



Mesures de similarité pour les trajectoires sémantiques : prise en compte de trois niveaux de granularité

Cécile Cayère, Christian Sallaberry, Cyril Faucher, Marie-Noelle Bessagnet,
Philippe Roose, Maxime Masson

► To cite this version:

Cécile Cayère, Christian Sallaberry, Cyril Faucher, Marie-Noelle Bessagnet, Philippe Roose, et al.. Mesures de similarité pour les trajectoires sémantiques : prise en compte de trois niveaux de granularité. *Revue ouverte d'ingénierie des systèmes d'information*, 2024, 24 (4). hal-04683445

HAL Id: hal-04683445

<https://univ-pau.hal.science/hal-04683445>

Submitted on 2 Sep 2024

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Mesures de similarité multidimensionnelles pour trajectoires sémantiques

Semantic Trajectories Similarity: Measures Addressing Spatial, Temporal and Thematic Dimensions

Cécile Cayèré¹, Christian Sallaberry², Cyril Faucher¹, Marie-Noëlle Bessagnet², Philippe Roose², Maxime Masson²

¹L3i, La Rochelle Université, La Rochelle, France, {cecile.cayere1, cyril.faucher}@univ-lr.fr

²LIUPPA, E2S, Université de Pau et des Pays de l'Adour (UPPA), Pau, France, {christian.sallaberry, marie-noelle.bessagnet, philippe.roose, maxime.masson}@univ-pau.fr

RÉSUMÉ. Ce papier s'inscrit dans le cadre du projet DA3T mené en collaboration avec des géographes. L'objectif est de proposer des méthodes et outils ayant pour objectif de traiter des traces de mobilité. Ce travail est expérimenté dans le domaine du tourisme en vue d'améliorer l'analyse de mobilité de touristes et par conséquent l'aménagement et la valorisation du territoire. Dans le cadre de la conception d'un module de calcul de similarité permettant de comparer deux trajectoires sémantiques, nous présentons deux nouvelles mesures de similarité s'intéressant aux trois dimensions (c.-à-d. spatiale, temporelle et thématique). Les résultats obtenus s'approchent de l'avis des experts et améliorent ceux des mesures de la littérature, dans notre contexte.

ABSTRACT. This paper is part of the DA3T project in collaboration with geographers. The objective is to propose methods and tools to process mobility tracks in order to improve their analysis and consequently touristic territory planning and valorization. As part of the design of a module for computing similarity for computing similarity between two semantic trajectories, we present two new similarity measures addressing all three dimensions (i.e. spatial, temporal and thematic).

MOTS-CLÉS. mesure de similarité, trajectoire sémantique, trace de mobilité.

KEYWORDS. similarity measure, semantic trajectory, mobility track.

Introduction

La traçabilité de la mobilité humaine est un phénomène qui prend beaucoup d'ampleur de par l'évolution des technologies GPS et l'augmentation des déplacements humains. Dans le projet régional Nouvelle-Aquitaine DA3T (c.-à-d. Dispositif d'Analyse des Traces numériques pour la valorisation des Territoires Touristiques), nous exploitons les traces laissées par des touristes afin d'aider les décideurs locaux dans la gestion et l'aménagement des territoires touristiques. Il s'agit d'un projet pluridisciplinaire réunissant informaticiens et géographes dans l'objectif de produire des outils et des méthodes d'analyse de traces de mobilité.

Dans le cadre de ce projet, nous avons développé une application mobile, nommée Geoluciole, permettant de capturer les déplacements de touristes volontaires, auxquels nous avons fait passer des entretiens semi-directifs afin d'obtenir plus d'informations sur ces déplacements (p. ex. activités touristiques pratiquées). Nous avons conçu un modèle générique de description de trajectoires sémantiques (CAYÈRÉ, et al. 2021) et une plateforme modulaire de type **ETL** (pour, *Extract, Transform, Load* permettant la conception et l'exécution de chaînes de traitement dédiées aux traces de mobilité (MASSON, et al. 2022). Ainsi, cette plateforme permet de paramétriser et d'enchaîner des modules de traitement de bas niveau en vue de répondre à un questionnement de plus haut niveau sur un jeu de traces de mobilité. Nous avons expérimenté ces propositions sur différents questionnements et jeux de données dédiés au tourisme ou encore à la migration de colonies d'oiseaux.

Dans cet article, nous nous intéressons à deux modules particuliers de la plateforme. Il s'agit de modules de calcul de similarité de deux trajectoires sémantiques conçus pour la comparaison de déplacements touristiques et adaptable à tout autre type de traces de mobilité. Le travail présenté ici, considère les dimensions spatiale, temporelle et thématique de deux trajectoires sémantiques pour établir leur degré de similarité. Nous nous positionnons dans les domaines informatique et géomatique pour traiter des données de capteurs enrichies. Le verrou scientifique relève de la recherche d'information géographique (RIG) : il s'agit de proposer de nouvelles mesures de comparaison de trajectoires sémantiques combinant trois dimensions spatiale, temporelle et thématique et dont les résultats s'approchent de l'avis des experts. L'originalité tient dans deux hypothèses : la première consiste à observer chaque couple de trajectoires selon les trois dimensions à des niveaux de granularité micro, méso et macro successivement et la seconde consiste à observer les trajectoires selon des perspectives bidimensionnelles (p. ex. spatio-temporel et tempo-thématique).

L'article est organisé comme suit. La partie §1 présente quelques définitions relatives aux trajectoires sémantiques et illustre nos motivations grâce à un scénario utilisant le jeu de données touristiques relatif à l'été 2020 à La Rochelle. La partie §2 fait l'état de l'art des mesures de similarité (et de distance) dédiées aux trajectoires sémantiques. La partie §3 détaille notre verrou et nos hypothèses de travail et présente nos deux mesures dédiée au calcul de similarité de trajectoires sémantiques. La partie §4 évalue ces mesures au travers des expérimentations. Pour finir, la partie §5 conclut cet article et propose quelques perspectives.

1. Trajectoires sémantiques touristiques

L'objet central de nos recherches est la trace de mobilité touristique, elle représente le déplacement d'un objet mobile (p. ex. un touriste) à travers une suite de positions géolocalisées et horodatées. Nous construisons des trajectoires brutes à partir de ces traces selon les besoins de l'analyse. En effet, le concept de trajectoire représente la sous-partie de la trace qui a un intérêt pour une application donnée (PARENT, et al. 2013). Dans nos travaux, les trajectoires sont construites sur des critères spatiaux et/ou temporels (p. ex. la trace d'une semaine d'un touriste pourrait résulter en un ensemble de trajectoires journalières ; on s'intéresse à l'activité d'un touriste durant une journée). Les trajectoires brutes peuvent ensuite être enrichies avec des données externes et deviennent des trajectoires sémantiques.

Ces données d'enrichissement peuvent être de simples labels (p. ex. "Tour de la Lanterne") ou des objets complexes (p. ex. nom : "Tour de la Lanterne", type : "tour", localisation : [46.15579, -1.15712], etc.) et sont liées à la trajectoire entière, à un segment ou à une position de celle-ci. Nous enrichissons les trajectoires avec des objets complexes pouvant représenter n'importe quel phénomène du monde réel, appelés aspects (MELLO, et al. 2019). Dans notre modèle (CAYÈRÉ, et al. 2021), un aspect est lié à la trajectoire par l'intermédiaire d'un ou plusieurs épisodes (c.-à-d. un intervalle temporel) qui définissent la ou les parties de la trajectoire enrichies par l'aspect. Les aspects d'un même type sont liés à une même séquence d'épisodes représentant un axe thématique particulier, appelée interprétation de la trajectoire (p. ex. séquence d'épisodes météorologiques).

Une trajectoire sémantique a une dimension temporelle (c.-à-d. les *timesteps*), une dimension spatiale (c.-à-d. les coordonnées spatiales) et un ensemble de dimensions sémantiques (c.-à-d. les interprétations).

Deux trajectoires sémantiques sont plus ou moins similaires sur une ou plusieurs de leurs dimensions. Par exemple, deux touristes peuvent suivre un même itinéraire sans pour autant pratiquer les mêmes activités ou se déplacer sur une même temporalité. Nous souhaitons comparer deux trajectoires sémantiques en tenant compte de toutes ces dimensions afin d'identifier si deux touristes ont des comportements similaires.

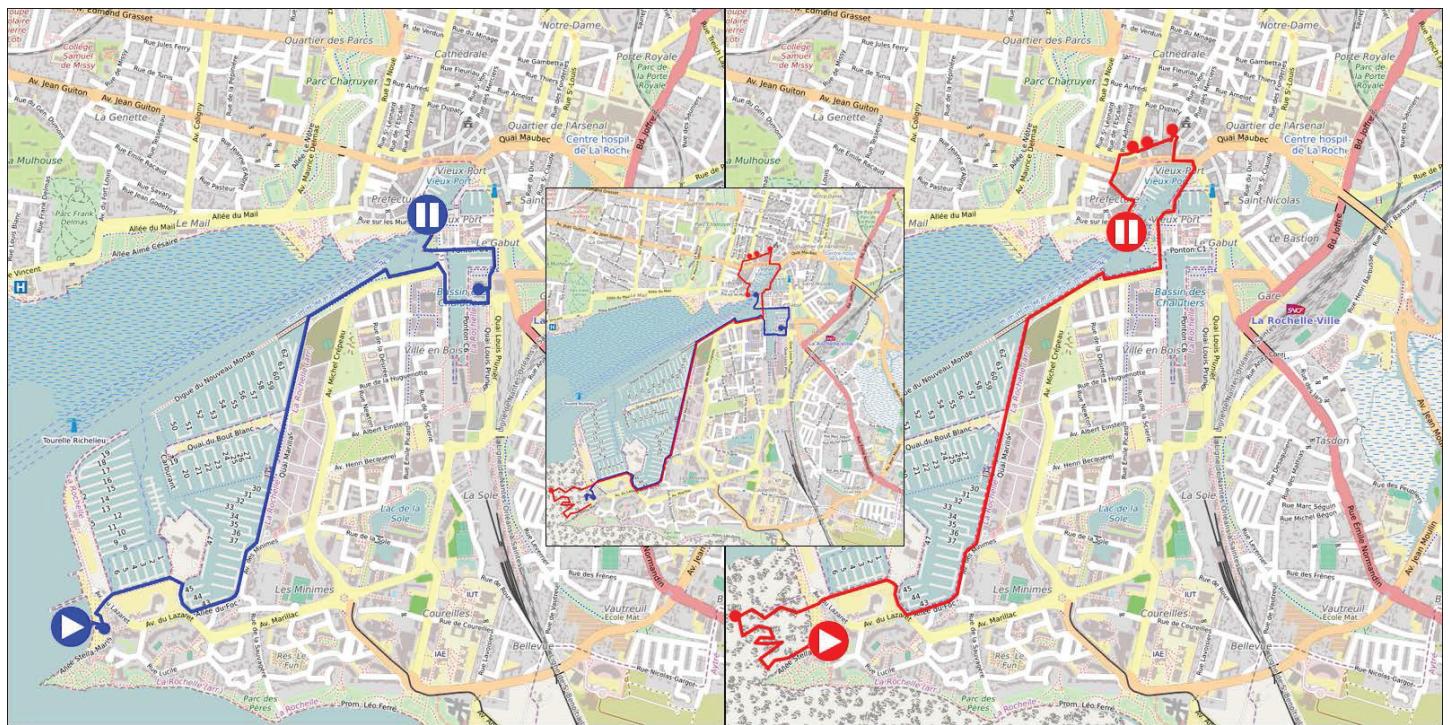


FIGURE 1. Deux trajectoires sémantiques appartenant à deux touristes différents

La figure 1 illustre la dimension spatiale de deux trajectoires sémantiques construites à partir de traces collectées. La figure 2 met en évidence la dimension temporelle à travers un axe du temps ainsi que la dimension thématique grâce à la représentation des différentes interprétations des trajectoires. Les aspects considérés ici sont les points d'intérêt, la météo, la marée et les activités touristiques issues des entretiens. Comparons manuellement ces deux trajectoires :

Dimension spatiale (cf. figure 1) : Des similitudes spatiales sont clairement visibles entre les trajectoires 1 et 2 (respectivement, bleue et rouge). Les deux se situent au centre-ville de La Rochelle et ont un point de départ et d'arrivée plus ou moins similaires (dans les mêmes zones). Les deux trajectoires comportent deux phases plutôt stationnaires ou de visite (c.-à-d. les zones de départ et d'arrivée où les positions sont plus proches les unes des autres) séparées par une phase de déplacement (c.-à-d. les longues lignes sans détour où les positions sont plus éloignées les unes des autres). De plus, il est à noter que les deux touristes traversent la ville en suivant le même chemin. Cependant, les arrêts (c.-à-d. amas de points aux mêmes endroits) que nous pouvons identifier à l'oeil nu ne sont pas les mêmes. Pour améliorer la comparaison, il faudrait pouvoir comparer les deux séquences de coordonnées géographiques. Nous pouvons déduire de toutes ces analyses que, malgré quelques légères différences, les deux trajectoires sont très similaires sur le plan spatial.

Dimension temporelle (cf. figure 2) : Côté dimension temporelle, les deux trajectoires se passent au mois d'août (c.-à-d. l'été). Ensuite, nous pouvons remarquer que l'une des trajectoires se passe le week-end (c.-à-d. un samedi) et l'autre en semaine (c.-à-d. un lundi). La durée des deux déplacements est de 6 heures environ mais ils ne se déroulent pas aux mêmes moments de la journée (l'un se déroule l'après-

description : nuageux
température : 15°C
vent : 8 km/h
station météo : [46.1780556, -1.1930555]
intervalle d'effet : [14/08/2020 17:00, 14/08/2020 18:00]

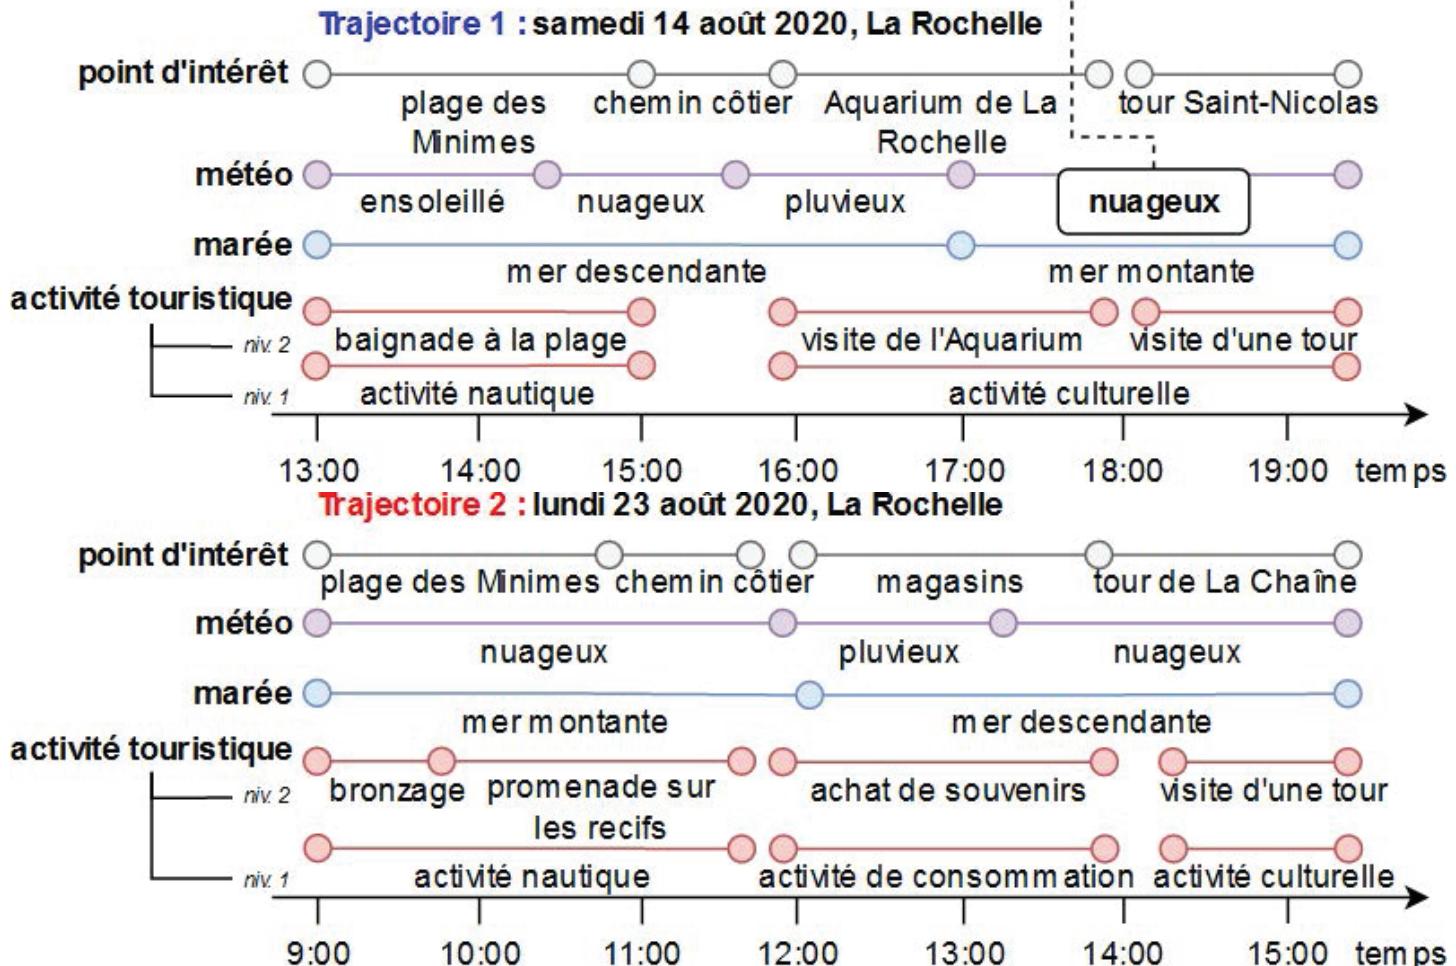


FIGURE 2. Enrichissement des deux trajectoires sémantiques

midi de 13h00 à 19h00, l'autre le matin et en début d'après-midi de 9h00 à 15h00). Ainsi, nous pouvons conclure que mis-à-part l'année, le mois et leur durée, les trajectoires sont plutôt différentes sur le plan temporel.

Dimension thématique (cf. figure 2) : Pour finir, concernant la dimension thématique, quatre interprétations enrichissent la trajectoire (à savoir, les points d'intérêt traversés par le touriste, la météo, la marée et les activités touristiques mentionnées dans l'entretien). L'interprétation concernant les activités touristiques se décompose en plusieurs niveaux de détail. Chaque épisode d'une interprétation (p. ex. l'épisode "nuageux" de la trajectoire 1) est un aspect décrit par un ensemble d'attributs (p. ex. sa description, sa température, etc.) qui ne sont pas tous détaillés ici pour ne pas surcharger la figure. La plus longue sous-séquence partagée par deux trajectoires est appelée plus longue séquence commune (VLACHOS, et al. 2002). En considérant uniquement les points d'intérêt traversés par les touristes, la plus longue séquence commune aux deux trajectoires est telle que :

{plage des Minimes, chemin côtier}

(1)

Nous pouvons aller plus loin grâce aux types (c.-à-d. l'attribut "type") des points d'intérêt, ce qui donne la plus longue séquence commune suivante :

{plage, chemin, tour} (2)

Enfin, en nous intéressant à toutes les interprétations en même temps, nous obtenons la plus longue séquence commune suivante :

{plage des Minimes, (plage des Minimes, nuageux),(chemin côtier, nuageux),
chemin côtier, pluie, (pleine mer, pluie), nuageux, (visite d'une tour, nuageux)} (3)

En observant, cette séquence, on se rend compte qu'il n'y a aucune correspondance quant à l'interprétation des marées. Mis-à-part cette différence, les trajectoires sont plutôt similaires sur le plan thématique.

Nous pouvons conclure que, même dans des contextes différents (c.-à-d. période de la journée et de la semaine, météo, marée, etc.), les profils de ces deux touristes sont assez similaires. En effet, les deux ont pratiqué des activités nautiques puis culturelles et, qui plus est, dans des lieux relativement proches (c.-à-d. plage des Minimes puis centre-ville). Ils ont aussi suivi le même itinéraire (c.-à-d. le long du port de plaisance) pendant une grande partie de leurs déplacements.

Cette comparaison manuelle est un travail fastidieux pour les géographes du projet car beaucoup de paramètres sont à prendre en compte. Un second besoin, qui ressort de nos discussions avec eux, est un outil automatique de comparaison de deux trajectoires sémantiques imitant au mieux le travail des experts.

La similarité (inverse de distance) entre deux trajectoires peut être évaluée grâce à une fonction de similarité (ou de distance) permettant d'attribuer un score qui varie selon leur ressemblance ou leur différence. Un score de similarité est élevé lorsque les trajectoires se ressemblent et faible lorsqu'elles diffèrent; inversement, un score de différence est élevé lorsque les trajectoires diffèrent l'une de l'autre et faible lorsqu'elles se ressemblent. De nombreuses fonctions de calcul de similarité se basent sur une ou plusieurs dimensions des trajectoires, quelques unes sont présentées dans la partie suivante.

2. Travaux connexes

Cette partie a pour but de faire le tour des mesures de similarité (et de distance) existantes permettant d'évaluer la ressemblance de deux trajectoires sur une ou plusieurs dimensions. Il existe déjà plusieurs travaux s'intéressant à comparer et classifier les mesures permettant de comparer des trajectoires (WANG, et al. 2013) (MAGDY, et al. 2015) (CLEASBY, et al. 2019) (SU, et al. 2020) (TAO, et al. 2021), cependant la dimension thématique est souvent omise, n'étant pas la dimension centrale de description du déplacement d'un objet mobile. Dans un premier temps, nous présentons les mesures de similarité spatiale (**i**). Dans un second temps, nous présentons les mesures de similarité temporelle (**ii**). Dans un troisième temps, nous présentons les mesures de similarité thématique (**iii**). Enfin, nous abordons le cas particulier des mesures s'intéressant aux séries temporelles qui peuvent être utilisées pour comparer les différentes dimensions des trajectoires (**iv**).

(i) La dimension spatiale d'une trajectoire GPS est une suite de coordonnées GPS, c.-à-d. une suite de paires (*longitude, latitude*) qui représente plus ou moins fidèlement l'itinéraire emprunté par l'objet mobile. Pour calculer la similarité spatiale entre deux trajectoires, nous pouvons les considérer comme

des suites de points, comme des suites de segments ou nous pouvons les simplifier à leurs enveloppes englobantes. Cela revient à calculer la similarité entre des points, entre des lignes ou entre des polygones. Pour calculer la distance entre deux points d'une trajectoire, il est possible d'utiliser la distance euclidienne (c.-à-d. L_2 -Norm) ou la distance de Manhattan (c.-à-d. L_1 -Norm). La distance euclidienne (ou ED) (FALOUTSOS, et al. 1994) peut être appliquée sur les points d'un espace euclidien à une dimension (p. ex. sur des éléments de séries temporelles) ou plusieurs dimensions (p. ex. sur des points de trajectoires). Pour mesurer la distance entre deux trajectoires dans un espace euclidien, il est possible d'utiliser la distance euclidienne entre les points correspondants des deux trajectoires (distance entre le i -ème point d'une trajectoire avec le i -ème point de l'autre trajectoire) puis d'additionner toutes les distances calculées. C'est la distance euclidienne à étapes bloquées (*lock-step euclidean distance*) (TAO, et al. 2021). Pour calculer la distance entre deux points GPS (sans conversion vers un espace euclidien), il existe la formule de Haversine utilisée pour la première fois en 1805 par James Andrew (ANDREW 1805). D'autres mesures de similarité spatiale se basent sur la division des trajectoires en segments ou en sous-trajectoires qu'elles comparent deux à deux comme la mesure SpADe (*Spatial Assembling Distance*) (CHEN, et al. 2007), la distance de Hausdorff (ALT 2009), AMSS (*Angular metric for shape similarity*) (NAKAMURA, et al. 2013) et TRACLUS (*TRAjectory CLUStering*) (LEE, et al. 2007). Nous réutilisons TRACLUS qui compare deux segments sur trois éléments importants (c.-à-d. parallélisme, distance et angle). Nous souhaitons comparer les polygones englobants les trajectoires. Pour cela, nous pouvons utiliser le système de raisonnement RCC-8 (*Region Connection Calculus*) qui étend les relations entre intervalles temporels d'Allen aux polygones spatiaux (AIELLO 2002) (SALLABERRY 2013) (p. ex. deux polygones sont déconnectés, se superposent, etc.) ou les 9-intersections (EGENHOFER 1997) qui décrivent les relations topologiques pouvant s'appliquer à des polygones, des lignes et des points. La mesure de similarité appliquée à la recherche d'information spatiale présentée dans (LE PARC-LACAYRELLE, et al. 2007) s'appuie sur l'intersection de deux polygones pour évaluer leur similarité, avec un score nul lorsqu'il n'y a pas d'intersection. Nous réutilisons cette dernière mesure car elle permet de comparer deux trajectoires sur un gros grain de détail en utilisant leurs boîtes englobantes.

(ii) La dimension temporelle d'une trajectoire GPS est une suite de marqueurs temporels (*timestamps*). Chaque marqueur est lié à un point de la trajectoire ; le tout représente le déplacement de l'objet mobile observé. La similarité temporelle entre deux trajectoires est souvent calculée de pair avec la dimension spatiale. Cependant, nous nous intéressons dans cette partie à la dimension temporelle uniquement. Pour calculer cette similarité, nous pouvons considérer les trajectoires comme des suites de marqueurs temporels ou des intervalles temporels. Les relations d'Allen (ALLEN 1983) sont un ensemble de 13 relations entre intervalles temporels (p. ex. les intervalles sont égaux, se rencontrent, etc.). Pour une paire d'intervalles donnés, ces relations renvoient des résultats booléens. La mesure de similarité appliquée à la recherche d'information temporelle présentée dans (LE PARC-LACAYRELLE, et al. 2007) s'appuie sur l'intersection entre deux intervalles temporels pour évaluer leur similarité, avec un score nul lorsqu'il n'y a pas d'intersection. Nous réutilisons cette mesure car elle permet de comparer deux trajectoires sur un gros grain de détail en utilisant les intervalles de temps englobants des trajectoires.

(iii) La dimension thématique d'une trajectoire sémantique est un ensemble d'interprétations, c.-à-d. un ensemble de séquences d'épisodes temporels liés à des aspects d'un certain type (p. ex. météo, points d'intérêt, etc.). Ainsi, chaque position correspond à un certain nombre d'épisodes appartenant à différentes interprétations dont il faut tenir compte dans le calcul de similarité. Dans les travaux connexes, afin

d'évaluer la similarité thématique des trajectoires sémantiques, ces dernières sont considérées comme des suites de données d'enrichissement simples (p. ex. label) ou complexes (p. ex. aspects) (chacune correspondant à une position), des suites d'épisodes sémantiques liés à des données d'enrichissement simples ou complexes ou des labels principaux résumant des interprétations spécifiques des trajectoires. Il existe des mesures spécifiquement destinées à comparer des trajectoires multi-aspects comme la mesure TRAFOS (VARLAMIS, et al. 2021) ou la mesure MUITAS (*MULTIple-aspect TrAjectory Similarity*) (MAY PETRY, et al. 2019). Nous réutilisons MUITAS car elle compare des trajectoires multi-aspect telles que nos trajectoires, des seuils sont appliqués pour comparer chaque attribut de chaque aspect et des pondérations régulent l'importance de chaque type d'aspect dans le calcul du score global. De plus, contrairement à TRAFOS, MUITAS ne nécessite pas l'utilisation de toutes les trajectoires du jeu de données pour calculer la similarité entre deux trajectoires. Certaines mesures considèrent les trajectoires comme des suites d'épisodes sémantiques comme la mesure LBS-Alignment (LU, et al. 2009) ou la distance d'édition enrichie (MOREAU, et al. 2018) où toute donnée d'enrichissement comparée doit être considérée au sein d'une ontologie ou hiérarchie de concepts pour être comparée.

(iv) Les mesures LCSS/LCS (*Longest Common Subsequence*), EDR (*Edit Distance on Real sequence*) (CHEN, et al. 2005), ERP (*Edit distance with Real Penalty*) (CHEN, et al. 2004) et DTW (*Dynamic Time Warping*) (KEOGH, et al. 2005) sont des mesures permettant de comparer des séries temporelles qui peuvent être utilisées dans notre contexte. Elles consistent à étudier la proximité des éléments des séries, deux à deux, pour choisir les meilleures correspondances et calculer un score de similarité (ou de distance) final. Plus les éléments mis en correspondance sont éloignés, plus grande sera la pénalité ajoutée au score final. Ces mesures prennent en compte l'ordre entre les éléments mais pas l'écart temporel qui les séparent. Elles peuvent être utilisées pour calculer la similarité des différentes dimensions de la trajectoire. Par exemple, nous réutilisons DTW pour la similarité spatiale qui est très adaptée au calcul de la similarité spatiale car elle utilise directement la distance entre les points sans seuil (dont la valeur peut dépendre de la taille de la trajectoire) et EDR pour la similarité des séquences thématiques car la correspondance des aspects peut être contrôlée avec un seuil.

Les mesures présentées dans cette partie s'intéressent à une ou deux dimensions mais rarement à toutes les dimensions des trajectoires sémantiques ce qui les éloigne de la manière de comparer des experts. Certaines mesures de similarité multidimensionnelle s'intéressent aux trois dimensions des trajectoires sémantiques (LU, et al. 2009), (FURTADO, et al. 2016) (MOREAU, et al. 2018). Bien que très intéressantes, ces mesures ne prennent pas en compte la notion d'aspect dans la dimension thématique ce qui les rend inadaptables à notre contexte. Dans la prochaine partie nous présentons nos deux mesures de similarité.

3. Mesures de similarité DA3T dédiée aux trajectoires sémantiques

Nous proposons deux mesures permettant de calculer automatiquement la similarité entre deux trajectoires sémantiques de deux façons différentes en s'inspirant de l'évaluation manuelle d'experts. Nous rappelons les besoins exprimés par les partenaires du projet et détaillons le verrou et les hypothèses sur lesquelles reposent ces nouvelles mesures (cf. partie 3.1). Ensuite, nous présentons les différentes déclinaisons de notre mesure DA3T (cf. parties 3.2 et 3.3).

3.1. Verrou de recherche et hypothèses de travail

Dans le projet DA3T, les géographes veulent comparer des trajectoires deux à deux (p. ex. comparaison de trajectoires représentatives appartenant à deux catégories de visiteurs différentes, comparaison d'une trajectoire de touriste avec un parcours type de l'Office du tourisme, etc.). Nous avons comparé, dans la partie 1, deux trajectoires sémantiques manuellement. Ce travail s'avère fastidieux pour les experts car beaucoup de dimensions et d'échelles de comparaison doivent être prises en compte. Aussi, nous devons développer des mesures de similarité entre trajectoires sémantiques intégrant les trois dimensions de la trajectoire sémantique (c.-à-d. spatiale, temporelle et thématique) et imitant la manière de comparer des experts. Ainsi, nous définissons notre verrou scientifique.

(V1) Définir une mesure de similarité entre trajectoires sémantiques intégrant les dimensions spatiale, temporelle et thématique et dont les résultats s'approchent de l'avis d'experts.

Afin de lever ce verrou **(V1)**, nous émettons des hypothèses qui guident nos travaux. Il existe des mesures de similarité qui comparent une ou plusieurs dimensions de la trajectoire sémantique mais rarement les trois simultanément. Nous avons abordé certaines de ces mesures dans la partie 2. Afin de comparer les trois dimensions des trajectoires sémantiques simultanément, nous avons conçu et développé deux mesures de similarité basées sur deux hypothèses.

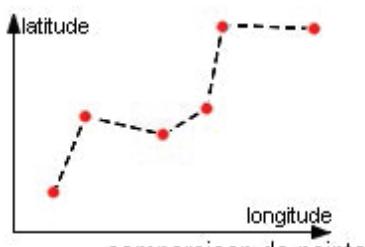
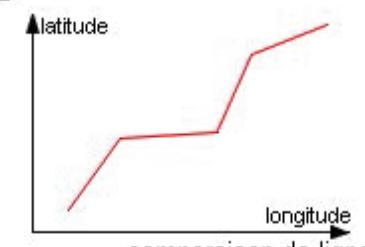
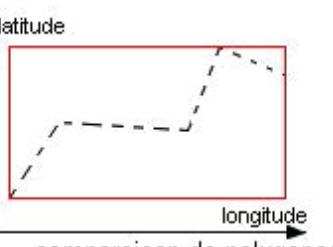
	Micro	Méso	Macro
Spatial	1  comparaison de points	2  comparaison de lignes	3  comparaison de polygones
Temporel	4  comparaison de marqueurs temporels	5  comparaison d'intervalles temporels	6  comparaison de vecteurs de données
Thématique	7  comparaison de données d'enrichissement	8  comparaison de séquences de données	9  comparaison d'ensembles de données

TABLEAU 1. Tableau récapitulatif des dimensions et niveaux de granularité d'une trajectoire sémantique

La première mesure consiste à combiner à l'aide de coefficients de pondération des sous-mesures de similarité spatiale, temporelle et thématique sur trois niveaux de granularité (c.-à-d. grain micro, grain méso et grain macro) chacune. Le tableau 3.1 illustre ces niveaux de granularité. Ainsi, par exemple, deux trajectoires sont comparées sur leur dimension spatiale, d'abord, au niveau de chacun des points relevés par le capteur (grain micro, cf. tableau 3.1, 1), puis, au niveau des segments correspondants (grain méso, cf. tableau 3.1, 2) et enfin, au niveau des boîtes englobantes (grain macro, cf. tableau 3.1, 3). Nous supposons que cette première approche de comparaison, du grain le plus large vers le grain le plus précis, permettra d'imiter l'analyse d'un géographe.

(H1) Combiner des mesures de similarité spatiale, temporelle et thématique permet de bâtir une mesure de similarité globale aux performances supérieures aux mesures de similarité existantes. L'originalité consiste à proposer différentes granularités d'observation de ces dimensions.

La seconde mesure consiste à combiner à l'aide de coefficient de pondération deux sous-mesures de similarité bidimensionnelles. Nous supposons que cette seconde approche de comparaison mettant en valeur une dimension comme dimension pivot permettra d'imiter l'analyse d'un géographe.

(H2) Combiner des mesures de similarité bidimensionnelles (p. ex. spatio-temporelle et tempo-thématique) permet de bâtir une mesure de similarité globale aux performances supérieures aux mesures de similarité existantes.

Ces deux hypothèses font écho au verrou **(V1)** et demandent de concevoir et de développer deux mesures de similarité permettant de comparer deux trajectoires sémantiques. Dans la prochaine partie, nous présentons ces mesures de similarité.

3.2. Mesure unidimensionnelle sur plusieurs niveaux de granularité

Pour valider l'hypothèse **(H1)**, nous mettons en œuvre une mesure de similarité qui combine des sous-mesures spatiales, temporelles et thématiques pondérées par des coefficients. Chacune de ces sous-mesures est la combinaison de trois mesures de niveaux de granularité différents également pondérées par des coefficients (cf. tableau 3.1). Ainsi, par exemple, la dimension spatiale d'une trajectoire est considérée successivement au niveau des points capturés (grain micro, cf. tableau 3.1, 1), au niveau des segments ou des lignes (grain méso, cf. tableau 3.1, 2) et au niveau des boîtes ou polygones englobants (grain macro, cf. tableau 3.1, 3).

Notre première mesure $DA3T_S1_{glb}$ est définie par l'équation 1.

$$DA3T_S1_{glb} = \alpha_{spt} * S_{spt} + \beta_{tmp} * S_{tmp} + \gamma_{thm} * S_{thm} \quad (1)$$

Dans cette formule, chaque sous-mesure du calcul de similarité liée à une dimension spécifique peut être de nouveau détaillée en trois nouvelles sous-mesures liées à des granularités différentes. Le développement de l'équation 1 est détaillé par les équations 2, 3 et 4.

$$S_{spt} = \alpha_{spt-mic} * S_{spt-mic} + \alpha_{spt-mes} * S_{spt-mes} + \alpha_{spt-mac} * S_{spt-mac} \quad (2)$$

$$S_{tmp} = \beta_{tmp-mic} * S_{tmp-mic} + \beta_{tmp-mes} * S_{tmp-mes} + \beta_{tmp-mac} * S_{tmp-mac} \quad (3)$$

$$S_{thm} = \gamma_{thm-mic} * S_{thm-mic} + \gamma_{thm-mes} * S_{thm-mes} + \gamma_{thm-mac} * S_{thm-mac} \quad (4)$$

La somme des coefficients de pondération d'un même niveau (p. ex. α_* , β_* and γ_*) est toujours égale à 1 telle que : $\alpha_{spt} + \beta_{tmp} + \gamma_{thm} = 1$, $\alpha_{spt-mic} + \alpha_{spt-mes} + \alpha_{spt-mac} = 1$, $\beta_{tmp-mic} + \beta_{tmp-mes} + \beta_{tmp-mac} = 1$ et $\gamma_{thm-mic} + \gamma_{thm-mes} + \gamma_{thm-mac} = 1$. De plus toute mesure de similarité S est telle que : $0 \leq S \leq 1$.

Parmi neuf sous-mesures de l'équation 1, nous créons trois nouvelles mesures de similarité $S_{spt-mes}$ (cf. tableau 3.1, 2), $S_{tmp-mac}$ (c. f. tableau 3.1, 6) et $S_{thm-mes}$ (cf. tableau 3.1, 8) et mettons en œuvre six versions modifiées des mesures existantes. Premièrement, les mesures de la dimension spatiale (cf. équation 2) sont les suivantes :

- $S_{spt-mic}$: Pour comparer les trajectoires au niveau des points, nous adaptons la DTW (KEOGH, et al. 2005) et nous y intégrons la distance Haversine (ANDREW 1805). DTW se concentre sur les modèles de trajectoires et ne prend en compte ni le temps de déplacement, ni la vitesse de déplacement (ou le changement de vitesse), ni la fréquence de capture des positions. DTW a besoin de la distance entre chaque paire de points pour calculer la similarité globale des deux trajectoires et nous avons choisi d'utiliser la distance Haversine pour cela. La distance d'Haversine mesure la distance entre deux points GPS.
- $S_{spt-mes}$: Pour comparer les trajectoires au niveau des lignes, nous créons un nouvel algorithme qui utilise TRACLUS (LEE, et al. 2007). TRACLUS permet de comparer deux segments en pondérant trois sous-mesures, chacune s'intéressant à une caractéristique particulière des segments (c.-à-d. leur parallélisme, leur distance et leur angle). Comme nous souhaitons comparer deux trajectoires, notre algorithme compare deux à deux les segments des trajectoires à l'aide de TRACLUS et, pour chacun d'eux, il agrège le meilleur score pour obtenir un score global.
- $S_{spt-mac}$: Pour comparer les trajectoires au niveau des boîtes englobantes, nous implémentons la mesure de similarité appliquée à la RI spatiale (LE PARC-LACAYRELLE, et al. 2007) qui utilise l'intersection de deux polygones pour calculer leur distance.

Ensuite, les mesures de similarité temporelle (cf. équation 3) sont les suivantes :

- $S_{tmp-mic}$: Pour comparer les trajectoires au niveau des horodatages, nous attribuons une période de la journée (par exemple, le matin, l'après-midi, le soir, etc.) à chaque horodatage et nous mettons en œuvre la mesure EDR (CHEN, et al. 2005) pour comparer deux séquences de périodes associées aux trajectoires. Nous considérons qu'il y a correspondance entre deux périodes de temps si elles sont exactement égales.
- $S_{tmp-mes}$: Pour comparer les trajectoires au niveau des intervalles temporels, nous réduisons les intervalles temporels des trajectoires à une échelle quotidienne. Par exemple, dans la figure 1, la trajectoire 1 de 13h à 19h le 14/07/2020 et la trajectoire 2 de 9h à 15h le 23/08/2020 sont résumées comme deux trajectoires de 13h à 19h et de 9h à 15h respectivement, quelque soit le jour précis. Nous appliquons ensuite la mesure de similarité temporelle appliquée à la RI (LE PARC-LACAYRELLE, et al. 2007) qui utilise l'intersection entre deux intervalles temporels pour calculer leur distance.
- $S_{tmp-mac}$: Pour comparer les trajectoires au niveau des contextes temporels, nous créons une nouvelle mesure de similarité pour comparer les vecteurs de données temporelles. Un vecteur de données temporelles est associé à la trajectoire entière (p. ex. "année : 2020, saison : automne, mois : 11, etc."). Ainsi, nous comparons deux trajectoires sur leurs vecteurs de données. Chaque élément des vecteurs qui diffère apporte une pénalité au score. Les valeurs des pénalités sont laissées au choix de l'utilisateur.

Enfin, les mesures de similarité thématique (cf. équation 4) sont les suivantes :

- $S_{thm-mic}$: Pour comparer les trajectoires au niveau des aspects, nous implémentons MUITAS (MAY PETRY, et al. 2019) car il nous permet de comparer les aspects en prenant en compte tous les attributs de chaque aspect. Par exemple, dans la figure 1, les deux premières positions des trajectoires 1 et 2 ont une similarité avec l'aspect "plage des Minimes" et une différence avec les aspects "nuageux" et "ensoleillé" respectivement.
- $S_{thm-mes}$: Pour comparer deux trajectoires au niveau des séquences d'éisodes, nous créons une nouvelle mesure de similarité pour comparer deux épisodes et nous l'intégrons dans la mesure EDR (CHEN, et al. 2005). Les épisodes peuvent être simples (p. ex. épisode lié à un unique aspect "nuageux") ou composés (p. ex. épisode lié à plusieurs aspects "nuageux" et "aquarium de La Rochelle"). Ainsi, si les deux épisodes sont simples, notre mesure renvoie 1 lorsque les aspects sont égaux et 0 sinon. Dans le cas d'éisodes composés, la mesure renvoie la moyenne des scores obtenus par chaque paire d'aspects.
- $S_{thm-mac}$: Pour comparer les trajectoires au niveau des thématiques principales, nous les résumons avec la valeur dominante de chaque aspect et utilisons la mesure LCSS, qui est très adaptée à la comparaison de deux chaînes de caractères. Par exemple, dans la figure 1, en termes de météo, la trajectoire 1, qui est résumée par "nuageux", est similaire à la trajectoire 2, qui est également résumée par "nuageux".

3.3. Mesure bidimensionnelle

Pour valider l'hypothèse (**H2**), nous mettons en œuvre une deuxième mesure de similarité qui combine des sous-mesures spatio-temporelles et tempo-thématiques pondérées par des coefficients. Notre mesure $DA3T_S2_{glb}$ est définie par l'équation 5.

$$DA3T_S2_{glb} = \alpha_{spt-tmp} * S_{spt-tmp} + \beta_{tmp-thm} * S_{tmp-thm} \quad (5)$$

Avec $\alpha_{spt-tmp} + \beta_{spt-tmp} = 1$ et $0 \leq S \leq 1$.

Dans l'équation 5, nous adaptons une mesure existante (cf. $S_{tmp-thm}$) et implémentons une version modifiée d'une mesure existante (cf. $S_{spt-tmp}$) :

- $S_{spt-tmp}$: Pour comparer les trajectoires sur la dimension spatio-temporelle, nous implémentons le STLCSS (VLACHOS, et al. 2002) qui utilise les distances spatiales et temporelles entre deux positions. Un seuil de distance temporelle est ajouté au seuil de distance spatiale existant. Ainsi, il permet d'identifier les trajectoires qui se rapprochent les unes des autres à la même heure de la journée. Par exemple, dans la figure 1, les trajectoires 1 et 2 ont un intervalle temporel commun entre 13h et 15h pendant lequel elles ne sont pas au même endroit ; leur score sera donc faible.
- $S_{tmp-thm}$: Pour comparer les trajectoires sur la dimension tempo-thématique, nous adaptons MUITAS (MAY PETRY, et al. 2019) afin de prendre en compte les horodatages des aspects, deux aspects correspondent lorsqu'ils sont similaires et proches temporellement. Par exemple, dans la figure 1, les trajectoires 1 et 2 ont un intervalle temporel commun entre 13h et 15h pendant lequel les activités et les points d'intérêt sont différents mais la météo et les marées sont similaires.

3.4. Synthèse

Dans cette partie, nous avons présenté deux mesures de similarité issues du verrou de recherche (**V1**) et des hypothèses (**H1**) et (**H2**).

Ces mesures de similarité permettant de comparer deux trajectoires sémantiques sur les trois dimensions des trajectoires sémantiques (c.-à-d. spatiale, temporelle et thématique). La mesure $DA3T_S1_{glb}$ est une combinaison pondérée de trois sous-mesures unidimensionnelles (c.-à-d. sous-mesures spatiale, temporelle et thématique) qui sont, à leur tour, des combinaisons pondérées de trois sous-mesures s'intéressant à des niveaux de granularité différents (c.-à-d. micro, méso et macro) pour la dimension en question. La mesure $DA3T_S2_{glb}$ est une combinaison pondérée de deux sous-mesures bidimensionnelles (c.-à-d. spatio-temporel et tempo-thématique).

Dans la partie suivante, nous expérimentons nos deux mesures de similarité.

4. Expérimentation

L'objectif de cette partie est de présenter l'expérimentation permettant de valider nos deux mesures de similarité entre trajectoires sémantiques et de vérifier si le verrou (**V1**) est levé. Rappelons que pour lever ce verrou, deux hypothèses ont été émises : l'hypothèse (**H1**) que la combinaison de mesures de similarité relatives à chaque dimension selon différents niveaux de granularité (c.-à-d. micro, méso, et macro) permet de bâtir une mesure de similarité globale aux performances supérieures aux mesures de similarité existantes et l'hypothèse (**H2**) que la combinaison de deux mesures bidimensionnelles permet de bâtir une mesure de similarité globale aux performances supérieures aux mesures de similarité existantes.

Dans un premier temps, nous présentons l'expérimentation sur la mesure s'intéressant aux trois dimensions selon plusieurs niveaux de granularité et dans un second temps, celle sur la mesure combinant des sous-mesures bidimensionnelles.

4.1. Description du jeu de données

L'application Géoluciole¹ est une application mobile, disponible sur iOS et Android, que nous avons développée dans le cadre du projet DA3T. Elle est destinée aux touristes visitant La Rochelle, volontaires pour nous partager leur trace de mobilité. Une fois inscrit, l'utilisateur répond à un bref questionnaire sur son contexte de visite (p. ex. Voyage-t-il accompagné ? Est-ce la première fois qu'il visite la ville ? etc.). Il a ensuite le choix d'activer ou pas la capture de son déplacement. Activée, l'application capture à intervalles de temps réguliers la longitude, la latitude, l'altitude et la vitesse de déplacement du téléphone mobile ainsi que l'horodatage et la précision de la capture. Il s'agit d'une valeur, en mètre, correspondant au rayon autour de la position capturée dans lequel se trouve la position réelle ; plus cette valeur est élevée moins la précision de la capture est bonne et inversement. L'envoi des données capturées se fait, après autorisation de l'utilisateur, à une base de données MongoDB hébergée sur un serveur mis en place par nos soins. Nous avons veillé à ce que Géoluciole soit conforme aux réglementations françaises et européennes concernant la protection de la vie privée.

1. Lien GooglePlay : https://play.google.com/store/apps/details?id=fr.univ_lr.geoluciole&hl=fr&gl=US

À l'été 2020, nous avons lancé une campagne de collecte à La Rochelle durant laquelle nous avons collecté 92 traces de mobilité de touristes volontaires avec un total de 118 951 captures et une moyenne d'environ 1 293 captures par trace avec un écart-type d'environ 1 585 et une médiane de 774. Tous les touristes n'ont pas été sollicités au même moment durant leur séjour, certains venaient tout juste d'arriver à La Rochelle, d'autres repartaient le lendemain. Ainsi, dans notre jeu de données, la moyenne des durées des séjours capturés est de 2 jours par touriste.

Parmi l'ensemble des touristes volontaires ayant lancé l'application, 15 ont passé un entretien semi-directif, une fois leurs séjour terminé, afin d'enrichir et de combler d'éventuels blancs dans les traces (dus aux coupures GPS, aux zones blanches, etc.). Ainsi, les entretiens permettent de récupérer des données sur les pratiques touristiques d'un visiteur au cours de sa visite (p. ex. sortie restaurant, baignade, etc.). Ces entretiens ont été retranscrits numériquement.

Le corpus utilisé pour cette expérience est composé de 30 paires de trajectoires touristiques journalières issues de la campagne de collecte Géoluciole. Ces paires représentent une variété de cas différents où les trajectoires peuvent être similaires sur toutes, plusieurs, une ou aucune des dimensions spatiale, temporelle et thématique. Nous avons enrichi ces trajectoires avec des données météorologiques, de lever et de coucher du soleil provenant d'OpenWeatherMap, des données sur les points d'intérêt de La Rochelle provenant de Datatourisme, des données sur les quartiers, les espaces verts, les plages et la marée provenant de La Rochelle Open Data.

4.2. Protocole expérimental

Le protocole de l'expérience est défini par les étapes suivantes :

1. Recueillir l'avis de quatre géographes du projet sur la similarité ou la non similarité de chaque paire de trajectoires, globalement et selon chaque dimension. Ces experts en géographie du tourisme expriment leur avis en notant chaque paire de trajectoires sémantiques selon chaque dimension et globalement (c.-à-d. quatre notes par paire, au total) entre 0 et 5, avec un score de 0 pour les trajectoires qui ne se ressemblent en rien selon eux et une note de 5 pour celles qui se ressemblent parfaitement selon eux.
2. Collecter les résultats issus des deux mesures DA3T $DA3T_S1_{glb}$ et $DA3T_S2_{glb}$ pour chaque paire de trajectoires globalement, selon chaque dimension ainsi que selon chaque niveau de granularité par dimension en ayant fixé les seuils (c.-à-d. les valeurs associées à chaque mesure au-delà desquelles deux trajectoires sont considérées comme similaires par cette mesure) et coefficients.
3. Collecter les résultats issus des mesures DTW (KEOGH, et al. 2005), de similarité de RI temporelle (LE PARC-LACAYRELLE, et al. 2007) et MUITAS (MAY PETRY, et al. 2019) correspondant respectivement aux mesures spatiale, temporelle et thématique de l'état de l'art que nous avons choisi comme référence.
4. Utiliser les métriques de précision, de rappel et de F1-score pour calculer la pertinence des mesures DA3T par rapport à l'avis des experts puis pour la comparer avec les mesures de l'état de l'art. Ces métriques sont essentielles pour comparer les résultats obtenus des mesures par rapport aux résultats attendus par les experts et nous détaillons leurs calculs dans la suite de cette partie.
5. Réitérer les étapes (2) et (4) avec des seuils et coefficients différents afin d'optimiser ces valeurs.

Pour calculer les métriques de précision et de rappel, nous devons d'abord vérifier si les résultats de la mesure correspondent à l'avis des experts (qui nous sert de vérité). Chaque paire de trajectoire est comptée comme un vrai positif (VP), comme un vrai négatif (VN), comme un faux positif (FP) ou comme un faux négatif (FN).

Avis des experts → ↓ Résultats de la mesure	Similaires	Non similaires
Similaires	VP	FP
Non similaires	FN	VN

TABLEAU 2. Catégorisation d'une paire de trajectoires après l'analyse des experts et l'exécution de la mesure

Le tableau 4.2 montre à quoi correspondent ces catégories : une paire de trajectoire est comptée comme un VP si les experts et la mesure évaluent les trajectoires comme similaires, comme VN si les experts et la mesure évaluent les trajectoires comme non similaires, comme FN si les experts évaluent les trajectoires comme similaires et la mesure les évalue comme non similaires et enfin comme FP si les experts évaluent les trajectoires comme non similaires et la mesure les évalue comme similaires.

Ainsi, la précision qui correspond au nombre de paires évaluées similaires par la mesure et par les experts rapporté au nombre de paires évaluées similaires par la mesure mais pas forcément par les experts, se calcule avec l'équation 1.

$$precision = \frac{nb_VP}{nb_VP + nb_FP} \quad (1)$$

Le rappel, qui correspond au nombre de paires évaluées similaires par la mesure et par les experts rapporté au nombre de paires évaluées similaires par les experts mais pas forcément par la mesure, se calcule avec l'équation 2.

$$rappel = \frac{nb_VP}{nb_VP + nb_FN} \quad (2)$$

Enfin, le F1-score, qui combine la précision et le rappel, se calcule avec l'équation 3.

$$f1 - score = 2 * \frac{precision * rappel}{precision + rappel} \quad (3)$$

Présentons maintenant les résultats de l'expérimentation.

4.3. Résultats

Après avoir collecté l'avis des experts concernant la similarité des trajectoires sémantiques pour chaque paire selon chaque dimension et globalement, nous avons calculé leur taux d'accord. Pour cela, nous nous sommes appuyé sur le kappa de Fleiss créé par Joseph L. Fleiss (FLEISS 1971), une mesure statistique permettant de mesurer l'accord entre plusieurs évaluateurs.

	Évaluation spatiale	Évaluation temporelle	Évaluation thématique	Évaluation globale
K-Fleiss	0,53	0,37	0,57	0,66

TABLEAU 3. Évaluation de l'accord entre les experts avec le kappa de Fleiss

Le tableau 4.3 montre les kappa de Fleiss calculés pour les évaluations spatiale, temporelle, thématique et globale. Pour les évaluations spatiale et thématique, il atteint respectivement 0,53 et 0,57, ce qui montre une concordance moyenne entre les avis des experts. Nous constatons que leurs avis sont beaucoup plus mitigés concernant la dimension temporelle pour laquelle le kappa de Fleiss n’atteint que 0,37, ce qui montre une légère concordance entre leurs avis. Pour finir, le kappa de Fleiss atteint 0,66 concernant l’évaluation globale, ce qui implique une concordance satisfaisante.

Nous allons maintenant passer à la présentation et à la discussion des résultats de l’évaluation concernant les deux mesures.

Résultats de l’expérimentation sur la mesure $DA3T_S1_{glb}$

Score	α_*	β_*	γ_*	Seuil	Précision	Rappel	F1-score
$S_{spt-mic}$				0,9	1	0,7	0,824
$S_{spt-mes}$				0,892	1	0,609	0,757
$S_{spt-mac}$				0,010	1	0,583	0,737
S_{spt}	0,33	0,33	0,34	0,616	1	0,737	0,848
$S_{tmp-mic}$				0,15	1	0,680	0,81
$S_{tmp-mes}$				0,2	0,882	0,833	0,857
$S_{tmp-mac}$				0,34	0,941	0,64	0,762
S_{tmp}	0,4	0,4	0,2	0,393	0,941	0,842	0,889
$S_{thm-mic}$				0,56	0,7	0,583	0,636
$S_{thm-mes}$				0,4	0,8	0,444	0,571
$S_{thm-mac}$				0,25	0,9	0,563	0,692
S_{thm}	0,4	0,2	0,4	0,5	0,727	0,727	0,727
$DA3T_S1_{glb}$	0,7	0,2	0,1	0,55	0,938	0,882	0,909

TABLEAU 4. Résultats de l’expérimentation sur la mesure $DA3T_S1_{glb}$

Le tableau 4.4 présente les résultats de l’optimisation des coefficients et des seuils relatifs à la mesure $DA3T_S1_{glb}$ effectuée en s’appuyant sur les avis des experts. Il présente les scores micro, méso et macro en matière de rappel, précision et F1-score pour chaque dimension. Rappelons que pour chaque dimension (c.-à-d. les lignes S_{spt} , S_{tmp} et S_{thm}), la colonne α_* correspond au coefficient appliqué au grain micro, la colonne β_* correspond au coefficient appliqué au grain méso et la colonne γ_* correspond au coefficient appliqué au grain macro. Globalement (c.-à-d. la ligne $DA3T_S1_{glb}$), la colonne α_* correspond au coefficient appliqué à la dimension spatiale, la colonne β_* correspond au coefficient appliqué à la dimension temporelle et la colonne γ_* correspond au coefficient appliqué à la dimension thématique. Les coefficients du tableau 4.4 sont les meilleures valeurs déterminées itérativement au cours du protocole expérimental.

Concernant la dimension spatiale, nous observons de légères disparités dans les résultats pour les grains micro, méso et macro. Le grain micro (c.-à-d. la ligne $S_{spt-mic}$) donne un F1-score de 0,824, supérieur aux deux autres grains (c.-à-d. les lignes $S_{spt-mes}$ et $S_{spt-mac}$). Le score spatial global (c.-à-d. la ligne S_{spt}) prend en compte les trois niveaux de granularité de manière équivalente et nous constatons une

légère amélioration des résultats par rapport à ceux des niveaux de granularité pris individuellement : F1-score de 0,848. Pour ce jeu de données, nous pouvons conclure que les experts utilisent tous les niveaux de granularité dans leur observation d'une trajectoire touristique dans la ville.

Concernant la dimension temporelle, nous observons que, parmi les trois niveaux de granularité, les grains micro et méso (c.-à-d. les lignes $S_{tmp-mic}$ et $S_{tmp-mes}$) donnent des F1-scores légèrement supérieurs à celui du grain macro (c.-à-d. la ligne $S_{tmp-mac}$). Ce grain a moins de poids dans le calcul du score temporel global (c.-à-d. la ligne S_{tmp}) et nous constatons une amélioration : F1-score de 0,889. Ainsi, là encore, il est intéressant de considérer les trois niveaux de granularité pour calculer la similarité temporelle de deux trajectoires sémantiques de ce jeu de données.

En ce qui concerne la dimension thématique, nous observons des scores plutôt faibles pour tous les niveaux de granularité. Les grains micro, méso et macro (c.-à-d. les lignes $S_{thm-mic}$, $S_{thm-mes}$ et $S_{thm-mac}$) donnent respectivement les F1-scores 0,636, 0,571 et 0,692. Nous supposons que ces faibles scores sont dû à un manque de données pour enrichir les trajectoires des touristes. Notons, en revanche, que le score thématique global (c.-à-d. la ligne S_{thm}) montre une amélioration par rapport aux niveaux de granularité séparés : F1-score de 0,727.

Enfin, les résultats obtenus avec la mesure $DA3T_S1_{glb}$ sont supérieurs à ceux des trois mesures dimensionnelles considérées séparément, ce qui valide (**H2**). Le coefficient attribué à la dimension thématique montre que les experts sont légèrement moins intéressés par cette dimension lorsqu'ils comparent deux trajectoires touristiques ; ceci est cohérent avec les résultats plus faibles obtenus pour cette dimension.

Évaluons $DA3T_S1_{glb}$ par rapport aux mesures de référence existantes dans les différentes dimensions. Les mesures de référence choisies sont : DTW présentée dans (KEOGH, et al. 2005) pour la dimension spatiale, la mesure de similarité RI temporelle présentée dans(LE PARC-LACAYRELLE, et al. 2007) pour la dimension temporelle et enfin MUITAS présentée dans (MAY PETRY, et al. 2019) pour la dimension thématique.

Dimension	Mesures de référence			$DA3T_S1_{glb}$
	DTW	RI temp.	MUITAS	
Spatiale	0,824			0,848
Temporelle		0,857		0,889
Thématique			0,636	0,727

TABLEAU 5. Comparaison de $DA3T_S1_{glb}$ avec les mesures de référence sur la base du F1-score

Le tableau 4.5 montre que $DA3T_S1_{glb}$ donne des résultats plus proches de l'opinion des experts que les mesures de référence sélectionnées sur la base de comparaison du F1-score, dans toutes les dimensions.

Passons maintenant à la présentation et à la discussion des résultats de l'évaluation concernant la seconde mesure. nos

Résultats de l'expérimentation sur la mesure $DA3T_S2_{glb}$

Score	$\alpha_{spt-tmp}$	$\beta_{tmp-thm}$	Seuil	Précision	Rappel	F1-score
$S_{spt-tmp}$			0,001	0,8	0,857	0,828
$S_{tmp-thm}$			0,28	0,6	0,818	0,692
$DA3T_S2_{glb}$	0,8	0,2	0,001	0,875	0,824	0,848

TABLEAU 6. Résultats de l'expérimentation sur la mesure $DA3T_S2_{glb}$

Le tableau 4.6 présente les résultats de l'optimisation des coefficients et des seuils relatifs à la mesure $DA3T_S2_{glb}$ effectuée en s'appuyant sur les avis des experts. Il présente les scores spatio-temporel et tempo-thématique en matière de rappel, précision et F1-score. Les coefficients $\alpha_{spt-tmp}$ et $\beta_{tmp-thm}$ du tableau 4.6 sont les meilleures valeurs déterminées itérativement au cours du protocole expérimental.

Les résultats obtenus avec $DA3T_S2_{glb}$ sont supérieurs à ceux des deux mesures bidimensionnelles considérées séparément, ce qui valide (**H2**). Le coefficient attribué à la mesure spatio-temporelle (c.-à-d. la ligne $S_{spt-tmp}$) est beaucoup plus faible que celui attribué à la tempo-thématique (c.-à-d. la ligne $S_{tmp-thm}$). Cela renforce encore l'idée qu'ici les géographes utilisent moins la dimension thématique pour comparer deux trajectoires sémantiques de ce jeu de données.

4.4. Discussion

Les expérimentations menées sur les deux mesures donnent des résultats assez similaires. Cependant, $DA3T_S1_{glb}$ est un peu plus proche de l'opinion des experts que $DA3T_S2_{glb}$. Pour les deux mesures, les sous-mesures incorporant la dimension thématique donnent des résultats faibles. Cela est dû à un manque de données d'enrichissement utiles pour la comparaison. Dans $DA3T_S2_{glb}$, nous nous sommes concentrés sur la dimension temporelle, les deux sous-mesures intègrent cette dimension. Cependant, il est rare que deux trajectoires se chevauchent temporellement et nous avons dû aligner temporellement leurs premiers horodatages pour avoir des résultats pertinents. Ainsi, pour éviter ce type de pré-traitement, nous recommandons d'utiliser $DA3T_S1_{glb}$ pour comparer deux trajectoires sémantiques de touristes et nous recommandons d'utiliser la $DA3T_S2_{glb}$ pour comparer une trajectoire sémantique d'un touriste avec un itinéraire enrichi de l'office du tourisme où les temps de déplacement et de visite sont préalablement estimés.

Ainsi, nous pouvons conclure que le verrou (**V1**) est levé. Nous avons conçu deux mesures de similarité intégrant les dimensions spatiale, temporelle et thématique des trajectoires sémantiques qui donnent des résultats s'approchant plus de l'avis des experts que ceux des mesures existantes.

5. Conclusion

Cet article a permis de présenter deux nouvelles mesures de calcul de similarité permettant de comparer deux trajectoires sémantiques sur les trois dimensions des trajectoires sémantiques (c.-à-d. spatiale, temporelle et thématique). Nos propositions découlent du verrou (**V1**) et des hypothèses (**H1**) et (**H2**). L'intérêt de ces deux mesures repose sur leur décomposition en sous-mesures et sur la mise en place de

coefficients de pondération pour contrôler l'influence des sous-scores sur le score final. La première mesure, nommée DA3T_S1_{glb}, est une combinaison pondérée de trois sous-mesures, chacune s'intéressant à une dimension (c.-à-d. spatiale, temporelle et thématique). Ces sous-mesures dimensionnelles sont, à leur tour, des combinaisons pondérées de trois autres sous-mesures, chacune s'intéressant à un niveau de granularité spécifique (c.-à-d. micro, méso et macro). La seconde, nommée DA3T_S2_{glb}, est une combinaison pondérée de deux sous-mesures, chacune s'intéressant à deux dimensions simultanément (c.-à-d. spatio-temporel et tempo-thématique). Nous avons centré cette mesure autour de la dimension temporelle car cette dernière est centrale dans notre modèle de trajectoire sémantique et dans la notion de trajectoire de manière générale. L'objectif de nos mesures est que leurs résultats s'approchent de l'avis d'un expert sur la similarité de deux trajectoires sémantiques. L'expérimentation mise en place a deux objectifs : le premier est de fixer les coefficients de pondération pour obtenir les résultats les plus proches de l'avis des experts et le second est d'évaluer la mesure vis-à-vis d'autres mesures de la littérature et vis-à-vis de l'avis des experts.

Dans de prochains travaux, nous souhaitons intégrer nos mesures à notre plateforme modulaire pour réaliser une expérimentation de plus grande envergure avec plus d'experts et un plus grand corpus de trajectoires sémantiques. Actuellement adaptées au domaine du tourisme et imitant l'avis d'experts en géographie du tourisme, nos mesures peuvent être améliorées afin de les adapter à des contextes spécifiques (c.-à-d. déplacements humains touristiques ou professionnels, animaliers, etc.) et ainsi être pondérées de façon automatique selon ces contextes d'usage.

Bibliographie

- [1] AIELLO M., *A spatial similarity measure based on games : Theory and practice*. Logic Journal of IGPL, vol. 10, 2002.
- [2] ALLEN J. F., *Maintaining knowledge about temporal intervals*. Communications of the ACM, vol. 26, no 11, p. 832–843, 1983.
- [3] ALT H., *The Computational Geometry of Comparing Shapes*. In Efficient Algorithms : Essays Dedicated to Kurt Mehlhorn on the Occasion of His 60th Birthday, p. 235–248. Berlin, Heidelberg, Springer-Verlag. 2009.
- [4] ANDREW J., *Astronomical and nautical tables*. 1805.
- [5] CAYÈRÉ C., SALLABERRY C., FAUCHER C., BESSAGNET M.-N., ROOSE P., MASSON M., RICHARD J., *Multi-Level and Multiple Aspect Semantic Trajectory Model : Application to the Tourism Domain*. ISPRS International Journal of Geo-Information, 10(9) p. 592, 2021.
- [6] CHEN L., NG R., *On The Marriage of Lp-norms and Edit Distance*. In, p. 792–803, 2004.
- [7] CHEN L., ÖZSU M. T., ORIA V., *Robust and fast similarity search for moving object trajectories*. Proceedings of the ACM SIGMOD International Conference on Management of Data, p. 491–502, 2005.
- [8] CHEN Y., NASCIMENTO M. A., OOI B. C., TUNG A. K. H., *SpADe : On Shape-based Pattern Detection in Streaming Time Series*. In 2007 IEEE 23rd International Conference on Data Engineering, p. 786–795, 2007.
- [9] CLEASBY I. R., WAKEFIELD E. D., MORRISSEY B. J., BODEY T. W., VOTIER S. C., BEARHOP S., *Using time-series similarity measures to compare animal movement trajectories in ecology*. Behavioral Ecology and Sociobiology, vol. 73, no 11, p. 151, 2019.
- [10] EGENHOFER M. J., *Query Processing in Spatial-Query-by-Sketch*. Journal of Visual Languages and Computing, vol. 8, no 4, p. 403–424, 1997.
- [11] FALOUTSOS C., RANGANATHAN M., MANOLOPOULOS Y., *Fast subsequence matching in time-series databases*. ACM SIGMOD Record, vol. 23, no 2, p. 419–429, 1994.
- [12] FLEISS J. L., *Measuring nominal scale agreement among many raters*. Psychological Bulletin, 76(5), p. 378–382, 1971.
- [13] FURTADO, A. S., KOPANAKI D., ALVARES L. O., BOGORNY V. *Multidimensional Similarity Measuring for Semantic Trajectories*. Transactions in GIS, 20(2), p. 280-298, 2016.
- [14] KEOGH E., RATANAMAHATANA C. A., *Exact indexing of dynamic time warping*. Knowledge and Information Systems, vol. 7, no 3, p. 358–386, 2005.

- [15] LEE J.-G., HAN J., WHANG K.-Y., *Trajectory clustering : a partition-and-group framework*. In Proceedings of ACM SIGMOD international conference on Management of data, p. 593–604. New York, NY, USA, Association for Computing Machinery, 2007.
- [16] LE PARC-LACAYRELLE A., GAIOL M., SALLABERRY C., *La composante temps dans l'information géographique textuelle*. Document Numérique, vol. 10, no 2, p. 129–148, 2007.
- [17] LU E. H.-C., TSENG V. S., *Mining Cluster-Based Mobile Sequential Patterns in Location-Based Service Environments*. In 2009 Tenth International Conference on Mobile Data Management : Systems, Services and Middleware, p. 273–278, 2009.
- [18] MAGDY N., SAKR M., ABDELKADER T., ELBAHNASY K., *Review on trajectory similarity measures*. 2015.
- [19] MASSON M., CAYÈRE C., BESSAGNET M.-N., SALLABERRY C., ROOSE P., FAUCHER C., *An ETL-like platform for the processing of mobility data*. In Proceedings of the 37th ACM/SIGAPP Symposium on Applied Computing, SAC '22, p. 547–555, New York, NY, USA, 2022.
- [20] MAY PETRY L., FERRERO C., ALVARES L., RENSO C., BOGORNY V., *Towards semantic-aware multiple-aspect trajectory similarity measuring*. Transactions in GIS, vol. 23, 2019.
- [21] MELLO R. D., BOGORNY V., ALVARES L. O., SANTANA L. H. Z., FERRERO C. A., FROZZA A. A., *MASTER : A multiple aspect view on trajectories*. Transactions in GIS, p. tgis.12526, 2019.
- [22] MOREAU C., DEVOGELE T., ETIENNE L., *Extraction de motifs de trajectoires sémantiques similaires*. In Spatial Analysis and Geomatics. Montpellier, France, 2018.
- [23] NAKAMURA T., TAKI K., NOMIYA H., SEKI K., UEHARA K., *A shape-based similarity measure for time series data with ensemble learning*. Pattern Analysis and Applications, vol. 16, no 4, p. 535–548, 2013.
- [24] PARENT C., SPACCAPIETRA S., RENSO C., ANDRIENKO G. L., ANDRIENKO N. V., BOGORNY V., *Semantic trajectories modeling and analysis*. ACM Comput. Surv., vol. 45, no 4, p. 42 :1–42 :32, 2013.
- [25] SALLABERRY C., *Geographical Information Retrieval in Textual Corpora*. Wiley-ISTE, 2013.
- [26] SU H., LIU S., ZHENG B., ZHOU X., ZHENG K., *A survey of trajectory distance measures and performance evaluation*. The VLDB Journal, vol. 29, no 1, p. 3–32, 2020.
- [27] TAO Y., BOTH A., SILVEIRA R. I., BUCHIN K., SIJBEN S., PURVES R. S., *A comparative analysis of trajectory similarity measures*. GIScience and Remote Sensing, vol. 58, no 5, p. 643–669, 2021.
- [28] VARLAMIS I., SARDIANOS C., BOGORNY V., ALVARES L. O., CARVALHO J. T., RENSO C. et al., *A novel similarity measure for multiple aspect trajectory clustering*. In Proceedings of the 36th Annual ACM Symposium on Applied Computing. New York, NY, USA, Association for Computing Machinery, 2021.
- [29] VLACHOS M., KOLLIOS G., GUNOPULOS D., *Discovering similar multidimensional trajectories*. In Proceedings 18th International Conference on Data Engineering, p. 673–684, San Jose, CA, USA, IEEE Comput. Soc. 2002.
- [30] WANG H., SU H., ZHENG K., SADIQ S., ZHOU X., *An effectiveness study on trajectory similarity measures*. p. 13–22, 2013.