Biagioni and Jakob Eriksson. Map inference in the face of noise and disparity. In *Proceedings of the 20th International Conference on Advances in Geographic Information Systems*, SIGSPATIAL '12, page 79–88, New York, NY, USA, 2012. Association for Computing Machinery.
- [14] Lili Cao and John Krumm. From gps traces to a routable road map. In *17th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems (ACM SIGSPATIAL GIS 2009), November 4-6, 2009, Seattle, WA*, pages 3–12, November 2009.
- [15] Lili Cao and John Krumm. From gps traces to a routable road map. In *Proceedings of the 17th ACM SIGSPATIAL international conference on advances in geographic information systems*, pages 3–12, 2009.
- [16] Pingfu Chao, Wen Hua, Rui Mao, Jiajie Xu, and Xiaofang Zhou. A survey and quantitative study on map inference algorithms from gps trajectories. *IEEE Transactions on Knowledge and Data Engineering*, 34(1) :15–28, 2020.
- [17] Chen Chen, Cewu Lu, Qixing Huang, Qiang Yang, Dimitrios Gunopulos, and Leonidas Guibas. City-scale map creation and updating using gps collections. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, KDD '16, page 1465–1474, New York, NY, USA, 2016. Association for Computing Machinery.
- [18] Liang-Chieh Chen, Yukun Zhu, George Papandreou, Florian Schroff, and Hartwig Adam. Encoder-decoder with atrous separable convolution for semantic image segmentation. In *Proceedings of the European conference on computer vision (ECCV)*, pages 801–818, 2018.
- [19] Zebin Chen, Xiaolin Xiao, Yue-Jiao Gong, Jun Fang, Nan Ma, Hua Chai, and Zhiguang Cao. Interpreting trajectories from multiple views : A hierarchical self-attention network for estimating the time of arrival. In *Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, pages 2771–2779, 2022.
- [20] Aluir Porfírio Dal Poz, EFO Martins, and Rodrigo Bruno Zanin. Road network extraction using gps trajectories based on morphological and skeletonization algorithms. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 43 :239–245, 2022.
- [21] Jonathan J Davies, Alastair R Beresford, and Andy Hopper. Scalable, distributed, real-time map generation. *IEEE Pervasive Computing*, 5(4) :47–54, 2006.
- [22] Bruno de Moura Morceli and Aluir Porfírio Dal Poz. Road extraction from low-cost gnss-device dense trajectories. *Journal of Location Based Services*, pages 1–20, 2023.

- [23] David H Douglas and Thomas K Peucker. Algorithms for the reduction of the number of points required to represent a digitized line or its caricature. *Cartographica : the international journal for geographic information and geovisualization*, 10(2) :112–122, 1973.
- [24] David Duran, Vera Sacristán, and Rodrigo I Silveira. Map construction algorithms : a local evaluation through hiking data. *GeoInformatica*, 24(3) :633–681, 2020.
- [25] Stefan Edelkamp and Stefan Schrödl. Route planning and map inference with global positioning traces. In *Computer Science in Perspective*, 2003.
- [26] Emre Eftelioglu, Ravi Garg, Vaibhav Kango, Chintan Gohil, and Amber Roy Chowdhury. Ring-net : road inference from gps trajectories using a deep segmentation network. In *Proceedings of the 10th ACM SIGSPATIAL International Workshop on Analytics for Big Geospatial Data*, pages 17–26, 2022.
- [27] Shihao Feng, Luo Chen, Wei Xiong, and Yilin Deng. A method of extracting road network structure from trajectory data based on u-net network. 1 :1388–1392, 2020.
- [28] Shihao Feng, Luo Chen, Wei Xiong, and Yilin Deng. A method of extracting road network structure from trajectory data based on u-net network. In *2020 IEEE International Conference on Information Technology, Big Data and Artificial Intelligence (ICIBA)*, volume 1, pages 1388–1392. IEEE, 2020.
- [29] Raphael A Finkel and Jon Louis Bentley. Quad trees a data structure for retrieval on composite keys. *Acta informatica*, 4 :1–9, 1974.
- [30] Zhongliang Fu, Liang Fan, Yangjie Sun, and Zongshun Tian. Density adaptive approach for generating road network from gps trajectories. *IEEE Access*, 8 :51388–51399, 2020.
- [31] Yuan Guo, Bijun Li, Zhi Lu, and Jian Zhou. A novel method for road network mining from floating car data. *Geo-spatial Information Science*, 25(2) :197–211, 2022.
- [32] Yuejun Guo, Anton Bardera, Marta Fort, and Rodrigo I Silveira. A scalable method to construct compact road networks from gps trajectories. *International Journal of Geographical Information Science*, 35(7) :1309–1345, 2021.
- [33] Mahdi Hashemi. A testbed for evaluating network construction algorithms from gps traces. *Computers, Environment and Urban Systems*, 66 :96–109, 2017.
- [34] Mahdi Hashemi. Automatic inference of road and pedestrian networks from spatial-temporal trajectories. *IEEE transactions on intelligent transportation systems*, 20(12) :4604–4620, 2019.
- [35] Eric He, Fan Bai, Curtis Hay, Jinzhu Chen, and Vijayakumar Bhagavatula. A map inference approach using signal processing from crowd-sourced gps data. *ACM Transactions on Spatial Algorithms and Systems (TSAS)*, 7(2) :1–23, 2021.
- [36] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep residual learning for image recognition. *CoRR*, abs/1512.03385, 2015.
- [37] Songtao He, Favyen Bastani, Sofiane Abbar, Mohammad Alizadeh, Hari Balakrishnan, Sanjay Chawla, and Sam Madden. Roadrunner : improving the

- precision of road network inference from gps trajectories. In *Proceedings of the 26th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems*, pages 3–12, 2018.
- [38] Tianfu He, Jie Bao, Ruiyuan Li, Sijie Ruan, Yanhua Li, Li Song, Hui He, and Yu Zheng. What is the human mobility in a new city : Transfer mobility knowledge across cities. In *Proceedings of The Web Conference 2020, WWW '20*, page 1355–1365, New York, NY, USA, 2020. Association for Computing Machinery.
- [39] Gao Huang, Zhuang Liu, Laurens Van Der Maaten, and Kilian Q Weinberger. Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 4700–4708, 2017.
- [40] Jincui Huang, Yunfei Zhang, Min Deng, and Zhengbing He. Mining crowdsourced trajectory and geo-tagged data for spatial-semantic road map construction. *Transactions in GIS*, 26(2) :735–754, 2022.
- [41] Weixing Jia, Guiling Wang, Xuankai Yang, and Fengquan Zhang. Unpaired learning of roadway-level traffic paths from trajectories. In *International Conference on Collaborative Computing : Networking, Applications and Worksharing*, pages 171–190. Springer, 2021.
- [42] Philumon Joseph, Binsu C Koor, and Job Thomas. Automatic road network reconstruction from gps trajectory data using curve reconstruction algorithms. In *High Performance Computing and Networking : Select Proceedings of CHSN 2021*, pages 551–564. Springer, 2022.
- [43] Sophia Karagiorgou and Dieter Pfoser. On vehicle tracking data-based road network generation. In *Proceedings of the 20th International Conference on Advances in Geographic Information Systems*, pages 89–98, 2012.
- [44] Sophia Karagiorgou, Dieter Pfoser, and Dimitrios Skoutas. Segmentation-based road network construction. In *Proceedings of the 21st ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems*, pages 460–463, 2013.
- [45] Sophia Karagiorgou, Dieter Pfoser, and Dimitrios Skoutas. A layered approach for more robust generation of road network maps from vehicle tracking data. *ACM Transactions on Spatial Algorithms and Systems (TSAS)*, 3(1) :1–21, 2017.
- [46] Isaac Lera, Toni Pérez, Carlos Guerrero, Víctor M. Eguíluz, and Carlos Juiz. Analysing human mobility patterns of hiking activities through complex network theory. *PLOS ONE*, 12(5) :1–19, 05 2017.
- [47] Hengfeng Li, Lars Kulik, and Kotagiri Ramamohanarao. Automatic generation and validation of road maps from gps trajectory data sets. In *Proceedings of the 25th ACM International on Conference on Information and Knowledge Management*, pages 1523–1532, 2016.
- [48] Mingqian Li, Panrong Tong, Mo Li, Zhongming Jin, Jianqiang Huang, and Xian-Sheng Hua. Traffic flow prediction with vehicle trajectories. In *Proceedings of the AAAI Conference on Artificial Intelligence*, volume 35, pages 294–302, 2021.

- [49] Yali Li, Longgang Xiang, Caili Zhang, and Huayi Wu. Fusing taxi trajectories and rs images to build road map via dcnn. *IEEE Access*, 7 :161487–161498, 2019.
- [50] Lingbo Liu, Zewei Yang, Guanbin Li, Kuo Wang, Tianshui Chen, and Liang Lin. Aerial images meet crowdsourced trajectories : a new approach to robust road extraction. *IEEE transactions on neural networks and learning systems*, 2022.
- [51] Xuemei Liu, James Biagioni, Jakob Eriksson, Yin Wang, George Forman, and Yanmin Zhu. Mining large-scale, sparse gps traces for map inference : comparison of approaches. In *Proceedings of the 18th ACM SIGKDD international conference on Knowledge discovery and data mining*, pages 669–677, 2012.
- [52] Xuemei Liu, Yanmin Zhu, Yin Wang, George Forman, Lionel M Ni, Yu Fang, and Minglu Li. Road recognition using coarse-grained vehicular traces. *Hp Labs*, 2012.
- [53] Mingqi Lv, Ling Chen, and Gencai Chen. Mining user similarity based on routine activities. *Information Sciences*, 236 :17–32, 2013.
- [54] Jared Macshane and Ali Ahmadinia. Ai assisted trail map generation based on public gps data. In *2023 Systems and Information Engineering Design Symposium (SIEDS)*, pages 37–42. IEEE, 2023.
- [55] Radu Marinescu-Istodor and Pasi Fränti. Grid-based method for gps route analysis for retrieval. *ACM Transactions on Spatial Algorithms and Systems (TSAS)*, 3(3) :1–28, 2017.
- [56] Radu Marinescu-Istodor and Pasi Fränti. Cellnet : Inferring road networks from gps trajectories. *ACM Transactions on Spatial Algorithms and Systems (TSAS)*, 4(3) :1–22, 2018.
- [57] Mashaal Musleh, Sofiane Abbar, Rade Stanojevic, and Mohamed Mokbel. Qarta : An ml-based system for accurate map services. *Proc. VLDB Endow.*, 14(11) :2273–2282, oct 2021.
- [58] OpenStreetMap contributors. Planet dump retrieved from <https://planet.osm.org> . <https://www.openstreetmap.org>, 2017.
- [59] Nobuyuki Otsu. A threshold selection method from gray-level histograms. *IEEE Trans. Syst. Man Cybern.*, 9 :62–66, 1979.
- [60] Arian Prabowo, Piotr Koniusz, Wei Shao, and Flora D Salim. Coltrane : Convolutional trajectory network for deep map inference. In *Proceedings of the 6th ACM International Conference on Systems for Energy-Efficient Buildings, Cities, and Transportation*, pages 21–30, 2019.
- [61] Min Pu, Jiali Mao, Yuntao Du, Yibin Shen, and Cheqing Jin. Road intersection detection based on direction ratio statistics analysis. In *2019 20th IEEE international conference on mobile data management (MDM)*, pages 288–297. IEEE, 2019.
- [62] Narinder Singh Punn and Sonali Agarwal. Inception u-net architecture for semantic segmentation to identify nuclei in microscopy cell images. *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, 16(1) :1–15, 2020.

- [63] Jia Qiu and Ruisheng Wang. Inferring road maps from sparsely sampled gps traces. *Journal of Location Based Services*, 10(2) :111–124, 2016.
- [64] Jia Qiu and Ruisheng Wang. Road map inference : A segmentation and grouping framework. *ISPRS International Journal of Geo-Information*, 5(8) :130, 2016.
- [65] Olaf Ronneberger, Philipp Fischer, and Thomas Brox. U-net : Convolutional networks for biomedical image segmentation. *CoRR*, abs/1505.04597, 2015.
- [66] Amédée Roy, Sophie Lanco Bertrand, and Ronan Fablet. Deep inference of seabird dives from gps-only records : Performance and generalization properties. *PLoS Computational Biology*, 18(3) :e1009890, 2022.
- [67] Sijie Ruan, Jie Bao, Yuxuan Liang, Ruiyuan Li, Tianfu He, Chuishi Meng, Yanhua Li, Yingcai Wu, and Yu Zheng. Dynamic public resource allocation based on human mobility prediction. *Proceedings of the ACM on interactive, mobile, wearable and ubiquitous technologies*, 4(1) :1–22, 2020.
- [68] Sijie Ruan, Cheng Long, Jie Bao, Chunyang Li, Zisheng Yu, Ruiyuan Li, Yuxuan Liang, Tianfu He, and Yu Zheng. Learning to generate maps from trajectories. In *Proceedings of the AAAI conference on artificial intelligence*, volume 34, pages 890–897, 2020.
- [69] Sijie Ruan, Zi Xiong, Cheng Long, Yiheng Chen, Jie Bao, Tianfu He, Ruiyuan Li, Shengnan Wu, Zhongyuan Jiang, and Yu Zheng. Doing in one go : Delivery time inference based on couriers’ trajectories. In *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, pages 2813–2821, 2020.
- [70] Olivier Schirm, Maxime Devanne, Jonathan Weber, Arnaud Lecus, Germain Forestier, and Cédric Wemmert. Une approche multi-grilles pour la génération automatique d’une carte de sentiers de randonnée à partir de données gps. In *ORASIS 2023*, 2023.
- [71] Wenyi Shen, Wenyu Wu, Jiali Mao, Jie Chen, Shaosheng Cao, Lisheng Zhao, Aoying Zhou, and Lin Zhou. Sami : A shape-aware cycling map inference framework for designated driving service. In *2023 IEEE 39th International Conference on Data Engineering (ICDE)*, pages 3269–3281. IEEE, 2023.
- [72] Rade Stanojevic, Sofiane Abbar, Saravanan Thirumuruganathan, Sanjay Chawla, Fethi Filali, and Ahid Aleimat. *Robust Road Map Inference through Network Alignment of Trajectories*, pages 135–143.
- [73] Carole H Sudre, Wenqi Li, Tom Vercauteren, Sebastien Ourselin, and M Jorge Cardoso. Generalised dice overlap as a deep learning loss function for highly unbalanced segmentations. In *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support : Third International Workshop, DLMIA 2017, and 7th International Workshop, ML-CDS 2017, Held in Conjunction with MICCAI 2017, Québec City, QC, Canada, September 14, Proceedings 3*, pages 240–248. Springer, 2017.
- [74] Tao Sun, Zonglin Di, Pengyu Che, Chun Liu, and Yin Wang. Leveraging crowd-sourced gps data for road extraction from aerial imagery. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 7509–7518, 2019.

- [75] Jianbo Tang, Min Deng, Jincai Huang, and Huimin Liu. A novel method for road intersection construction from vehicle trajectory data. *IEEE Access*, 7 :95065–95074, 2019.
- [76] Jianbo Tang, Min Deng, Jincai Huang, Huimin Liu, and Xueying Chen. An automatic method for detection and update of additive changes in road network with gps trajectory data. *ISPRS International Journal of Geo-Information*, 8(9) :411, 2019.
- [77] Håvard Tveite. The QGIS thin greyscale image to skeleton plugin. <http://plugins.qgis.org/plugins/ThinGreyscale/>, 2015–2019.
- [78] Jingdong Wang, Ke Sun, Tianheng Cheng, Borui Jiang, Chaorui Deng, Yang Zhao, Dong Liu, Yadong Mu, Mingkui Tan, Xinggang Wang, et al. Deep high-resolution representation learning for visual recognition. *IEEE transactions on pattern analysis and machine intelligence*, 43(10) :3349–3364, 2020.
- [79] Suyi Wang, Yusu Wang, and Yanjie Li. Efficient map reconstruction and augmentation via topological methods. In *Proceedings of the 23rd SIGSPATIAL International Conference on Advances in Geographic Information Systems*, SIGSPATIAL '15, New York, NY, USA, 2015. Association for Computing Machinery.
- [80] Hao Wu, Hanyuan Zhang, Xinyu Zhang, Weiwei Sun, Baihua Zheng, and Yuning Jiang. Deepdualmapper : A gated fusion network for automatic map extraction using aerial images and trajectories. In *Proceedings of the AAAI Conference on Artificial Intelligence*, volume 34, pages 1037–1045, 2020.
- [81] Junwei Wu, Yunlong Zhu, Tao Ku, and Liang Wang. Detecting road intersections from coarse-gained gps traces based on clustering. *JCP*, 8(11) :2959–2965, 2013.
- [82] Xingzhe Xie, Wenzhi Liao, Hamid Aghajan, Peter Veelaert, and Wilfried Philips. Detecting road intersections from gps traces using longest common subsequence algorithm. *ISPRS International Journal of Geo-Information*, 6(1) :1, 2016.
- [83] Lin Yang, Jing Wei, Zejun Zuo, and Shunping Zhou. Mac-gan : A community road generation model combining building footprints and pedestrian trajectories. *ISPRS International Journal of Geo-Information*, 12(5) :181, 2023.
- [84] Xuankai Yang, Guiling Wang, Jiahao Yan, and Jing Gao. T2i-cyclegan : a cyclegan for maritime road network extraction from crowdsourcing spatio-temporal ais trajectory data. In *Collaborative Computing : Networking, Applications and Worksharing : 16th EAI International Conference, CollaborateCom 2020, Shanghai, China, October 16–18, 2020, Proceedings, Part II 16*, pages 203–218. Springer, 2021.
- [85] Xue Yang, Luliang Tang, Chang Ren, Yang Chen, Zhong Xie, and Qingquan Li. Pedestrian network generation based on crowdsourced tracking data. *International Journal of Geographical Information Science*, 34(5) :1051–1074, 2020.
- [86] Jing Yuan, Yu Zheng, Xing Xie, and Guangzhong Sun. Driving with knowledge from the physical world. In *Proceedings of the 17th ACM SIGKDD international conference on Knowledge discovery and data mining*, pages 316–324, 2011.

- [87] Jing Yuan, Yu Zheng, Chengyang Zhang, Wenlei Xie, Xing Xie, Guangzhong Sun, and Yan Huang. T-drive : driving directions based on taxi trajectories. In *Proceedings of the 18th SIGSPATIAL International conference on advances in geographic information systems*, pages 99–108, 2010.
- [88] Caili Zhang, Yali Li, Longgang Xiang, Fengwei Jiao, Chenhao Wu, and Siyu Li. Generating road networks for old downtown areas based on crowd-sourced vehicle trajectories. *Sensors*, 21(1) :235, 2021.
- [89] Caili Zhang, Longgang Xiang, Siyu Li, and Dehao Wang. An intersection-first approach for road network generation from crowd-sourced vehicle trajectories. *ISPRS International Journal of Geo-Information*, 8(11) :473, 2019.
- [90] Ju Zhang, Qingwu Hu, Jiayuan Li, and Mingyao Ai. Learning from gps trajectories of floating car for cnn-based urban road extraction with high-resolution satellite imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 59(3) :1836–1847, 2020.
- [91] Yongchuan Zhang, Jiping Liu, Xinlin Qian, Agen Qiu, and Fuhao Zhang. An automatic road network construction method using massive gps trajectory data. *ISPRS International Journal of Geo-Information*, 6(12) :400, 2017.
- [92] Renjie Zheng, Qin Liu, Weixiong Rao, Mingxuan Yuan, Jia Zeng, and Zhongxiao Jin. Topic model-based road network inference from massive trajectories. In *2017 18th IEEE International Conference on Mobile Data Management (MDM)*, pages 246–255. IEEE, 2017.
- [93] Baoding Zhou, Tianjing Zheng, Jincai Huang, Yunfei Zhang, Wei Tu, Qingquan Li, and Min Deng. A pedestrian network construction system based on crowd-sourced walking trajectories. *IEEE Internet of Things Journal*, 8(9) :7203–7213, 2020.
- [94] Lichen Zhou, Chuang Zhang, and Ming Wu. D-linknet : Linknet with pretrained encoder and dilated convolution for high resolution satellite imagery road extraction. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, pages 182–186, 2018.
- [95] Yan Zhou, Jiaqi Wang, and Yeting Zhan. An urban road extraction method based on trajectory clustering. In *IGARSS 2022-2022 IEEE International Geoscience and Remote Sensing Symposium*, pages 1268–1271. IEEE, 2022.
- [96] Qiqi Zhu, Yanan Zhang, Lizeng Wang, Yanfei Zhong, Qingfeng Guan, Xiaoyan Lu, Liangpei Zhang, and Deren Li. A global context-aware and batch-independent network for road extraction from vhr satellite imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 175 :353–365, 2021.