

Contributions Informatiques à l'Observation, la Modélisation et la Simulation des Systèmes Urbains

Nicolas Verstaevel

▶ **To cite this version:**

Nicolas Verstaevel. Contributions Informatiques à l'Observation, la Modélisation et la Simulation des Systèmes Urbains. Modélisation et simulation. Université Toulouse Capitole, 2025. ⟨tel-05379140⟩

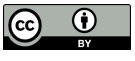
HAL Id: tel-05379140

https://hal.science/tel-05379140v1

Submitted on 24 Nov 2025

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.



Distributed under a Creative Commons CC BY 4.0 - Attribution - International License

Communauté d'universités et établissements de Toulouse

UNIVERSITÉ TOULOUSE CAPITOLE

MÉMOIRE

En vue de l'obtention de l'

HABILITATION A DIRIGER DES RECHERCHES DE L'UNIVERSITE DE TOULOUSE

Délivré par : *l'Université Toulouse Capitole (UT Capitole)*

Présenté et soutenu le *02/10/2025* **par :**

Nicolas Verstaevel

Contributions Informatiques à l'Observation, la Modélisation et la Simulation des Systèmes Urbains

JURY

GUESSOUM Zahia	Maitre de conférences HDR	Université de Reims Champagne-Ardenne
GRISLIN-LE-STRUGEON Emmanuelle	Professeur des Universités	Université Polytechnique Hauts-de-France
SABOURET Nicolas	Professeur des Universités	Université Paris-Saclay
VERCOUTER Laurent	Professeur des Universités	INSA Rouen Normandie
PEREZ Pascal	Professeur	AURIN
CUSSAT-BLANC Sylvain	Professeur des Universités	Université Toulouse Capitole
GAUDOU Benoit	Professeur des Universités	Université Toulouse Capitole

École doctorale et spécialité :
MITT : Domaine STIC : Intelligence Artificielle

Unité de Recherche :
Institut de Recherche en Informatique de Toulouse, UMR 5055 (CNRS)

Professeur référent :
GAUDOU Benoit

Rapporteurs :
GUESSOUM Zahia, *GRISLIN-LE-STRUGEON Emmanuelle* et *SABOURET Nicolas*

Résumé

Ce mémoire présente les activités de recherche de Nicolas Verstaevel, maître de conférences à l'Université Toulouse Capitole, en vue de l'obtention de l'Habilitation à Diriger des Recherches. Ses travaux s'articulent autour de trois axes principaux liés à l'étude des systèmes socio-techniques complexes, notamment dans le contexte de la ville intelligente et de la mobilité.

Le premier axe concerne l'observation des phénomènes urbains à l'aide de l'Internet des Objets et de capteurs. Deux contributions sont présentées dans le cadre du projet "Liverpool Smart Pedestrian" : un dispositif d'analyse de flux vidéo pour le comptage de trafic et un dispositif d'analyse de la qualité de l'air (PM2.5). Ces travaux explorent la question de l'observabilité partielle et de la manière dont les données locales peuvent informer sur des phénomènes macroscopiques.

Le deuxième axe porte sur la construction de modèles par apprentissage artificiel. Une première contribution consiste en un modèle d'apprentissage ensembliste coopératif où l'apprentissage résulte de l'auto-organisation d'agents contextes. Ce modèle est évalué et de nouvelles métriques d'explicabilité sont proposées. Une seconde contribution s'intéresse à l'analyse de la mobilité pour la classification automatique des modes de transport à partir de traces GNSS et d'accéléromètre.

Le troisième axe est consacré à la simulation à base d'agents de phénomènes urbains, avec un focus sur la simulation de foules denses. Ces contributions concernent le couplage de modèles de granularités différentes (HyPedSim) et la prédiction de trajectoires de piétons par l'intégration d'un terme de collision dans la fonction de perte d'un réseau de neurones (TTC-SLSTM).

Ce mémoire ouvre de nouvelles perspectives de recherches autour de la simulation dirigée par la donnée. Un projet de recherche original est proposé, s'appuyant sur cette démarche intégrée associant collecte de données, construction de modèles par apprentissage artificiel et simulation à base d'agents.

Remerciements

Il fut un temps — celui des cartables trop lourds et des cahiers à carreaux — où je croyais que les adultes savaient tout. Et parmi eux, il y avait une caste mystérieuse : les enseignants. Ils portaient des lunettes qui faisaient sérieux, des voix qui portaient loin, et des phrases qui ouvraient des mondes. C'est grâce à eux que j'ai appris que les choses ont un nom, que les idées ont une histoire, et que les questions sont parfois plus précieuses que les réponses. Ils m'ont appris l'importance de la nature et le fonctionnement des choses. La terre tourne autours du soleil, les fleuves ruissellent vers la mer, et les mots peuvent porter des idées comme les bateaux portent les hommes. Ils ne m'ont pas donné la vérité comme on donne une pomme, mûre et brillante, mais ils m'ont appris à la cueillir moi-même, parfois verte, parfois gâtée, toujours instructive.

Plus tard, bien plus tard, j'ai rencontré les scientifiques. Ils n'avaient pas de craie sur les doigts, mais des instruments étranges et des hypothèses pleines d'audace. Ils ne disaient pas "voici la vérité", mais "essayons de la trouver ensemble". Et dans leurs laboratoires, j'ai retrouvé l'émerveillement de l'enfant qui regarde une fourmi porter dix fois son poids, ou une étoile scintiller sans raison apparente.

C'est entre ces deux figures — l'instituteur et le chercheur — que s'est tracé mon chemin. L'un m'a appris à écouter, l'autre à questionner. Et si ce mémoire existe, c'est peut-être pour leur rendre hommage, à eux et à tous ceux qui m'ont appris à chercher sans jamais cesser de croire, mais aussi à l'enfant que j'étais et celui que suis devenu.

Il me semble, en relisant ces pages, que le chemin fut long. Non pas celui des kilomètres - quoi qu'ils furent nombreux -, mais celui des années, des idées, des doutes et des enthousiasmes. Toujours trop long pour les pressés, trop fugace pour les rêveurs, le temps des idées échappe aux horloges. Il avance à sa manière, indomptable, porté par l'élan de ceux qui cherchent sans relâche, et s'arrête parfois juste assez pour laisser une pensée éclore.

Ce mémoire, que l'on dit d'Habilitation, je le vois plutôt comme une vieille valise en cuir, un peu usée, remplie de carnets, de brouillons, de conversations volées au vent, et de silences pleins de sens. Je n'ai pas gravi des montagnes, mais j'ai traversé des collines — celles de la pensée, parfois escarpées, souvent ensoleillées. Et si je suis arrivé jusqu'ici, c'est que, derrière moi, il y avait des voix, des regards, des mains tendues. Alors, avant de parler de science, permettez-moi de parler de reconnaissance

Ma famille m'a appris que servir n'est pas se soumettre, mais se tenir debout pour les autres. Le service public, chez nous, n'était pas un mot d'administration : c'était une manière

d'être, une fidélité au bien commun, une dignité tranquille. Ils m'ont transmis cette idée simple et forte : que l'on travaille pour quelque chose qui nous dépasse, et que l'on enseigne pour que d'autres puissent aller plus loin.

Même si mes travaux leur ont parfois semblé relever du mystère — écoutés comme on écoute une histoire fantastique, avec ce mélange de silence attentif et de sourire complice — ils n'ont jamais douté de leur sens. Derrière l'apparente magie du discours scientifique et des technologies, il y avait pour eux une confiance tranquille : celle qui ne demande à comprendre, mais qui sait pourquoi l'on cherche.

Sur le chemin de la recherche, on croise des visages, des voix, des silences qui comptent. Certains vous bousculent, d'autres vous apaisent, mais tous vous font avancer. Il y eut ceux qui posaient des questions plus grandes que les réponses, et ceux qui savaient écouter sans interrompre. Des collègues devenus amis, des amis devenus repères. Ensemble, nous avons partagé des cafés trop froids, des réunions trop longues, et des idées trop belles pour rester dans un tiroir. À chacun, je dois un éclat de ce mémoire. Il est fait de leurs remarques, de leurs rires, de leurs encouragements, de leurs regards complices quand le doute s'invitait. Ce sont eux, les compagnons de pensée, les artisans de l'ombre, les passeurs de courage.

Ce mémoire, je l'ai écrit à l'ombre des briques roses de la Manufacture des Tabacs, dans ce bâtiment qui confronte le labeur d'hier et les idées de demain. Les murs y parlent bas, mais ils parlent vrai : ils ont vu passer des ouvriers, des étudiants, des chercheurs, et quelques rêves en transit.

C'est là, entre deux cours, entre deux réunions, que j'ai posé mes mots. Avec la lenteur du fonctionnaire qui sait que le temps est compté, mais que la pensée ne se presse pas. Être enseignant-chercheur, c'est naviguer entre deux mondes : celui du savoir, vaste et libre, et celui des politiques, changeant et bruyant. On rame parfois à contre-courant, on ajuste la voile, on esquive les injonctions. Mais on avance, porté par cette conviction têtue que transmettre et chercher sont deux façons d'aimer le monde. Ce texte est né là, dans ce va-et-vient entre les murs de briques et les vagues du réel. Il est le fruit d'une patience, d'une fidélité, et d'un certain entêtement à croire que la pensée mérite qu'on lui fasse place.

Ce mémoire a suivi son cours comme un ruisseau entre les pierres, parfois ralenti, parfois accéléré, toujours guidé par des regards attentifs.

Je remercie les rapporteurs et membres du jury qui ont accepté de l'accueillir, de le lire, de le questionner. Leur exigence, leur disponibilité et leur sens du dialogue ont donné à ce travail une portée qu'il n'aurait pu atteindre seul.

Je tiens également à saluer les institutions qui m'ont offert le cadre nécessaire à son élaboration, et les collègues qui, par leurs échanges et leurs critiques, ont contribué à en affiner les contours. Ce mémoire est le fruit d'un parcours partagé, d'une communauté de pensée, et d'un engagement collectif envers le savoir.

Enfin, je veux remercier Flora et Léo.

Flora, je dois ce que ni la science ni les mots ne peuvent expliquer. Elle est à la fois la pierre et le vent : solide quand je vacille, légère quand je m'alourdis. Elle m'ancre dans le réel et me pousse vers l'ailleurs. Dans ses silences, il y a des encouragements que je n'ai jamais

su formuler moi-même. Et à Léo, mon fils, je dois cette part d'éternité qu'un parent offre au monde sans jamais la posséder. Il est le prolongement de mes gestes, le témoin de mes espoirs, et le rappel constant que le savoir ne vaut que s'il éclaire ceux qui viennent après.

Ces écrits leurs appartiennent autant qu'à moi. Il sont nés de leur présence, de leur patience, et de cette forme d'amour qui ne demande rien, mais qui donne tout. À eux deux, je dois ce que les mots ne disent pas : la joie d'être là, la force d'aimer, et cette forme d'éternité qui ne s'écrit pas dans les pages, mais dans les instants partagés.

Ce travail de mémoire s'achève, mais le chemin, lui, continue. Car la pensée ne connaît ni ligne d'arrivée ni repos complet : elle avance, elle bifurque, elle s'égare parfois, mais elle ne s'arrête jamais. Il reste tant de questions à poser, tant de silences à écouter, tant de mondes à comprendre. Et si ce travail a tracé quelques sillons, il appartient à d'autres — plus jeunes, plus audacieux, plus libres — de les prolonger. Comme les collines de l'enfance, la recherche offre toujours un sentier que l'on n'avait pas vu. Il suffit d'un rayon de lumière, d'un mot juste, ou d'un regard neuf pour qu'un horizon s'ouvre. Alors je referme ces pages, non comme on ferme un livre, mais comme on ferme une porte derrière soi, en sachant qu'elle reste entrouverte — pour les idées, pour les rencontres, et pour les jours à venir.

Table des matières

1 Introduction **15**
- 1.1 Contexte et parcours académique . . . 16
- 1.2 Introduction scientifique . . . 17
- 1.3 Plan du manuscrit . . . 19

2 Observation des Phénomènes Urbains par l'IoT **21**
- 2.1 Introduction . . . 22
- 2.2 L'observabilité partielle des systèmes urbains . . . 22
  - 2.2.1 Le projet "Liverpool Smart Pedestrian" . . . 28
- 2.3 Analyse des flux de trafic par analyse des flux vidéo . . . 29
  - 2.3.1 Contexte des travaux . . . 29
  - 2.3.2 Un dispositif informatique en périphérie de réseau pour l'analyse de flux vidéo de trafic urbain . . . 30
  - 2.3.3 Discussion des résultats . . . 33
- 2.4 Impact de la qualité d'air (PM2.5) sur la mobilité . . . 35
  - 2.4.1 Contexte des travaux . . . 35
  - 2.4.2 Un dispositif de mesure de qualité d'air . . . 37
  - 2.4.3 Discussion des résultats . . . 38
- 2.5 Conclusion et perspectives . . . 38

3 Construction de Modèles par Apprentissage Artificiel **43**
- 3.1 Introduction . . . 44
- 3.2 Apprentissage ensembliste coopératif . . . 44
  - 3.2.1 Contexte des travaux . . . 44
  - 3.2.2 Un algorithme d'apprentissage ensembliste coopératif . . . 48
  - 3.2.3 Discussion des résultats . . . 58
  - 3.2.4 Synthèse . . . 69
- 3.3 Classification des modes de transport . . . 70
  - 3.3.1 Contexte des travaux . . . 70
  - 3.3.2 Évaluation d'un pipeline d'apprentissage machine pour la détection des modes de transport . . . 75

3.3.3 Synthèse . . . 83
3.4 Conclusion et perspectives . . . 84

4 Simulation et Prédiction dans des Foules Denses **87**
4.1 Introduction . . . 88
4.2 Simulation à base d'agents de phénomènes urbains . . . 88
4.2.1 La simulation à base d'agents . . . 88
4.2.2 La modélisation multi-échelles et le couplage de modèles . . . 90
4.2.3 La simulation de foules . . . 92
4.3 Contributions à la simulation de foules denses . . . 94
4.3.1 Cas d'étude : la Fête des Lumières à Lyon . . . 94
4.3.2 Couplage de modèles mesoscopique et microscopique pour la simulation de foules : application à la fête des lumières . . . 97
4.3.3 Prédiction de trajectoires de piétons en foules denses . . . 113
4.4 Conclusion et perspectives . . . 123

5 Conclusion générale et perspectives **127**
5.1 Conclusion générale . . . 128
5.2 Projets de recherche et perspectives . . . 130
5.2.1 Explorer la simulation dirigée par la donnée . . . 130
5.2.2 Modéliser l'impact de la ville sur les usages : explorer le rôle des affordances urbaines . . . 131
5.2.3 Développer l'explicabilité locale des comportements des agents . . . 132
5.2.4 Etudier les apports de l'apprentissage machine à la simulation à base d'agents . . . 134

Table des figures

2.1 Représentation schématique des étapes du processus de traitement [Barthélemy et al., 2019] 31

2.2 Images du prototype et de son boîtier dissipateur thermique en aluminium étanche (IP67) [Barthélemy et al., 2019]. 32

2.3 En haut : tracé du nombre de piétons, véhicules et cyclistes détectés par le capteur entre le 20-02-2019 et le 27-02-2019-. Chaque point d'une série de données représente le nombre d'individus détectés au cours de la dernière minute. On observe le rythme circadien journalier des déplacements. En bas : Nombre de piétons (vert), de vélos (rouge) et de véhicules (jaune) détectés toutes les heures le 23 février 2019.[Barthélemy et al., 2019] 34

2.4 Trajectoire des 631 piétons détectés au cours de l'alerte incendie. [Barthélemy et al., 2019] 35

2.5 Une carte du centre ville de Liverpool (source : OpenStreetMap® sous licence ODbL). À gauche : l'emplacement de l'installation des 20 capteurs. À droite : la co-localisation de deux caméras et d'un capteur de qualité d'air (en violet) sur un pylône. [Barthélemy et al., 2019] 36

3.1 Le cycle d'inférence des agents contextes projette l'espace d'entrée X dans un espace cible Y au travers de trois fonctions de transformation ©C. Blanco-Volle 51

3.2 Représentations graphiques des frontières de décision obtenues pour chaque dataset (lignes) et pour chaque modèle linéaire seul ou dans une instance de Smapy (colonnes). La précision de classification obtenue est indiquée en bas à droite pour chaque cas [Fourez, 2024]. 61

3.3 Visualisation des fonctions 2D utilisées pour générer les ensembles de données pour l'expérience (ligne du haut) et des fonctions approximées par notre modèle (ligne du bas). Les niveaux de couleur approchant le jaune correspondent à des valeurs plus élevées, tandis que les niveaux de couleur approchant le bleu correspondent à des valeurs plus faibles [Blanco-Volle et al., 2024a]. 65

3.4 Visualisation du pavage de l'espace (normalisé entre −1 et 1) par les agents contextes pour la fonction Beale. Chaque rectangle bleu représente un agent *Context*, et le rectangle rouge est un exemple du voisinage généralisé d'une observation. Visualisation des agents *Context* dans le voisinage d'une observation (3.4b). [Blanco-Volle et al., 2024a] 66
3.5 Comparaison de la carte de distribution des observations utilisées pour entraîner le modèle (à gauche) et de la visualisation de l'indice de couverture associé à ce modèle (à droite). [Blanco-Volle et al., 2024a] 66
3.6 Visualisation de la densité (3.6a), du volume moyen (3.6b), et du degré de consensus (3.6c) des agents contextes [Blanco-Volle et al., 2024a]. 68
3.7 Hiérarchie des différents types de données selon [Fourez, 2024] 72
3.8 Schéma récapitulatif des étapes de la détection du mode de transport [Fourez, 2024] 74
3.9 Histogramme du nombre de points par mode de transport [Fourez, 2024]. . . . 76
3.10 Diagramme en barres du nombre de points par mode de transport dans le jeu de données GeoLife à l'issue du pré-traitement [Fourez, 2024]. 78
3.11 Histogramme du nombre de points retenus par mode de transport dans le détaché US-TMD [Fourez, 2024]. 78
3.12 Importances de Gini pour le classifieur Random Forest entraîné avec la meilleure combinaison de paramètres (sélectionnée par validation croisée). Les features d'écarts temporels sont représentées en rouge. Les features issues des données d'accéléromètre sont représentées hachurées [Fourez, 2024]. 82
3.13 Distribution des features `mean_accelerometer_time_delta` (gauche) et `mean_location_time_delta` (droite) en fonction du mode de transport. Les données sont représentées sous forme de diagramme en boite sans les outliers [Fourez, 2024]. 83

4.1 Classification des différents modèles opérationnel [Dang et al., 2024c] 93
4.2 Organisation de la Fête des Lumières en 2022. [Dang, 2025] 95
4.3 Positionnement des caméras pour la captation [Dang, 2025]. 96
4.4 Série temporelle du flux de sortie sur les rues Chenavard et Constantine 97
4.5 Principe général de l'approche [Dang et al., 2024c]. 98
4.6 Architecture de HyPedSim [Dang et al., 2024c]. 100
4.7 Diagramme d'activité des piétons à chaque étape de la simulation [Dang et al., 2024c]. 101
4.8 Illustration du processus de croisement uniforme entre deux chromosomes [Dang et al., 2024c]. 105
4.9 Moyenne et meilleure valeurs de fitness sur 150 générations [Dang et al., 2024c]. 106
4.10 Comparaison des débits observés et simulés (moyenne sur 90 simulations) pour les deux routes de sortie : (**a**) Route de Constantine. (**b**) Route de Chenavard [Dang et al., 2024c]. 107

4.11 Analyse de sensibilité locale sur les 11 paramètres du modèle (**a**) t_{delay}, (**b**) α, (**c**) β, (**d**) A, (**e**) B, (**f**) V^{pref}, (**g**) τ, (**h**) $f_{\min}$, (**i**) $f_{\max}$, (**j**) $\rho_{\min}$, (**k**) $\rho_{\max}$ [Dang et al., 2024c]. 108
4.11 Analyse de sensibilité locale sur les 11 paramètres du modèle (**a**) t_{delay}, (**b**) α, (**c**) β, (**d**) A, (**e**) B, (**f**) V^{pref}, (**g**) τ, (**h**) $f_{\min}$, (**i**) $f_{\max}$, (**j**) $\rho_{\min}$, (**k**) $\rho_{\max}$ [Dang et al., 2024c]. 109
4.12 Carte de densité pour chacun des modèles avec 6000 agents simulés [Dang et al., 2024c]. 111
4.13 Visualisation de la simulation avec 6000 agents. Les agents de couleur rouge sont contrôlés par le modèle CC, alors que les agents de couleur bleue sont contrôlés par le modèle SFM [Dang et al., 2024c]. 112
4.14 Comparaison des temps de calcul pour différents nombre d'agents (en milliers) [Dang et al., 2024c]. 112
4.15 Exemples de trajectoire produisant une bonne précision en terme de distance mais conduisant à une collision (a) et une trajectoire d'évitement de collision (b) [Dang et al., 2024c]. 114
4.16 Résultats d'évaluation pour différentes valeurs de λ sur les jeux de données à faible densité [Dang et al., 2024c]. 121
4.17 Résultats d'évaluation pour différentes valeurs de λ sur les jeux de données à haute densité [Dang et al., 2024c]. 122

Chapitre 1

Introduction

Contents

1.1 Contexte et parcours académique 16
1.2 Introduction scientifique 17
1.3 Plan du manuscrit 19

DANS cette Habilitation à Diriger des Recherche, je présente mes activités de recherche, résultat de douze années de rencontres, d'échanges et de réflexions. Les contributions que j'ai choisi d'intégrer dans ce manuscrit couvrent trois domaines : l'observation des systèmes urbains à l'aide de capteurs, la construction de modèles à l'aide de l'apprentissage artificiel, et la simulation de phénomènes urbains à base d'agents. Dans un premier temps, mon parcours de chercheur permet d'informer le contexte dans lequel ces travaux ont été réalisés. Puis, une introduction scientifique permet d'introduire la démarche scientifique qui guide mes travaux et d'introduire ses les éléments principaux : la complexité des systèmes informatiques appliqués à la ville, au travers de l'Internet des Objets, la construction de modèles par apprentissage artificiel et la simulation à base d'agents. Je conclus en donnant la structure du manuscrit.

1.1 Contexte et parcours académique

En juin 2016, j'ai obtenu le grade de docteur délivré par l'Université Toulouse 3 Paul Sabatier avec ma thèse intitulée «Auto-organisation de dispositifs robotiques par démonstrations» [Verstaevel, 2016] sous la direction de Marie-Pierre Gleizes (Professeure) et de l'encadrement de Christine Régis (Maîtresse de conférences) et Fabrice Robert (Sogeti High Tech) dans l'équipe SMAC du laboratoire IRIT. Cette thèse s'est inscrite dans le cadre d'une convention CIFRE avec l'entreprise Sogeti High Tech (devenue Capgemini Engineering), et aborde la problématique de l'apprentissage par démonstrations en contextes ambiants. De 2016 à 2017, j'ai été ATER à temps plein à l'Université Toulouse 3 Paul Sabatier. Dans cette période, mes travaux se concentrent sur l'apprentissage de modèles dans le contexte de la ville intelligente [Nigon et al., 2017]. J'ai ensuite réalisé 6 mois de postdoctorat dans le cadre du projet régional 3PEGASE pour lequel j'ai proposé un nouveau modèle de détection d'anomalies comportementales chez les personnes âgées [Verstaevel et al., 2018b]. En février 2018, j'ai intégré l'équipe du Smart Infrastructure Facility à l'université de Wollongong en Australie où j'ai travaillé sur des problématiques liées à l'Internet des Objets et à l'analyse de la mobilité [Verstaevel et al., 2020]. Depuis septembre 2019, j'ai intégré le corps des Maîtres de Conférences en Informatique à l'Université de Toulouse Capitole dans l'équipe Système Multi-Agent Coopératifs (SMAC). Mes travaux portent sur l'étude, le contrôle et la simulation de systèmes sociotechniques complexes par le paradigme multi-agents. Ils sont à la conjonction entre les systèmes multi-agents, la simulation et l'apprentissage artificiel. Ils visent à la production de méthodes et d'outils informatiques permettant la modélisation, l'analyse et l'aide à la décision dans des domaines liés aux thématiques de la ville intelligente, sur des applications principalement liées à la mobilité : analyse des flux de trafic, qualité d'air, analyse de traces GPS et modélisation des déplacements piétons. Ces domaines d'applications sont propices pour faire émerger des problématiques liées à la complexité dans les systèmes sociotechniques. Ils permettent aussi d'avoir une approche pluridisciplinaire en abordant des verrous liés aux systèmes complexes.

Durant ces années, j'ai participé à plusieurs projets de recherche : 3Pegase (Plate-forme PrEdictive pour Personnes âGées et ASsistancE) financé par fonds FEDR et la région Oc-

citanie, "Liverpool Smart Pedestrians" financé par le programme *Australian Government Smart Cities and Suburbs*, l'ANR-SWTICH (https://anr.fr/Projet-ANR-19-CE22-0003), l'ANR-DFG MADRAS (https://anr.fr/Projet-ANR-20-CE92-0033). Je suis depuis Janvier 2025 porteur de l'ANR-JCJC MIMICO (https://www.irit.fr/mimico/).

Parallèlement, j'ai co-dirigé deux thèses : celle de Thibault Fourez [Fourez, 2024], soutenue en Juin 2024, thèse CIFRE en collaboration avec le bureau d'études en ingénierie Transport et Mobilité CITEC, et intitulée *Analyzing Human Mobility with an Ensemblist Multi-Agent Context Learning System*, et celle de Dang Huu Tu [Dang, 2025], soutenue en Janvier 2025, thèse issue de l'ANR-DFG MADRAS et intitulée *Simulation and prediction of dense crowd dynamics*. En ce moment, je participe à l'encadrement de trois thèses : celle de Clément Blanco-Volle, thèse CIFRE avec l'entreprise CONTINENTAL qui porte sur la recommandation de vitesse dans les véhicules connectés, celle de Jordan Levy, thèse CIFRE avec l'entreprise SOBEN via leur marque TwinsWheel et qui s'intéresse à la détection d'anomalies explicables dans le contexte de la robotique mobile, et enfin celle d'Elisa Ceuille, financement ministériel dont l'objet est l'étude de l'apport de l'affordance dans les simulations à base d'agents.

Ces travaux couvrent différentes applications où l'outil informatique est utilisé pour étudier, modéliser et prédire les évolutions de systèmes complexes. Ainsi je m'intéresse à l'observation de ces systèmes au travers de différentes sources de données, l'intégration de ces données dans des modèles prédictifs à l'aide de l'apprentissage artificiel, et l'utilisation de ces données pour simuler le comportement des entités dans ces systèmes. Les applications à la ville intelligente présentées dans ce manuscrit permettent d'établir un fil rouge liant mes différentes activités de recherche. Ce manuscrit ne prétend pas réaliser une présentation exhaustive de toutes mes activités de recherche, mais il se concentre sur celles qui ont influencé mon approche des systèmes complexes ont par conséquent alimenté mes réflexions sur mon projet de recherche.

1.2 Introduction scientifique

Dans cette habilitation, je présente mes travaux dans le champ des systèmes socio-techniques complexes, en prenant la ville et ses mobilités comme terrain applicatif. Les systèmes socio-techniques complexes sont caractérisés par l'imbrication d'éléments technologiques et sociaux, où les interactions entre ces composants génèrent des comportements émergents souvent non linéaires et difficiles à prédire. Ces systèmes se distinguent par l'hétérogénéité de leurs composants, leur caractère ouvert, leurs dynamiques imprévisibles, leur grande échelle et leur distribution spatiale. De plus, les interactions multi-niveaux entre des entités locales (au niveau microscopique) conduisent à l'émergence de dynamiques (au niveau macroscopique). Ces interactions sont souvent non linéaires, difficile à spécifier *a priori* et peuvent produire des émergences imprévues à l'échelle globale.

La ville constitue un cadre d'étude particulièrement pertinent pour ces systèmes socio-techniques complexes. Elle est intrinsèquement complexe, difficile à spécifier dans son intégralité, en constante évolution et animée par les interactions d'une multitude d'entités (citoyens,

infrastructures, services). La ville, avec ses applications liées à la mobilité, est ainsi propice à l'émergence de problématiques liées à cette complexité et requiert une approche pluridisciplinaire. La ville peut être envisagée comme un système adaptatif complexe où les interactions locales entre citoyens et les composantes urbaines donnent naissance à des phénomènes macroscopiques tels que la congestion. Étudier et modéliser les liens entre ces niveaux micro et macro permet d'appréhender ces dynamiques urbaines.

Face à cette complexité, l'Internet des Objets (IoT) émerge comme une source de données privilégiée pour l'observation des phénomènes urbains. Le développement conjoint de la ville intelligente et de l'IoT permet désormais de mesurer les traces des interactions à des échelles microscopiques, tant spatiales que temporelles. Grâce à des réseaux de capteurs distribués, l'IoT offre la capacité de collecter des données en temps réel provenant de diverses sources : infrastructures, véhicules, bâtiments, et même comportements individuels. Cette collecte omniprésente à différentes échelles ouvre des opportunités pour observer les dynamiques locales et les intégrer dans des modèles. Cependant, la localité de ces données questionne aussi leur capacité à informer sur des phénomènes macroscopiques à large échelle. Cette question scientifique nécessite le développement de nouveaux outils d'analyse pour à la fois intégrer ces données dans des outils d'aide à la décision et prédire les évolutions possibles de ces systèmes.

L'apprentissage artificiel et la simulation à base d'agents comme des outils d'analyse complémentaires pour appréhender la complexité des villes en présentant des applications liées à l'étude de la mobilité : monitoring des flux de trafic, impact sur la qualité d'air, analyse de trace GPS ou modélisation des foules denses. L'apprentissage artificiel, et plus spécifiquement l'apprentissage supervisé, offre la possibilité de construire des modèles prédictifs à partir des données collectées, permettant de lier les observations locales à des phénomènes macroscopiques. La modélisation à base d'agents, quant à elle, propose une approche ascendante pour modéliser les systèmes complexes en simulant les interactions entre un ensemble d'agents autonomes et leur environnement. Cette approche permet d'étudier l'émergence de comportements macroscopiques à partir de règles locales. Des travaux sur la simulation de foules denses illustrent l'application de la modélisation à base d'agents à des phénomènes urbains complexes.

La démarche méthodologique adoptée dans ce mémoire s'articule autour d'un processus allant de la collecte de données par le biais de l'IoT et d'autres sources vers deux modes d'analyse principaux :

— La **construction de modèles par apprentissage artificiel** pour l'identification de motifs, la prédiction de comportements et l'établissement de liens entre données locales et phénomènes globaux.
— La **construction de modèles à base d'agents** pour la modélisation des interactions et l'étude de l'émergence de dynamiques complexes au sein des systèmes urbains.

Des outils et techniques issus de l'**analyse de sensibilité** et de **l'explicabilité des modèles** sont mobilisées pour qualifier la robustesse des modèles et étudier leurs comportements.

Je présente un projet de recherche visant à associer ces trois axes – collecte de données, construction de modèles par apprentissage artificiel et simulation à base d'agents. Ce projet

s'articule autour de quatre axes principaux :

- Explorer la simulation dirigée par la donnée en utilisant les données empiriques issues de l'IoT et de traces d'utilisateurs pour alimenter et calibrer les modèles de simulation de mobilité.
- Modéliser l'impact de la ville sur les usages en explorant le rôle des affordances urbaines dans la prise de décision des agents au sein des simulations urbaines.
- Développer l'explicabilité locale des comportements des agents en étudiant le comportement des algorithmes d'apprentissage et en extrayant des informations sur la nature du système cible.
- Étudier les apports de l'apprentissage machine à la simulation agents, notamment pour le passage à l'échelle et la calibration des modèles.

Le projet ANR-JCJC MIMICO que j'ai démarré en janvier 2025 est une illustration de ce projet de recherche. Il ambitionne de concevoir et étudier de nouvelles méthodes d'analyse des simulations à base d'agent à partir de l'utilisation et l'explicabilité de modèles de substitution construits par apprentissage artificiel. En appliquant ces méthodes à des problématiques liés à la ville, le projet vise à une meilleure compréhension des systèmes socio-techniques complexes que constituent les villes, en exploitant la synergie entre l'observation par l'IoT, l'analyse par l'apprentissage artificiel et la simulation à base d'agents.

Les défis complexes posés par l'observation, la modélisation et la simulation des dynamiques urbaines au travers de l'informatique, se sont imposés à moi comme un cadre propice à l'étude des systèmes complexes. Les verrous identifiés, allant de l'observabilité partielle à la prédiction de comportements émergents, en passant par l'intégration de données hétérogènes et le passage à l'échelle des modèles, constituent autant de pistes de recherche que ce mémoire ambitionne d'éclairer à travers les travaux qui suivent. J'invite dès lors le lecteur à parcourir les chapitres suivants, où mes contributions et perspectives qui en découlent sont exposées plus en détail.

1.3 Plan du manuscrit

Le manuscrit est structuré autour de trois chapitres, abordant chacun un des axes de mes contributions : l'observation de phénomènes urbains dans la ville intelligente (Chapitre 2), la construction de modèles par l'apprentissage artificiel (Chapitre 3), et la simulation à base d'agents (Chapitre 4). Chaque chapitre comporte une introduction pour positionner les travaux dans le contexte scientifique, puis la description de deux contributions. Une conclusion permet de dégager des perspectives de recherche dans la continuité de ces travaux. Enfin, un projet de recherche original et présenté en Chapitre 5. La structure détaillée du manuscrit est donc la suivante.

Le Chapitre 2 positionne des contributions dans le domaine de la ville intelligente et de l'Internet des Objets. Il établit les caractéristiques complexes de ces systèmes en proposant d'étudier les liens entre l'observabilité locale de phénomènes et leurs effets macroscopiques (Section 2.2). Les deux contributions présentées s'inscrivent dans le cadre du projet "Liverpool

Smart Pedestrian " (Section 2.2.1). La première (Section 2.3) décrit un dispositif d'analyse des flux de mobilité par l'analyse de flux vidéos. Le dispositif repose sur l'utilisation d'une architecture de réseau de neurones en périphérie pour effectuer les traitements et garantir l'anonymisation des données. La seconde (Section 2.4) concerne un dispositif d'analyse de qualité d'air. Ce dispositif est évalué comparativement à des dispositifs de références et des résultats de déploiement urbains sont donnés. La Section 2.5 conclut cette première partie en proposant des perspectives et poursuites à ces travaux.

Le Chapitre 3 aborde la construction de modèles par l'apprentissage automatique. Une première contribution présente un modèle d'apprentissage coopératif ensembliste (Section 3.2). Ce modèle propose une approche originale où le processus d'apprentissage résulte de l'organisation d'un ensemble de modèles. Des expérimentations sont présentées et de nouvelles métriques d'explicabilités sont proposées. Une seconde contribution porte sur la classification automatique de traces de mobilité en fonction du modes de transports (Section 3.3). Un pipeline de traitement est détaillé et évalué par la comparaison de différents algorithmes. Un nouveau jeu de données est aussi introduit. L'originalité de la contribution repose sur la prise en compte des écarts temporels dans l'analyse des *features*. Une étude de l'importance de la prise en compte des écarts temporels montre l'amélioration des résultats de classification. La Section 3.4 conclut par de nouvelles perspectives de poursuite des travaux.

Le Chapitre 4 présente des contributions à la simulation à base d'agents. La section 4.2 contextualise les travaux et problématiques, en introduisant la problématique du couplage de modèles et le domaine de la simulation des foules. La Section 4.3 est consacrée à des contributions à la simulation de foules denses issues de l'ANR-DFG-MADRAS (https://anr.fr/Projet-ANR-20-CE92-0033). La Section 4.3.1 décrit la fête des lumières qui sert de cas d'étude aux travaux. La Section 4.3.2 présente HyPedSim, un modèle de simulation de foules denses qui repose sur le couplage entre des modèles de granularité différente. Le modèle est évalué et calibré sur la fête des lumières, et des expérimentations de passage à l'échelle permettent d'étudier ses performances. La Section 4.3.3 présente une seconde contribution, qui porte sur la prédiction de trajectoires de piétons. Un nouveau modèle, TTC-LSTM est décrit et évalué. L'originalité de l'approche repose sur la prise en compte d'un terme modélisant les collisions entre agents dans la fonction d'apprentissage. La Section 4.4 conclut en proposant de nouvelles perspectives qui fixent les bases d'un nouveau projet de recherche.

Enfin, le chapitre 5 conclut ce mémoire par une synthèse des travaux (Section 5.1) qui permettent de proposer quatre axes de recherches (Section 5.2) : explorer la simulation dirigée par la donnée (Section 5.2.1), modéliser l'impact de la ville sur les usages en étudiant rôle des affordances urbaines (Section 5.2.2), développer l'explicabilité locale des comportement agents (Section 5.2.3) et étudier les apports de l'apprentissage machine à la simulation agents (Section 5.2.4).

Chapitre 2

Observation des Phénomènes Urbains par l'IoT

Contents

2.1 Introduction 22
2.2 L'observabilité partielle des systèmes urbains 22
2.2.1 Le projet "Liverpool Smart Pedestrian" 28
2.3 Analyse des flux de trafic par analyse des flux vidéo 29
2.3.1 Contexte des travaux 29
2.3.2 Un dispositif informatique en périphérie de réseau pour l'analyse de flux vidéo de trafic urbain 30
2.3.3 Discussion des résultats 33
2.4 Impact de la qualité d'air (PM2.5) sur la mobilité 35
2.4.1 Contexte des travaux 35
2.4.2 Un dispositif de mesure de qualité d'air 37
2.4.3 Discussion des résultats 38
2.5 Conclusion et perspectives 38

2.1 Introduction

Ce chapitre présente les contributions qui visent à concevoir des outils informatiques et infrastructures logicielles pour étudier des phénomènes urbains liés à la mobilité et son impact sur la qualité d'air. Ces contributions s'inscrivent dans un cadre plus large de la ville intelligente et de l'Internet des Objets. Le chapitre explore ainsi la problématique de l'observabilité partielle dans ces systèmes, où des phénomènes sociaux macroscopiques ne peuvent être observés que partiellement localement ou par l'utilisation de proxys environementaux. En effet, on ne peut pas observer directement tous les déplacements des citoyens dans une ville, mais des données de transport (trafic routier, usage des transports en commun, localisation des smartphones) servent de proxys pour comprendre les flux de population. Similairement, les effets du changement climatique sur les sociétés ne sont pas toujours directement mesurables, mais indicateurs comme la fréquence des événements extrêmes (canicules, sécheresses) permet de tracer des tendances. Dans un premier temps, nous nous positionnons par rapport aux concepts de Ville Intelligente et d'Internet des Objets. Nous discutons des propriétés de ces systèmes physiquement réparties et de la nature des phénomènes qu'ils tendent à observer ou contrôler. Dans un second temps, nous présentons deux contributions : l'une s'intéressant à l'analyse des flux de mobilité à l'échelle d'un quartier par l'analyse des flux de caméra de surveillance, l'autre s'intéressant à l'analyse de la qualité de l'air (PM2.5). À partir de ces deux contributions, nous discutons de l'usage de l'Internet des Objets et de proxy pour observer l'impact des mobilités humaines. Les travaux présentés dans ce chapitre font référence aux publications suivantes : [Arshad et al., 2019] [Barthélemy et al., 2019] [Guastella et al., 2021] [Verstaevel et al., 2017a] [Verstaevel et al., 2020] [Forehead et al., 2020] [Ogie and Verstaevel, 2020] [Verstaevel et al., 2017a]

2.2 L'observabilité partielle des systèmes urbains

Bien que son usage soit devenu courant, il n'existe pas de définition formelle d'une *Smart City*. Ce terme, polysémique, présente des usages qui dépendent des intérêts de ses utilisateurs. Plusieurs travaux d'analyse de la littérature scientifique proposent une description des propriétés, des usages et des concepts qui peuplent l'idée de *Smart City*. Par exemple, dans une revue de la littérature datant de 2013, [Dameri and Cocchia, 2013] étudient l'évolution des termes *Smart City* et *Digital City* entre 1993 et 2013. [Montes, 2020] propose une analyse du terme *Smart City* de 1987 à 2020 pour mettre en avant qu'il est le résultat d'un

Cette section s'appuie sur l'article: Verstaevel, Nicolas, Jérémy Boes et Marie-Pierre Gleizes. **From Smart Campus to Smart Cities : Issues of the Smart Revolution**. *Issues of the Smart Revolution. 2nd Workshop on Smart and Sustainable Cities (WSSC 2017) in association with the IEEE Smart World Congress 2017, Jul 2017, San Francisco Bay, United States.* 2017.

Cette section s'appuie sur l'article: Julien Nigon, Verstaevel, Nicolas, Jérémy Boes, Frédéric Migeon et Marie-Pierre Gleizes. **Smart is a matter of context**. *Modeling and Using Context : 10th International and Interdisciplinary Conference, CONTEXT 2017, Paris, France, June 20-23, 2017, Proceedings 10. Springer International Publishing, p. 189-202.*. 2017.

processus historique de transformations qui ont affectés l'émergence et le développement des *Smart City*. On peut trouver plusieurs origines au terme de *Smart City*, par exemple dans la technopolis de [Gibson et al., 1992]. Mais c'est probablement à IBM que l'on doit sa large diffusion, via son initiative de marketing *"Smarter Cities"* de plusieurs millions de dollars en 2008 [Palmisano, 2009].

[Peirce et al., 2013] positionne le concept comme résultant de l'émergence d'un besoin de contrôle par les pouvoirs publics sur l'organisation de la ville. La constitution des État-Unis impose un recensement de la population tous les 10 ans. La compilation manuelle des résultats du premier recensement a pris 3 ans aux agents (de 1790 à 1793) pour être présentée. Le recensement établit alors une population de 4 millions d'habitants. Le traitement des données du recensement de 1880 prendra 7 ans de traitement manuel, pour aboutir à une population de 50 millions d'habitants. En suivant ce rythme, le traitement des données du prochain recensement de 1890 risquait de produire des résultats obsolètes avant même de pouvoir être complètement analysé.

[Peirce et al., 2013] voit dans cet évènement ce que James Beniger a appelé « la révolution du contrôle » de la fin du 19e siècle. [Beniger, 1992] décrit une époque où « les innovations en matière de traitement de l'information et de technologies de communication étaient à la traîne par rapport à celles de l'énergie et de son application à la fabrication et au transport ». La forte croissante urbaine et technologique des villes rend ce processus complexe à mesurer.

La solution au traitement des données de recensement sera mécanique par la création d'une tabulatrice à carte perforée conçue par l'ingénieur Herman Hollerith. L'usage de cette machine permettra un gain de temps (et d'argent) et conduira à la création de la compagnie *Computing-Tabulating-Recording Company* qui deviendra par la suite *Business Machines Corporation* (IBM).

Ainsi, la *Smart City* s'inscrit dans l'évolution d'un ensemble de termes, "ville connectée", "ville intelligente", "ville digitale", dont le sens vise à promouvoir la convergence entre les technologies de l'information et de la communication, et les villes dans un objectif de contrôle. Le concept de *Smart City* s'est non seulement répandu dans différents domaines scientifiques, mais il a également eu un impact sur la société civile, comme l'illustre l'utilisation du terme par les politiciens, les gouvernements des villes et les entreprises de toutes sortes. Cette utilisation large et multidisciplinaire du terme *Smart City* rend difficile la proposition d'une définition précise et consensuelle. [Gracias et al., 2023] propose comme définition : "Les villes intelligentes utilisent les technologies numériques, les technologies de communication et l'analyse de données pour créer un environnement de service efficace et efficient qui améliore la qualité de vie urbaine et promeut la durabilité."

Initialement, ce besoin de contrôle donne naissance à des applications liées à la nécessité pour les villes de gérer leurs différents actifs : énergie, eau, gestion des déchets, logistique, ou encore transport [Neirotti et al., 2014]. [Hall et al., 2000] décrit la Smart City comme « une ville qui surveille et intègre l'état de toutes ses infrastructures critiques, y compris les routes, les ponts, les tunnels, les rails, les métros, les aéroports, les ports maritimes, les communications, l'eau, l'électricité et même les principaux bâtiments, pour mieux optimiser ses

ressources, planifier ses activités de maintenance préventives et contrôler les aspects liés à la sécurité tout en maximisant les services offerts à ses citoyens ». Cette vision promeut une approche descendante (top-down), où la technologie est vue comme un levier permettant l'optimisation de la prise de décision par les pouvoirs publics. La ville intelligente devient alors une chambre de contrôle qui nécessite des investissements technologiques pour traiter les larges volumes de données.

À cette vision descendante (top-down) de la ville s'est vue opposer une approche ascendante (bottom-up). La principale critique à cette approche orientée technologie ([Pisani and (France), 2015] parle de "datapolis") est qu'elle aborde la technologie comme une finalité sans en questionner l'usage. L'objectif premier est ainsi l'optimisation des processus et des flux existants. Ainsi, [Yin et al., 2015] questionne l'usage : « À travers les âges, le récit du développement technologique et urbain [...] a largement ignoré les besoins des groupes socio-environnementaux d'éléments interactifs et interdépendants. En s'alliant à la logique du capitalisme, il a favorisé la prolifération d'agendas économiques favorables à la croissance, qui ont été responsables de l'inégalité sociale et de la dégradation de l'environnement. [...] Le monde façonné par les projets de villes intelligentes est, pour paraphraser Horkheimer, un monde de moyens. Mais quelles sont les finalités ? Que vise en définitive le phénomène des villes intelligentes en dehors des intérêts économiques des élites capitalistes ? En d'autres termes, les questions clés sont les suivantes : intelligent pour quoi et pour qui ? ». L'approche ascendante pose comme axiome qu'une ville est faite pour des citoyens [Breuer et al., 2014]. La ville intelligente n'est pas qu'un ensemble d'infrastructures et d'architectures, mais un moyen par lequel des citoyens interagissent. La technologie peut agir comme facilitateur pour permettre la collaboration entre les citoyens et aborder des problématiques sociétales et environnementales. [Breuer et al., 2014]([Pisani and (France), 2015] parle dans ce cas de "participolis").

L'approche ascendante (bottum-up) centrée sur les utilisateurs pose de nouveaux défis à la conception de systèmes informatiques. Il devient difficile (voir impossible) de spécifier *a priori* les objectifs et les interactions dans ces systèmes aux utilisateurs variés. De plus, l'aspect intrinsèquement interdisciplinaire des villes intelligentes, impliquant de nombreux domaines tels que l'urbanisation, les sciences sociales ou l'informatique, complexifie cette spécification. Pour pallier ces limites, des espaces d'innovation, de co-conception et de laboratoires vivants se sont construits avec pour objectif de favoriser un processus d'interaction, d'innovation et de co-conception en impliquant toutes les parties prenantes (gouvernements, entreprises, citoyens, utilisateurs...) [Breuer et al., 2014].

Mes travaux: *Living Lab et co-innovation*

Les travaux présentés dans ce document s'inscrivent dans cette démarche de co-innovation et d'émergence de nouveaux usages numériques par l'expérimentation in vivo. Les travaux des sections 2.2.1, 2.3 et 2.4 ont été réalisés dans le cadre du Digital Living Lab de l'Université de Wollongong (Australie) et en contact avec des instances gouvernementales. Le GIS neOCampus (https://www.irit.fr/neocampus/), regroupement de 20 laboratoires visant à créer des synergies en recherche et innovation entre laboratoires autour de l'Internet des Objets (IoT), a permis de supporter les experimentations des thèses de Thibault Fourez [Fourez, 2024] (avec l'entreprise CITEC), de Clément Blanco-Volle (avec l'entreprise CONTINENTAL) ou encore celle de Jordan Levy (avec l'entreprise SOBEN/TwinsWheel) au sein de laboratoire commun DRiOC. Même si les contributions sont d'ordres techniques, elles s'inscrivent dans une démarche d'expérimentation de solutions digitales appliquées à la ville.

Une autre difficulté vient d'une inversion dans le processus de contrôle. On peut prendre l'exemple des réseaux électriques (smart-grid) comme illustration de cette inversion du contrôle [Khalid, 2024]. Les réseaux électriques sont historiquement des systèmes conçus pour transporter l'énergie des organes de productions vers les usagers dans une approche descendante. La multiplication des sources locales de production (panneaux solaires, éoliens ...), les marchés de l'énergie et les modifications de consommation des usagers modifient cette vision descendante des systèmes puisque des producteurs et consommateurs locaux peuvent apparaître dynamiquement dans le réseau complexifiant la maintenance et l'évolution des systèmes électriques. La ville peut être vue comme un système adaptatif complexe composé de services, de ressources et d'acteurs en interaction spatiale et temporelle [Khan et al., 2022]. On peut alors adopter une approche *bottom-up* des phénomènes urbains : des agents (les citoyens) interagissent quotidiennement et localement avec un système (la ville et ses composants) et des phénomènes macroscopiques émergent de ces interactions locales. La mobilité illustre bien ce phénomène : des choix et préférences individuels au niveau microscopique en termes de mode et de trajets conduisent à la formation aux niveaux macroscopiques de phénomènes de congestion. Réciproquement, on peut aussi s'intéresser à des phénomènes d'influence du niveau macroscopique vers le niveau microscopique. Ainsi une politique publique peut vouloir influencer ou contraindre la décision des agents. L'existence de liens entre niveaux microscopiques et macroscopiques n'est pas une propriété spécifique à la ville, et existe dans de nombreux systèmes complexes comme la biologie.

Mes travaux: *Étude du lien micro/macro dans la ville*

Du point de vue d'un informaticien, les applications des villes intelligentes présentent des propriétés intrinsèques communes aux systèmes complexes, tels que l'hétérogénéité des composants, la non-linéarité, l'ouverture, des dynamiques non prédictibles, la grande échelle et la distribution spatiale [Verstaevel et al., 2017a]. Au-delà de ces caractéristiques, ce sont des applications intéressantes pour étudier et comprendre la manière dont des phénomènes locaux influencent des dynamiques globales et vice versa. En effet, la complexité de ces systèmes socio-techniques repose en partie sur des interactions non linéaires et multi-niveaux entre des entités locales (micro) et des dynamiques observées à l'échelle globale (macro) [Batty, 2013]. Par exemple, une amélioration locale de l'efficacité énergétique peut avoir des répercussions significatives sur la consommation globale de ressources de la ville. Cependant, ces effets ne sont pas toujours prévisibles et c'est pourquoi je m'intéresse à la conception de modèles et d'outils spécifiques pour étudier ces phénomènes.

Une nouveauté offerte par le paradigme de la Smart City est la possibilité d'observer ces phénomènes à l'échelle microscopique sur de nouvelles échelles spatiales et temporelles. En effet, à l'échelle macroscopique, il existe des outils (statistiques et empiriques) permettant d'extraire et d'étudier des indicateurs sur différents aspects. Ainsi, les recensements de population permettent de fournir une information représentative de la composition du territoire, ou les enquêtes ménages et déplacement de donner une échantillon de la répartition entre les différents modes de déplacement.

Le développement conjoint de la ville intelligente avec celui de l'Internet des Objets (et plus généralement de l'informatique), permet maintenant de mesurer les traces des interactions à des échelles microscropiques. L'IoT se révèle être une technologie intéressante en matière de collecte d'informations locales sur des échelles temporelles et spatiales étendues. Grâce aux capteurs distribués et à des réseaux de communications dédiés, l'IoT permet de capturer des données en temps réel provenant de diverses sources telles que les infrastructures urbaines, les véhicules, les bâtiments, et même les comportements individuels des citoyens [Gubbi et al., 2013]. Cette capacité de collecte omniprésente et granulaire offre une opportunité sans précédent d'observer les dynamiques locales et de les intégrer dans des modèles globaux. L'Internet des Objets est un facilitateur, mais son utilisation nécessite une approche équilibrée qui considère à la fois les avantages technologiques et les implications socio-éthiques. En effet, l'intégration de l'IoT dans le tissu urbain pose des défis significatifs, notamment en termes de vie privée : la collecte constante de données personnelles et comportementales soulève des préoccupations éthiques et juridiques [Karale, 2021]. Une autre limite actuelle de l'IoT appliqué à la smart city réside dans le manque d'interopérabilité nécessaire pour permettre des combinaisons d'usages innovants [José and Rodrigues, 2024]. En l'absence de modules, services ou objets standardisés et largement disponibles, les initiatives de villes intelligentes peinent à offrir des solutions réelles et intégrées. Pour combler cette lacune, il est essentiel d'ac-

croître la portabilité des données et de promouvoir des concepts technologiquement neutres afin de faciliter l'interopérabilité et encourager la recombinaison systématique des ressources.

Dans une ville intelligente, les traces des utilisateurs sont variées et proviennent de sources multiples, reflétant la complexité et l'interconnectivité des environnements urbains modernes. Les capteurs directs, tels que les caméras de surveillance et les détecteurs de mouvement, collectent des données en temps réel sur les activités et les déplacements des citoyens dans les espaces publics. Les capteurs indirects, comme les systèmes de géolocalisation (Global Navigation Satellite System), fournissent des informations sur les localisations et les itinéraires des véhicules et des piétons. Par ailleurs, les traces de navigation des applications mobiles et des services en ligne révèlent des comportements, des préférences et des habitudes numériques des utilisateurs.

Mes travaux: *Traces utilisateurs*

Dans mes travaux plusieurs traces ont été exploitées : des données d'évènements issus de capteurs ambiants [Verstaevel et al., 2018b], des données issues de flux vidéos [Barthélemy et al., 2019][Chraibi et al., 2023] ou encore des données de capteurs de micro-particules dans l'air [Forehead et al., 2020]. Dans sa thèse [Fourez, 2024], Thibault Fourez propose une caractérisation des sources de données exploitables dans le cadre de l'analyse de mobilité en différenciant données contextuelles, utilisateurs et agrégées.

L'abondance des données locales nécessite de nouveaux algorithmes pour étudier et interpréter les liens entre ces données locales et la complexité des interactions entre les différents éléments du système urbain que l'on observe. Les modèles doivent non seulement gérer l'hétérogénéité des données, mais aussi être capables de prédire (voir chapitre 3) et de simuler (voir chapitre 4) les effets à l'échelle macroscopique des phénomènes observés localement, sous l'hypothèse qu'une telle relation existe.

La question de l'observabilité locale dans les villes intelligentes est essentielle pour comprendre comment les données générées par les citoyens et les infrastructures urbaines peuvent être collectées, analysées et utilisées de manière efficace pour améliorer la qualité de vie.

Un système est dit observable si l'on peut complètement reconstruire les états internes du système à partir de ses sorties [Liu et al., 2013]. Ce concept d'observabilité a été introduit par [Kalman, 1960] pour les systèmes dynamiques linéaires et a été principalement étudié en statistiques et en théorie du contrôle. Les filtres de Kalman, par exemple, sont une famille d'algorithmes qui estiment les états d'un système dynamique à partir de séries de mesures incomplètes ou bruités. Ils utilisent une série de mesures observées dans le temps, y compris le bruit statistique et d'autres inexactitudes en estimant une distribution de probabilité conjointe sur les variables pour chaque pas de temps.

La propriété d'observabilité, dans le contexte de l'observation des activités humaines, pose un défi majeur. En effet, il est souvent impossible d'observer directement et intégralement les comportements locaux à l'aide des dispositifs de l'IoT. Parfois, nous ne pouvons qu'observer

les conséquences de ces comportements par l'intermédiaire de proxys, en utilisant par exemple le bruit ambiant pour estimer l'état du trafic [Rahim et al., 2021]. Cette limitation rend complexe l'établissement de liens entre les observations locales et les dynamiques globales. L'étude de ces interconnexions micro/macro est ainsi cruciale pour une compréhension approfondie des systèmes socio-techniques des villes intelligentes. On peut alors considérer la Smart City comme un écosystème de sources de données permettant de générer et collecter des traces sur des comportements locaux. On cherche à établir l'existence d'une relation entre la dynamique des phénomènes locaux et les effets produits à une échelle macroscopique.

Ainsi on peut formaliser une première question de recherche : **"Comment des données obtenues à l'échelle locale peuvent-elles nous informer sur des phénomènes macroscopiques ?"**. Cette question englobe plusieurs défis. Dans ce chapitre, nous nous intéressons notamment à la mise en place de capteurs et dispositifs de collecte de données dans la ville au travers de la conception de deux capteurs pour mesurer la mobilité et la qualité de l'air.

Dans le chapitre 3, nous nous intéressons à la construction automatique de modèles pour créer le lien entre donnée locale et phénomène macroscopique. Dans le chapitre 4, nous nous intéressons à la simulation de phénomènes urbains et leur calibration.

2.2.1 Le projet "Liverpool Smart Pedestrian"

Le projet « Liverpool Smart Pedestrian project » [Verstaevel et al., 2020] est un projet financé dans le cadre du programme «Australian Government Smart Cities and Suburbs Program». Il a démarré en 2018 pour une durée d'un an. Il est issu d'une collaboration entre le conseil municipal de Liverpool (Nouvelle-Galles du Sud) et l'université de Wollongong. Le projet vise à concevoir et évaluer des solutions innovantes pour la collecte de données de manière non intrusive afin de contribuer à la planification urbaine de la ville.

La ville de Liverpool est une banlieue de Sydney, dans l'État de Nouvelle-Galles du Sud, en Australie. Elle est située dans le Grand Ouest de Sydney, à 32 kilomètres au sud-ouest du quartier central des affaires de Sydney. En 2018 au démarrage du projet, sa population est estimée à 27 084 habitants. L'attrait de la ville l'a amenée à se développer, avec davantage de logements, de bureaux et d'établissements d'enseignement. Il était estimé que le réaménagement de la Civic Place sur Scott St devait entraîner 30 000 mouvements de piétons supplémentaires par jour, ce qui fait de la ville une bonne zone d'expérimentation pour contrôler l'effet de ce réaménagement sur les flux de piétons et de circulation.

Dans ce contexte, au sein de l'équipe du Dr Johan Barthelemy, mes contributions portent sur la conception d'une architecture basée sur le standard oneM2M, la conception et le déploiement de dispositifs d'analyse de flux piétons, cyclistes et automobiles, et la conception et le déploiement de capteurs de qualité d'air.

Cette section s'appuie sur l'article: Verstaevel, Nicolas et Barthélemy, Johan et Forehead, Hugh et Bilal, Arshad et Perez, Pascal. **Assessing the effects of mobility on air quality : The Liverpool Smart Pedestrian Project**. *Transportation Research Procedia, Volume 48, https://doi.org/10.1016/j.trpro.2020.08.276*. 2020.

Au démarrage du projet, deux ateliers participatifs ont été menés à l'aide du jeu Arki_nopoly [Frisk, 2016] développé par l'entreprise arkilab https://www.arkilab.dk/. Aki_nopoly propose une approche participative où un ensemble d'usagers identifie des problématiques et formule des hypothèses d'aménagement urbain. Le jeu s'inspire du Monopoly, et propose aux utilisateurs d'interagir avec un plan de la zone d'étude. Les résultats de ces ateliers ont permis de définir un ensemble de besoins fonctionnels et non fonctionnels :

- Détection et suivi multimodal : il y a un intérêt fort à concevoir des capteurs permettant de capturer les déplacements, piétons, cyclistes et automobiles.
- Respect de la vie privée : les données doivent garantir l'anonymisation des informations et aucune donnée personnelle ne doit être stockée ou échangée.
- Exploiter l'infrastructure existante : la solution doit tirer parti des infrastructures existantes en termes de réseaux et de caméras. L'adaptation du réseau de vidéosurveillance existant pour collecter davantage de données a été identifiée comme une innovation majeure.
- Évolutivité et interopérabilité : en fonction de l'évolution des besoins de mobilité, de nouveaux capteurs peuvent être ajoutés à tout moment, quelles que soient leurs technologies, ce qui signifie que le réseau de capteurs peut être facilement étendue pour capturer de nouveaux types de données.

2.3 Analyse des flux de trafic par analyse des flux vidéo *on the edge*

2.3.1 Contexte des travaux

L'intérêt pour la problématique de l'analyse des flux de trafic pour les villes n'est pas nouvelle. Par exemple, le comptage routier est une des premières méthodes qui a été employée pour analyser et modéliser les flux de trafic [Dupuy, 1975]. Ce comptage peut se faire de manière manuelle (en plaçant un ou des observateurs sur le bord des axes d'intérêt), ou de manière automatique par le biais d'instruments dont l'installation peut être fixe ou temporaire [Commenges, 2013]. Les détecteurs de boucles inductives et les tubes pneumatiques comptent parmi les premiers outils de mesure automatique du trafic [Polk et al., 1996] offrant alors une plus grande fréquence d'échantillonnage que les comptages manuels [Commenges, 2013]. Dans une analyse documentaire interdisciplinaire, Bibri et Krogstie [Bibri and Krogstie, 2017b][Bibri and Krogstie, 2017a] ont souligné l'intérêt des technologies de l'information et de la communication pour concevoir une nouvelle génération d'outils de planification urbaine pour améliorer la mobilité et l'accessibilité. Le développement de l'IoT a permis le déploiement de nouveaux types de dispositifs s'appuyant sur l'usage des technologies mobiles via les téléphones, le NFC, ou les données de systèmes de

Cette section s'appuie sur l'article: Barthélemy, Johan and Verstaevel, Nicolas and Forehead, Hugh and Perez, Pascal. **Edge-computing video analytics for real-time traffic monitoring in a smart city**. *Sensors, MDPI*. 2019.

navigation (GNSS) [Antoniou et al., 2011]. Une autre approche, qui est celle que nous avons expérimentée, est d'exploiter les réseaux de caméras de surveillance déjà existants pour en extraire automatiquement des informations anonymisées sur le trafic [Barthélemy et al., 2019]. À l'époque de nos travaux (2019), plusieurs travaux avaient exploré l'usage des réseaux de neurones pour traiter hors ligne des flux vidéo et en extraire des données de comptage ([Dimou et al., 2016, Peppa et al., 2018, Acharya et al., 2017]) mais à notre connaissance, aucune approche n'avait proposé d'utiliser l'analyse de données en temps réel comme outil de planification urbaine et n'avait déployé cet outil en contexte opérationnel. Une des limitations à ce déploiement est la nature sensible des données issues de caméras de surveillance : les caméras sont déployées sur des réseaux en boucles fermées, et souvent, la consultation des images n'est possible que par un petit ensemble de personnes assermentées pour garantir le respect (et le droit) à la vie privée. Le paradigme du *edge computing* (informatique en périphérie de réseaux) offre une approche intéressante à ce problème [Satyanarayanan, 2017] : rapprocher les traitements des sources de données offre la possibilité d'économiser de la bande passante, de réduire les risques de sécurité en limitant les données sortant des dispositifs de traitement et ainsi de garantir le respect de la vie privée. En effet, la confidentialité des données est assurée par un traitement qui dénature les données brutes (le flux vidéo) en des données anonymisées (des informations de comptage et de trajectoire). Les données résultantes sont généralement plus petites que les données brutes d'origine. Les images ne quittent pas le réseau de vidéo surveillance existant et seules des données dénaturées sont produites par le dispositif.

2.3.2 Un dispositif informatique en périphérie de réseau pour l'analyse de flux vidéo de trafic urbain

2.3.2.1

Le dispositif que nous avons conçu est construit sur l'association d'un ordinateur embarqué à base d'ARM (NVIDIA Jetson TX2, le tableau 2.1 présente les caractéristiques techniques), doté d'unités spécialisées pour accélérer les calculs des réseaux neuronaux utilisés pour le traitement d'images et fonctionnant sous Ubuntu 16.04 LTS, associé à un microprocesseur Pycom Lopy 4 pour gérer les communications LoRaWAN sur le plan de fréquence AS923 (utilisé en Australie).

Le capteur effectue 4 étapes de manière itérative à une fréquence moyenne 20 fois par seconde :

1. Acquisition d'images à partir d'un flux vidéo.
2. Détection des objets d'intérêt dans l'image.
3. Suivi des objets en faisant correspondre les détections avec celles de l'image précédente.
4. Mise à jour des trajectoires des objets déjà stockées dans la base de données de l'appareil ou création d'enregistrements pour les objets nouvellement détectés.

La Figure 2.1 représente une vue schématique des différentes étapes. La Figure 3.1 présente deux images du prototype.

CPU	ARM Cortex-A57(quad-core)@2 GHz + NVIDIA Denver2(dual-core)@2 GHz
GPU	256-core Pascal @ 1300 MHz
Memory	8 GB 128-bit LPDDR4 @ 1866 MHz | 59.7 GB/s
Storage	32 GB eMMC 5.1, SDIO, SATA
Decoder	4 K × 2 K 60 Hz Decode (12-Bit Support)
Codecs vidéo	H.264, H.265, VP8, VP9
Connectivity	802.11a/b/g/n/ac 2×2 867 Mbps, Bluetooth 4.1
Ethernet	10/100/1000 BASE-T Ethernet
USB	USB 3.0 + USB 2.0
PCie	Gen 2 | 1 × 4 + 1 × 1 or 2 × 1 + 1 × 2
Autres entrées/sorties	UART, SPI, I2C, I2S, GPIOs, CAN
Température	-25°C à 80°C
Consommation	15W, 12V

TABLE 2.1 – Caractéristiques techniques NVIDIA Jetson TX2 (version 2018)

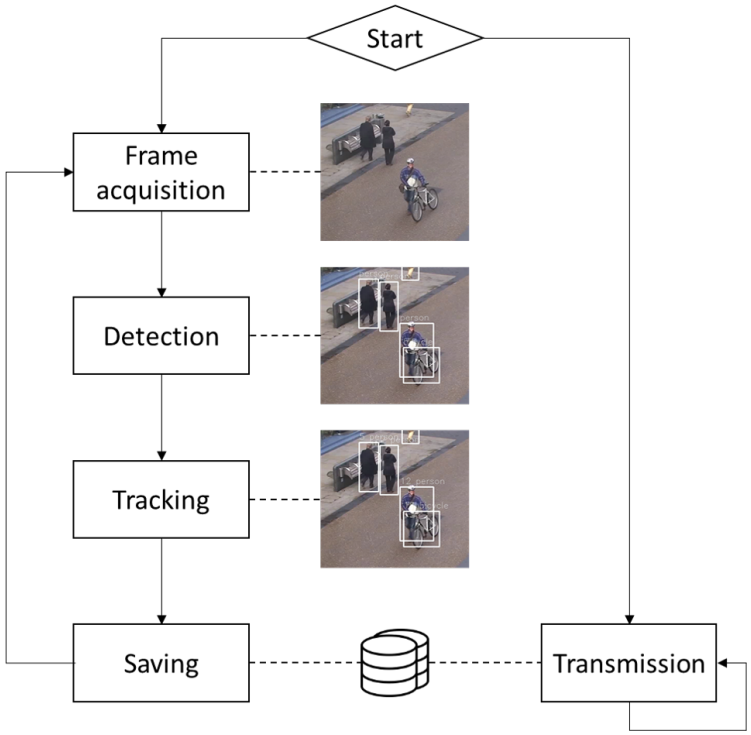


FIGURE 2.1 – Représentation schématique des étapes du processus de traitement [Barthélemy et al., 2019]

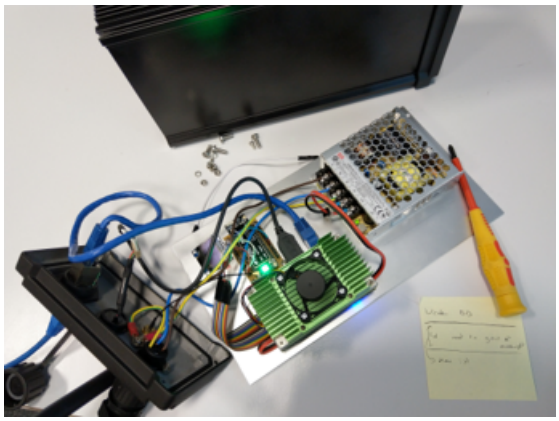


FIGURE 2.2 – Images du prototype et de son boîtier dissipateur thermique en aluminium étanche (IP67) [Barthélemy et al., 2019].

Pour assurer la détection des objets à l'étape 2, nous avons utilisé YOLO V3 [Farhadi and Redmon, 2018], un réseau de neurones à convolution (CNN) utilisé pour prédire les boîtes englobantes et les probabilités de classe des objets dans les images d'entrée. Ce choix repose sur le fait que YOLO offre un bon équilibre entre vitesse et précision et qu'il permet une détection des objets à trois échelles [Mao et al., 2019]. Le réseau est entièrement convolutif et contient 106 couches cachées rassemblées dans des blocs résiduels. Il est entraîné sur le dataset COCO [Lin et al., 2014] pour détecter six types d'objets : Piéton, Bus, Cycliste, Camion, Voiture, Motocycle. YOLO divise l'image en trois grilles (une pour chaque échelle de détection) et chaque grille prédit un ensemble fini de boîtes englobantes. Chaque boîte englobante est caractérisée par la coordonnée (x, y) de son centroïde, sa largeur w et sa hauteur h, un score de confiance O et une probabilité P pour chacune des 6 classes. Les classes dont le score de confiance O est inférieur à un seuil fixé sont rejetées. Finalement une technique de Non-Maximal Suppression (NMS) est appliquée pour éviter la duplication du même objet dans chaque échelle. On obtient donc un ensemble de boîtes englobantes, où la classe de probabilité la plus élevée est utilisée pour déterminer la nature de l'objet détecté. Les valeurs de paramètres utilisés sont visibles dans la Table 2.2.

Le suivi des objets à l'étape 3 est réalisé par SORT (Simple Online and Real-Time Tracking [Bewley et al., 2016]). À chaque nouvelle image, l'algorithme combine un filtre de Kalman [Kalman, 1960] utilisé pour estimer la position courante de chaque boîte englobante à partir de sa position dans l'image précédente, avec un algorithme hongrois [Kuhn, 1955] utilisé pour résoudre le problème d'association entre la position des boîtes englobantes prédites par Kalman et les boites englobantes détectées par YOLO dans l'image courante, en utilisant l'indice de Jacard comme métrique de similarité. Chaque association dont l'indice de Jacard est inférieur à un seuil fixé est rejetée.

Deux paramètres supplémentaires sont également utilisés pour éviter que la mémoire de l'appareil ne soit complètement remplie, pour atténuer le problème de la détection des faux

Image en entrée	416x416 pixels
Grille de détection à petite échelle	52x52 cellules
Grille de détection à moyenne échelle	25x26 cellules
Grille de détection à grande échelle	13x13 cellules
Nombre de boîtes englobantes par cellule	3
Seuil de confiance	0.9
Seuil NMS	0.5

TABLE 2.2 – Paramètres de YOLOV3 utilisés pour la détection d'objets [Barthélemy et al., 2019].

positifs et pour améliorer le suivi des objets qui peuvent être occultés pendant un maximum d'images. Pour être conservé, un objet n'est sauvegardé que s'il a été vu au moins dans hit_{min} images et sera éliminé s'il n'a pas été détecté dans age_{max} images consécutives. Chaque nouvel objet reçoit un identifiant unique (Version 4-UUID) pour assurer son suivi dans le temps.

Ainsi, lors de l'étape 4, pour chaque objet détecté identifié par son $UUID$ et à chaque image un vecteur de données $((x, y), w, h)$ est enregistré dans une base de données locale au dispositif.

2.3.3 Discussion des résultats

Un premier résultat sur un jeu de donnée labélisé a permis de montrer que le capteur était plus enclin aux faux négatifs qu'aux faux positifs, sous-estimant ainsi le nombre de détections [Barthélemy et al., 2019]. Cependant, l'analyse tendancielle en termes de nombre d'objets détectés est correcte, ce qui se traduit par des performances et une précision globalement satisfaisantes pour les cas d'utilisation considérés de ce capteur.

Dans une seconde expérimentation, le capteur a été déployé à l'intérieur de notre laboratoire pour étudier le flux de personnes traversant le premier étage du bâtiment lors d'une alerte incendie. Ce bâtiment abrite différents laboratoires et activités d'enseignement, et constitue donc un bon endroit pour surveiller l'activité des piétons. La caméra a été placée devant un escalier qui constitue l'accès principal au premier étage. Le tracé des trajectoires est visible sur la Figure 2.4.

Une troisième expérimentation s'est déroulée lors du déploiement de 20 capteurs dans le centre ville de la ville de Liverpool, NSW, Australie. La figure 2.5 montre, à gauche, la carte du centre ville et la position des capteurs et à droite, la co-localisation de deux caméras de surveillance et d'un capteur de qualité d'air.

La Figure 2.3 montre les résultats du comptage obtenus sur une semaine de mesure allant du 20 février 2019 au 27 février 2019. Il affiche le nombre de piétons (bleu), de véhicules (oranges) et de vélos (vert) détectés chaque minute pendant ces huit jours. Sur la figure du haut, nous pouvons facilement voir le rythme circadien quotidien de la ville, où la plupart de l'activité a eu lieu entre 08h00 et 16h00. Sur la figure du bas, on peut observer le nombre de détections horaires sur la journée du 23 février 2019, illustrant mieux ce phénomène.

Ces expérimentations ont permis de montrer la faisabilité et l'intérêt du déploiement de solutions d'analyse d'images pour l'analyse de flux à l'intérieur et à l'extérieur des bâtiments. Bien que la détection ne parvienne pas à capturer l'ensemble des trajectoires (des progrès ont été réalisés depuis améliorant grandement la qualité de détection de YOLO [Sharma et al., 2024]), elle parvient à capturer les tendances d'évolutions de la mobilité.

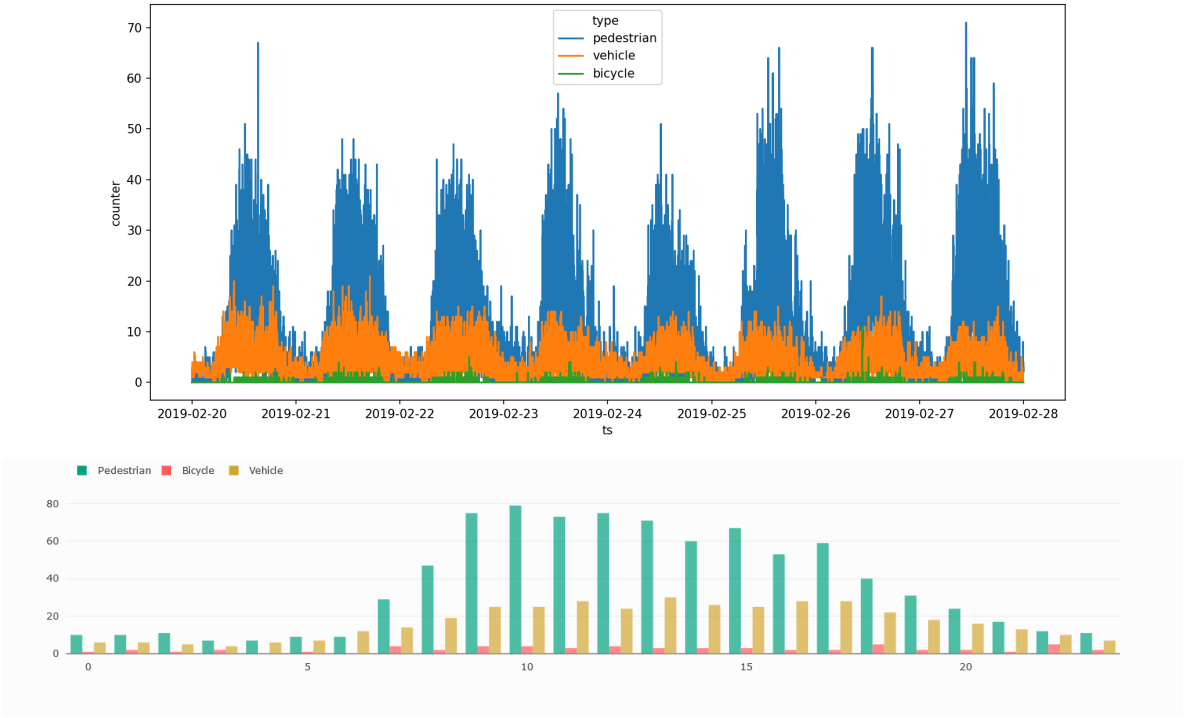


FIGURE 2.3 – En haut : tracé du nombre de piétons, véhicules et cyclistes détectés par le capteur entre le 20-02-2019 et le 27-02-2019-. Chaque point d'une série de données représente le nombre d'individus détectés au cours de la dernière minute. On observe le rythme circadien journalier des déplacements. En bas : Nombre de piétons (vert), de vélos (rouge) et de véhicules (jaune) détectés toutes les heures le 23 février 2019.[Barthélemy et al., 2019]

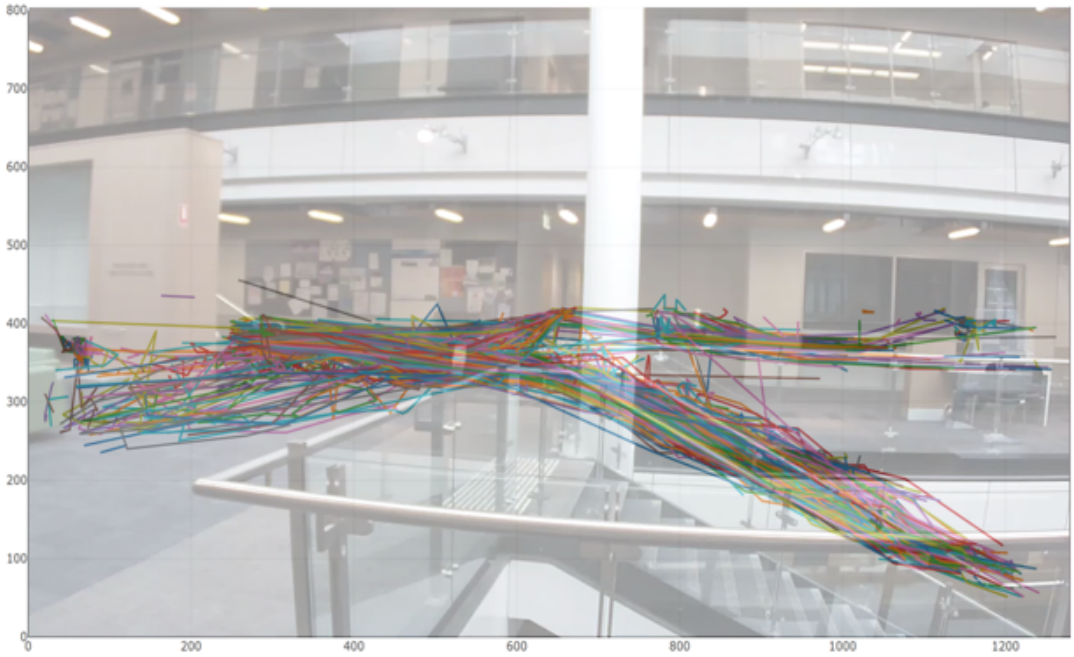


FIGURE 2.4 – Trajectoire des 631 piétons détectés au cours de l'alerte incendie. [Barthélemy et al., 2019]

2.4 Impact de la qualité d'air (PM2.5) sur la mobilité

2.4.1 Contexte des travaux

Une seconde approche que nous avons explorée est la possibilité d'étudier indirectement la mobilité en observant son impact sur des facteurs environnementaux.

Des études ont montré que l'exposition aux particules fines ($PM_{2.5}$) peut poser un risque sur la santé des individus, pouvant provoquer des effets négatifs sur les fonctions cérébrales, respiratoires ou encore impactant le système immunitaire [Rückerl et al., 2011].

Plusieurs travaux ont établi des liens entre qualité de l'air et la mobilité urbaine. Dans [Setton et al., 2011], des chercheurs ont étudié l'impact de mobilité quotidienne sur l'exposition à la pollution atmosphérique liée au trafic et les estimations des effets sur la santé. Les études épidémiologiques sur la pollution atmosphérique liée au trafic évaluent généralement l'exposition dans les lieux d'habitation uniquement. Cependant, si les sujets de l'étude passent du temps hors de leur domicile, une erreur de mesure de l'exposition, et donc un biais, peut être introduite dans les analyses épidémiologiques. Ainsi, dans une étude couplant capteur

Cette section s'appuie sur l'article: Forehead, Hugh and Barthelemy, Johan and Arshad, Bilal and Verstaevel, Nicolas and Price, Owen and Perez, Pascal. **Traffic exhaust to wildfires : PM2. 5 measurements with fixed and portable, low-cost LoRaWAN-connected sensors**. *Plos One*. 2020.

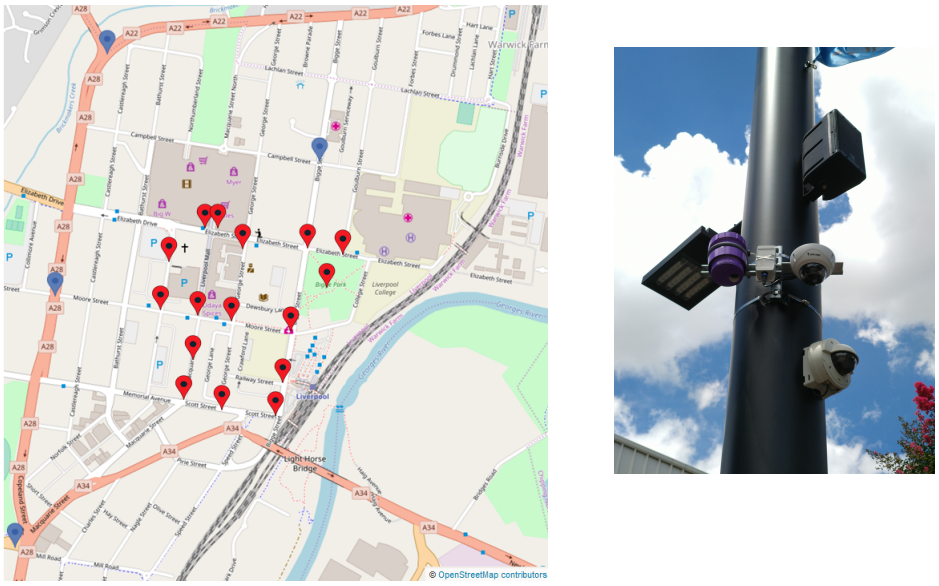


FIGURE 2.5 – Une carte du centre ville de Liverpool (source : OpenStreetMap® sous licence ODbL). À gauche : l'emplacement de l'installation des 20 capteurs. À droite : la co-localisation de deux caméras et d'un capteur de qualité d'air (en violet) sur un pylône. [Barthélemy et al., 2019]

fixe et capteurs mobiles, ils ont montré que la qualité de l'air affecte les flux de population des villes et suggèrent que le fait d'ignorer les schémas de mobilité quotidienne peut contribuer à fausser l'hypothèse nulle dans les études épidémiologiques utilisant des estimations d'exposition au niveau individuel. [Cui et al., 2019] ont réalisé une étude utilisant des données de localisation basées sur les téléphones et la régression de variables instrumentales pour essayer de découvrir si la qualité de l'air affecte la mobilité de la population en Chine. Leurs résultats confirment que la qualité de l'air a une incidence sur les mouvements de la population. Une augmentation de 100 points de l'indice de qualité de l'air entraînera une augmentation de 49,60 % des sorties de population, et une augmentation de 1 μgm^3 de $PM_{2,5}$ peut entraîner une augmentation de 0,47 % des sorties de population. Les incidents liés à la pollution atmosphérique peuvent inciter les gens à quitter leur ville trois jours ou une semaine plus tard par le chemin de fer ou la route. L'effet est hétérogène entre les jours ouvrables, les week-ends et les jours fériés.

Ainsi, les municipalités confrontées à une dégradation de la qualité d'air mettent en place des politiques publiques pour agir sur la mobilité des individus dans l'espoir d'améliorer la qualité d'air. Cependant, ces politiques publiques peuvent produire des effets contradictoires. [Davis, 2017] a étudié l'impact de la politique de restriction de la conduite basée sur les plaques d'immatriculation dans le cadre de la lutte contre la pollution atmosphérique urbaine dans la ville de Mexico. La restriction de la conduite basée sur les plaques d'immatriculation est une

réponse de plus en plus courante des villes à la pollution de l'air. L'auteur a étudié les données horaires des stations de surveillance de la pollution pour mesurer l'effet sur la qualité de l'air de l'extension au samedi de la politique de restriction. Il en ressort que « les restrictions de circulation du samedi n'améliorent pas la qualité de l'air dans la ville de Mexico ». Pour huit polluants majeurs, l'extension du programme n'a eu pratiquement aucun effet perceptible sur les niveaux de pollution. Ces résultats décevants contrastent fortement avec les estimations faites avant l'extension, qui prévoyaient une diminution de 15 % des émissions des véhicules le samedi ». Pour expliquer cet échec, l'auteur souligne qu'il n'a trouvé aucune preuve que l'extension du programme a réussi à inciter les conducteurs à adopter des moyens de transport moins polluants.

Dans ce contexte, nous voyons dans l'IoT la possibilité de mesurer la qualité de l'air à hauteur d'exposition sur de nouvelles échelles spatiales et temporelles.

2.4.2 Un dispositif de mesure de qualité d'air

Le dispositif que nous avons conçu et expérimenté est un capteur dont l'objectif est de mesurer les particules en suspension pour deux usages : le premier pour mesurer l'exposition des piétons aux bords des routes dans un centre urbain, le second pour quantifier la production de fumée lors de feux de forêt. Pour assurer la reproductibilité de l'expérimentation et l'usage par le plus large public possible, la conception s'est orientée vers l'assemblage de composants disponibles au grand public.

Le dispositif est basé sur un microcontrôleur Pycom Lopy 4 , manufacturé par PyCom Ltd (Guildford, UK) choisi pour son architecture construite sur le projet open source Arduino Uno, et combinant sur un même microcontrôleur des protocoles de communication Wifi, Bluetooth Low Energy, LoRaWAN et Sigfox).

Le capteur de microparticules $PM_{2.5}$ que nous avons retenu est le capteur Nova SDS011, un capteur basé sur un laser qui mesure le nombre de microparticules présentes dans un flux d'air. Pour réaliser ce choix, trois capteurs de marques différentes ont été testés et comparés à un capteurs de références [Forehead et al., 2020]. La spécification du capteur donne une limite de détection à $0.3\mu m$. Le capteur est alimenté en courant $5VDC$ soit via un port USB dédié ou par un transformateur $240V$ vers $5V$ (Mean Well MPM-30-5).

Un boîtier spécifique pour protéger le capteur lors de son installation extérieure a été conçu. Ce boîtier est construit à partir de matériaux de construction courant comme un tube PVC de $100mm$ de diamètre. Un ventilateur de $30mm$ de diamètre est ajouté pour faciliter la circulation d'air. L'ensemble des pièces utilisées pour le boîtier et un guide de construction du capteur est disponible [Forehead et al., 2020] pour permettre à la communauté de construire leurs propres capteurs.

Le *firmware* que nous avons développé est disponible sur Zenodo sous Licence MIT [Barthélemy and Verstaevel, 2020]. Le *firmware* permet la lecture des données du capteur à une fréquence désirée et l'envoi de la donnée selon le protocole de son choix (LoRaWAN,

https://docs.pycom.io/datasheets/development/lopy4/

WIFI ou enregistrement sur carte SD). À noter qu'un capteur GPS peut être ajouté pour faciliter la géolocalisation.

Une photographie du capteur assemblé et monté sur un pylône est visible sur la Figure 2.5 (la couleur violette du capteur a été choisie à la suite d'ateliers participatifs).

2.4.3 Discussion des résultats

L'article [Forehead et al., 2020] présente les résultats de l'évaluation du dispositif. Plusieurs tests ont été réalisés pour qualifier la qualité du capteur. Les principaux résultats ont montré une forte similarité de la mesure entre deux capteurs Nova SDS011, mais les capteurs mesurent une concentration de l'ordre d'1/3 de la mesure réalisée par le capteur de référence. Cependant, l'analyse des pics et des tendances montre une similarité avec l'instrument de référence. Le capteur produit donc une mesure intéressante en analyse tendancielle, mais ne permet pas une mesure exacte de la concentration.

Dans le cadre du projet *"Smart Pedestrian Project"* [Verstaevel et al., 2020], 20 capteurs ont été construits et positionnés dans le centre-ville de Liverpool (NSW). L'étude des données fournies par ces capteurs a permis de montrer que les appareils installés le long des routes ont des valeurs de PM2.5 considérablement élevées par rapport aux chiffres de la qualité de l'air de fond (air d'un lieu en l'absence de perturbations ou d'influences ponctuelles) de la station de surveillance la plus proche. Pour l'une des intersections étudiées, les valeurs étaient généralement supérieures d'un ordre de grandeur à la pollution de fond, ce qui correspond à une pollution plus importante causée par le trafic à l'arrêt. Les valeurs en bord de route étaient bien supérieures aux limites de sécurité recommandées par l'Australie (8 μgm^{-3} en moyenne annuelle ou 25 μgm^{-3} en moyenne journalière) pendant la majeure partie de la période de mesure, avec un nombre élevée de mesure dépassant le seuil.

Les expérimentations en laboratoire et le déploiement du dispotif dans la ville ont permis de démontrer l'intérêt et l'usage d'un réseau d'analyse de la qualité d'air à l'échelle d'une ville. La production d'un capteur open source déplaçable permet à la communauté de continuer à exploiter et peupler le dispositif. Elle illustre aussi la difficulté à observer et mesurer les phénomènes urbains, notamment la qualité de l'air qui se retrouve impactée à la fois par la structure de la ville et le trafic local.

2.5 Conclusion et perspectives

Ce chapitre a exploré le concept d'observabilité partielle dans la ville intelligente, avec pour objectif de démontrer les possibilités offertes par l'IoT pour observer des phénomènes urbains à de nouvelles échelles temporelles et spatiales. Deux résultats issus du même projet ont été présentés :

— L'analyse des flux de mobilité à partir de caméras de surveillance, en utilisant des algorithmes de détection et de suivi d'objets.
— L'analyse de la qualité de l'air (PM2.5) à l'aide de capteurs distribués dans la ville.

Ces deux exemples montrent que l'on peut observer la mobilité urbaine au travers de réseaux de capteurs vidéo, mais aussi au travers de son impact sur l'environnement, avec l'exemple des microparticules en suspension. Les résultats et l'expérience acquise de ces deux applications permet de dresser un ensemble de limitations et de perspectives.

Une difficulté à mesurer précisément les phénomènes urbains : les capteurs vidéos et de qualité d'air ont montré des résultats pertinents en analyse tendancielle pour approximer des phénomènes de mobilité. Cependant, comparés à des sources de données de référence (station de mesure de qualité d'air, comptage routier), les résultats montrent que les capteurs sous-estiment les valeurs réelles.

— Pour ce qui concerne la vidéo, cela s'explique d'abord par l'architecture du réseau de neurones utilisé (YoloV3) qui, bien qu'il détecte les objets à trois échelles différentes, n'est que faiblement robuste aux changements rapides d'échelles notamment pour les petits objets, ainsi qu'aux transformations possibles sur les objets (pan, tilt, zoom). YoloV3 est une architecture obsolète et des architectures plus récentes ont grandement amélioré le modèle [Sharma et al., 2024]. Cependant, il n'en reste pas moins des estimateurs de trafic et la qualité de la donnée traitée doit donc être étudiée en prenant en compte l'erreur intrinsèque à la mesure. Une deuxième limitation vient de la dépendance entre la qualité du jeu de données utilisé pour l'entraînement et la qualité de la prédiction du modèle d'apprentissage profond (et plus généralement du modèle que l'on veut construire du phénomène étudié). Le jeu de donné COCO [Lin et al., 2014], qui contient 328000 images annotées, est une bonne source pour entraîner le modèle, mais n'est pas suffisant, car ces données ne sont pas toutes représentatives pour le domaine étudié (dans notre cas, le trafic observé par des caméras de surveillance). Il est alors nécessaire d'augmenter cette base de données d'apprentissage (ce qui n'est pas sans difficulté quand il s'agit de données sensibles) ou d'utiliser des approches d'augmentation de données [Shorten and Khoshgoftaar, 2019]. L'absence de jeux de données certifiés et open-source rend d'autant plus nécessaire la transparence sur les processus et procédé mis en place pour permettre le traitement vidéo.
— Pour ce qui concerne la qualité d'air, les capteurs optiques (à faibles coûts) présentent une qualité de mesure moindre que les capteurs de mesure des stations de références. Cependant, ils peuvent être déployés en réseaux denses afin de fournir des informations utiles pour observer les sources de pollution et leur variabilité spatiale et temporelle à différentes échelles. Une approche qui pallie la faible qualité de mesure est la recalibration *in situ* des capteurs [Li et al., 2022] ou la recalibration à distance des capteurs en s'appuyant (ou non) sur l'apprentissage machine [D'Elia et al., 2024].

Le contexte de la donnée est important : les données ne sont pas des entités neutres et objectives. Elles sont le produit d'un processus de collecte, d'analyse et d'interprétation, et ce processus est nécessairement influencé par le contexte dans lequel il se déroule. Par exemple, les capteurs que nous avons déployés au niveau du sol sont plus exposés aux sources de pollution locales, comme le trafic routier, que les stations de référence, souvent installées en hauteur. Ignorer ce contexte peut conduire à une sous-estimation ou une surestimation de

la pollution réelle, et donc à des décisions inappropriées. Une première réponse est peut être à chercher dans l'approche participative à la conception des villes : la construction collective de solutions avec les parties prenantes et l'éducation aux technologies au travers de projets pilotes pour tester et affiner les technologies [Bianchi and Schmidt, 2023]. L'implication des acteurs finaux dans la phase de conceptualisation du projet permet de formaliser des hypothèses et problématiques, tout en permettant d'éduquer aux limites de la technologie. Une seconde réponse (que j'argumente ci-dessous) est à chercher dans l'interopérabilité et l'ouverture des données.

Développement de modèles plus sophistiqués pour relier les données locales aux phénomènes macroscopiques : les données produites à l'échelle locale permettent d'observer l'état d'un système complexes. Ce système présente des propriétés (hétérogénéité, non-linéarité, ouverture, dynamiques non prédictibles, grande échelle et distribution spatiale) qui rendent difficile la conception de modèles *a priori*. L'apprentissage machine offre alors un champ d'opportunités pour dériver des modèles à partir de données issues des capteurs de la ville intelligente [Dou et al., 2023]. C'est cette approche que nous explorons dans le chapitre 3.

Interopérabilité entre différentes sources de données : [José and Rodrigues, 2024] pointe qu'une limite actuelle de l'IoT appliqué à la smart city réside dans le manque d'interopérabilité nécessaire pour permettre des combinaisons d'usages innovants. Dans le projet "Liverpool Smart Pedestrian" (Section 2.2.1), nous avons conçu *Agnosticity* [Barthélemy et al., 2019], une plateforme construite sur le standard **oneM2M** [Alaya et al., 2015] pour assurer l'interopérabilité entre les données produites par nos capteurs et les services liés aux données. L'implémentation de ce protocole permet d'utiliser une API RESTful fournissant des procédures primitives pour l'authentification des machines, la découverte des ressources, l'enregistrement des applications, la gestion des conteneurs, les communications synchrones et asynchrones, l'autorisation des droits d'accès, l'organisation des groupes et le reciblage. Un apport intéressant que j'ai exploré avec mes collègues est la possibilité offerte par le protocole d'utiliser la sémantique des données sous la forme d'ontologies pour composer de nouveaux services à la volée [Verstaevel et al., 2018a], mais l'usage de la sémantique dans un contexte de ville intelligente reste un problème ouvert [Pliatsios et al., 2023].

L'importance de la donnée ouverte : les travaux présentés permettent d'illustrer la dépendance au jeux de données. Il est nécessaire de produire des données ouvertes et transparentes dans nos activités de recherche, que ce soit pour offrir de nouvelles sources d'apprentissage pour les algorithmes d'apprentissage machine ou pour construire de nouveaux services. Ainsi, les données de comptage de trafic et de qualité d'air obtenues dans le projet "Smart Pedestrian Liverpool" ont été mises à disposition par la ville sur leur plateforme de données ouvertes https://liverpool-city-council-westernparklands.opendatasoft.com/explore/. Avec mes collègues, nous avons produit deux datasets ([Barthélemy et al., 2020b, Barthélemy et al., 2020a]) à partir des données environnementales que nous avons collectées dans chaque pièce du SMART Infrastructure Facility de l'Université de Wollongong. Ce jeu de données contient des informations sur la tempéra-

ture, l'humidité, la luminosité, la pression, le mouvement, l'identifiant du nœud, l'identifiant de la pièce et la tension de la batterie. Chaque paquet reçu par le réseau LoRaWAN est également caractérisé par un RSSI, un SNR et une somme de contrôle. De ces données, nous avons pu explorer de nouvelles méthodes de corrélation entre dynamiques entre capteurs [Guastella et al., 2021]. Un autre jeu de données ouvertes se trouve dans la thèse de T. Fourez où nous avons collecté et mis à disposition un jeu de données OCC-TM qui contient les coordonnées GPS et les modes de transport associés au déplacement pour un utilisateur [Fourez, 2022].

Dans ce chapitre, j'ai positionné mes activités de recherche dans le contexte de la ville intelligente pour permettre de mettre en évidence la capacité de l'IoT à observer localement des phénomènes urbains. Cette première étape de collecte est à la fois une source d'opportunités et de nouveaux enjeux. La question de recherche "Comment des données observant un phénomène à l'échelle locale peuvent-elles nous informer sur des phénomènes macroscopiques ?" trouve ici des éléments de réponses en abordant l'usage de l'apprentissage machine pour l'analyse de flux vidéos ou la captation d'informations environnementales, mais elle reste principalement ouverte et nécessite des investigations plus approfondies. Dans le chapitre 3, j'explore l'usage de l'apprentissage automatique pour la construction de modèles. Les traces d'utilisateurs produits par la captation de données GNSS issues de données de téléphones sont utilisées. Dans le chapitre 4, je présente différents travaux liés à la simulation des systèmes urbains où les données locales peuvent être utilisées pour permettre la calibration des simulations. Dans le chapitre 5, mon projet de recherche associe ces trois étapes : collecte d'information, production de modèles, simulation.

Cette première partie du mémoire me permet aussi d'aborder la manière dont je vois mon rôle d'enseignant-chercheur en informatique, et par conséquent un premier fil de lecture de mes contributions : celui d'un facilitateur pour la compréhension de phénomènes urbains (ou non) guidés par la donnée. Il ne s'agit pas de créer un "Big Brother" qui surveille et contrôle en permanence les citoyens, mais plutôt de développer des outils et méthodes qui permettent aux citoyens de mieux comprendre et agir sur des phénomènes complexes. C'est une volonté de confronter les outils informatiques aux usages de la société civile et de l'industrie. La ville intelligente offre alors un terrain de jeux idéal : complexe, difficile à spécifier, vivant et dynamique.

Chapitre 3

Construction de Modèles par Apprentissage Artificiel

Contents

3.1 Introduction 44
3.2 Apprentissage ensembliste coopératif 44
3.2.1 Contexte des travaux 44
3.2.2 Un algorithme d'apprentissage ensembliste coopératif 48
3.2.3 Discussion des résultats 58
3.2.4 Synthèse 69
3.3 Classification des modes de transport 70
3.3.1 Contexte des travaux 70
3.3.2 Évaluation d'un pipeline d'apprentissage machine pour la détection des modes de transport 75
3.3.3 Synthèse 83
3.4 Conclusion et perspectives 84

3.1 Introduction

DANS ce chapitre, je présente mes contributions au domaine de l'apprentissage artificiel, et plus spécifiquement à des tâches de classification ou de régression par apprentissage supervisé. Le chapitre positionne l'apprentissage artificiel comme une réponse à la difficulté à spécifier *a priori* toutes les interactions dans les systèmes complexes. Je présente deux contributions au domaine de l'apprentissage artificiel. La première porte sur un méta-modèle d'apprentissage ensembliste coopératif où l'apprentissage est le résultat d'un processus d'auto-organisation d'un ensemble d'agents appelés agents contextes. Des expérimentations permettent d'explorer les propriétés de ce système et apportent des perspectives intéressantes en termes d'explicabilité. La seconde contribution porte sur l'analyse des mobilités à partir de traces d'utilisateurs, en s'intéressant plus spécifiquement à l'évaluation d'un pipeline de traitement de données pour permettre la classification des modes de transports. Les travaux présentés dans ce chapitre font référence aux publications suivantes : [Blanco-Volle et al., 2024a], [Blanco-Volle et al., 2024b], [Fourez et al., 2022a], [Fourez et al., 2022b], [Fourez et al., 2025], [Fourez, 2024], [Verstaevel et al., 2017b], [Nigon et al., 2017], [Boes et al., 2015]

3.2 Apprentissage ensembliste coopératif

Dans cette section, je présente un modèle d'apprentissage ensembliste coopératif issu de plusieurs de mes travaux de recherche. Dans la Section 3.2.1, j'introduis le contexte scientifique des travaux pour les positionner dans les domaines de l'apprentissage ensembliste. La Section 3.2.2 détaille une formalisation du modèle pour décrire son comportement. Des résultats comparatifs sur des modèles jouets sont discutés dans la première partie de la Section 3.2.3.1. La seconde partie explore le lien entre organisation du système et dynamique de la fonction sous-jacente au travers de nouvelles métriques d'explicabilité.

3.2.1 Contexte des travaux

Dans le chapitre 2, nous avons discuté des propriétés inhérentes aux applications de la ville intelligente : non-linéarité, ouverture, large échelle spatio-temporelle, hétérogénéité des composants, imprédictibilité [Nigon et al., 2017]. Ces propriétés limitent la capacité des concepteurs de systèmes à définir *a priori* tous les cas d'interaction et d'utilisation. Ainsi, l'apprentissage artificiel s'impose comme une solution pour permettre aux systèmes informatiques d'inférer leurs comportements en l'inférant à partir de données.

Le champ de recherche et d'application de l'apprentissage artificielle est riche d'approches et de méthodes pour doter les systèmes de ces capacités d'apprentissage [Goodfellow et al., 2016]. [Mitchell, 1997] propose une définition de l'apprentissage artificiel : *"A computer program is said to learn from experience E with respect to someclass of tasks T and performance measure P, if its performance at tasks in T, as measured by P, improves with experience E."* Cette définition met en évidence les notions de tâches T (on apprend à faire quelque chose), d'expérience E (comment l'apprenant interagit avec son environnement)

et de performance P, qui met en évidence le caractère dynamique de l'apprentissage et la nécessité d'évaluer la qualité de l'exécution d'une tâche. Selon la nature de T, P et E, la tâche d'apprentissage peut avoir différents noms : data mining, clustering, détection d'anomalies... La comparaison des algorithmes d'apprentissage automatique n'est possible que si T, P et E ont la même nature. Ainsi, le domaine s'est structuré autour de trois catégories [Russell and Norvig, 2016] : l'**apprentissage supervisé** où l'objectif est de construire une fonction permettant de caractériser la relation entre un ensemble de variables cibles Y et un ensemble de données d'entrées X servant de variables explicatives à partir de données labélisées par un oracle ; l'**apprentissage non supervisé** où l'objectif est de découvrir des structures dans des données non labélisées ; et l'**apprentissage par renforcement** qui s'intéresse à la modélisation de boucle d'interaction entre l'environnement et l'apprenant pour maximiser une valeur de récompense.

Mes travaux: *Apprentisage artificiel*

Dans les travaux présentés dans ce document, je me suis principalement intéressé à l'**apprentissage supervisé** dans des contextes applicatifs liés à la ville intelligente. Dans la Section 2.3 du chapitre précédent, j'ai présenté des contributions à l'apprentissage supervisé pour la détection et le suivi de flux de trafic [Barthélemy et al., 2019]. Dans ce chapitre je vais présenter de nouvelles contributions qui s'inscrivent dans l'approche supervisée : c'est-à-dire la construction de modèles à partir d'exemples labélisés fournis par un oracle. Les tâches T réalisées sont des tâches de régression [Blanco-Volle et al., 2024b, Blanco-Volle et al., 2024a] et de classification [Fourez et al., 2022a, Fourez et al., 2022b, Fourez et al., 2025]. Les systèmes complexes que j'étudie ont pour propriété de rendre difficile leur étude *a priori*, c'est à dire au moment de leurs conception, mais offrent *a contrario* de nombreuses sources de données pour étudier leurs comportement *a posteriori*. Je m'intéresse donc à la conception d'algorithmes d'apprentissage qui permettent de prédire les évolutions d'un système en observant a *posteriori* la qualité de la prédiction et en concevant des boucles de rétroactions qui visent à améliorer la performance du système en exploitant les nouvelles expériences E. Je présente deux modalités d'acquisition de ces expériences : **en-ligne**, c'est-à-dire à l'intégration des nouvelles expériences à chaque cycle du processus d'apprentissage [Blanco-Volle et al., 2024b, Blanco-Volle et al., 2024a] ou **hors-ligne**, c'est-à-dire en dissociant l'apprentissage de son exploitation [Fourez et al., 2022a, Fourez et al., 2022b, Fourez et al., 2025]. Je choisis, pour des raisons didactiques, de restreindre les travaux présentés au domaine de l'apprentissage supervisé. Cependant, je présenterai dans le chapitre 5 des travaux en cours dans les domaines de l'apprentissage non supervisé et par renforcement.

Les récentes évolutions du domaine sont dominées par les performances de l'apprentissage profond [Goodfellow et al., 2016], notamment grâce aux avancées dans les domaines des grands modèles de langage [Raiaan et al., 2024]. Ces modèles qui appartiennent à l'approche

connexionniste abordent l'apprentissage comme un processus émergent de l'interconnexion entre un ensemble d'unités simples. Les modèles les plus récents dépassent la centaine de milliards de paramètres, et nécessitent des ressources computationnelles importantes pour leur apprentissage et leur exécution. Les larges dimensions de ses espaces d'entrées et de sorties, ainsi que les dynamiques non linéaires qui se produisent entre ses composants, rendent ces modèles *boîte noire* difficiles à interpréter [Gilpin et al., 2018].

Mes travaux: *Apprentissage profond*

L'apprentissage profond repose sur une idée intéressante que l'apprentissage émerge de changements dans l'organisation de ses composants. Dans le chapitre 2, j'ai présenté des contributions à l'utilisation de l'apprentissage profond pour la détection de flux de trafics [Barthélemy et al., 2019]. Dans le chapitre 4, je présente les travaux de la thèse de Dan Huu-Tu, dans laquelle les réseaux neuronaux profonds sont utilisés comme outils pour générer des trajectoires réalistes de piétons dans des foules denses [Korbmacher et al., 2022a, Korbmacher et al., 2022d, Dang et al., 2024d, Korbmacher et al., 2022b, Dang et al., 2023c]. Cependant, mes contributions au domaine restent applicatives : j'utilise les réseaux de neurones comme des outils à qualifier pour étudier ou simuler des phénomènes.

L'apprentissage ensembliste est une famille d'algorithmes d'apprentissage automatique qui propose de combiner les résultats de plusieurs modèles d'apprentissage (*weak learners*) pour que les performances de prédictions collectives soient meilleures que celles obtenues par chacun des modèles seul [Dong et al., 2020]. Les algorithmes ensemblistes entraînent donc un ensemble de modèles sur une tâche spécifique de classification ou de régression, et agrègent leurs résultats (en combinant ou moyennant les sorties des modèles) pour produire une prédiction. En utilisant des modèles simples (*boîtes blanches*), tels que des régressions linéaires, l'apprentissage ensembliste apporte une contribution originale à la problématique de l'explicabilité. En effet, en analysant les contributions individuelles des modèles au collectif, il devient possible de mieux comprendre les mécanismes internes et d'offrir des explications plus transparentes des décisions prises [Gilpin et al., 2018] tout en conservant de bonnes performances [Dong et al., 2020]. On distingue quatre approches d'apprentissage d'ensembliste qui diffèrent par la manière dont elles génèrent, pondèrent et agrègent les modèles d'apprentissage.

— **Bagging** : l'approche par bagging [Breiman, 1996] s'intéresse à réduire la variance au sein de données bruitées. Un échantillon aléatoire de données dans un ensemble d'entraînement est sélectionné pour entraîner chaque modèle de manière indépendante. Le modèle final est obtenu en moyennant les prédictions de chacun des modèles.

— **Boosting** : dans le boosting, un échantillon aléatoire est sélectionné pour entraîner de manière séquentielle des modèles complémentaires. L'ajustement des poids d'un modèle se base sur l'observation des erreurs du modèle précédent, de sorte que chaque modèle cherche à compenser les erreurs des modèles précédents. Le modèle final est obtenu en combinant les prédictions.

— **Stacking** : dans le stacking, chaque apprenant faible est entraîné indépendamment. Le modèle final est obtenu en utilisant un méta-modèle dont le rôle est d'apprendre à pondérer les sorties des différents apprenants pour exploiter les forces et faiblesses des différents modèles.
— **Voting** : dans le voting, chaque apprenant faible est entraîné indépendamment et la sortie est obtenue par un système de vote majoritaire ou par un système de vote pondéré. Le vote réduit l'impact des modèles aberrants et favorise le consensus entre modèles.

Mes travaux: *Apprentissage ensembliste*

L'apprentissage ensembliste aborde l'apprentissage comme un problème d'agrégation entre un ensemble de modèles d'apprentissage artificiel. L'utilisation de modèles *boîtes blanches* permet d'apporter un équilibre entre performance et explicabilité des décisions. Mes travaux se positionnent donc dans le paradigme ensembliste, en essayant de concevoir des systèmes dont les capacités d'apprentissage sont issues de l'organisation d'un ensemble d'agents apprenants. Les travaux que je présente ci-après ([Blanco-Volle et al., 2024a, Blanco-Volle et al., 2024b, Fourez et al., 2022a, Fourez et al., 2022b, Fourez et al., 2025, Fourez, 2024, Verstaevel et al., 2017b, Nigon et al., 2017, Boes et al., 2015]), se positionnent donc dans ce domaine, principalement dans la catégorie Voting. Les travaux [Fourez, 2024, Fourez et al., 2022a, Fourez et al., 2022b, Fourez et al., 2025] proposent une approche de classification où la classe est obtenue par vote majoritaire d'un ensemble de classifieurs. Les travaux [Blanco-Volle et al., 2024a, Blanco-Volle et al., 2024b] généralisent l'approche en ajoutant un système d'agrégation par vote pondéré et apportent des contributions à l'explicabilité du processus d'apprentissage. Les travaux diffèrent cependant de l'apprentissage ensembliste par la manière dont les modèles sont construits et entraînés (voir Section 3.2).

Nous avons développé dans l'équipe SMAC ([Nigon et al., 2017, Blanco-Volle et al., 2024a]) une approche originale de l'apprentissage qui résulte de l'organisation entre un ensemble dynamique de modèles locaux appelés *agents contexte* (le modèle est présenté dans la Section 3.2.2). Cette approche, qui s'inscrit dans le paradigme de l'apprentissage ensembliste, émerge originellement du besoin de contrôler des systèmes complexes sans modèle *a priori* [Videau et al., 2011]. Ainsi, [Videau et al., 2011] et [Boes and Migeon, 2017] ont construit et évalué des systèmes où le contrôle est effectué à l'aide d'un modèle des conséquences des actions sur les fonctions objectifs à calibrer. Ce modèle repose sur la construction d'un ensemble d'agents qui encapsulent trois informations : la description d'une situation (le contexte), d'une action, et des conséquences de l'exécution de l'action sur les fonctions objectifs (la prédiction). La construction, l'adaptation et la sélection de ces agents dans un processus d'optimisation permettent alors de faire émerger une politique de contrôle. Les travaux de [Guivarch et al., 2012] et ceux de ma thèse

[Verstaevel, 2016] transposent les mécanismes au problème de la classification. L'agent contexte prend alors une forme plus simple associant un contexte à une classe. Les agents contextes deviennent alors des classifieurs qui déterminent en fonction du contexte la classe qui doit être prédite. La sélection de la classe est issue d'un vote majoritaire entre les agents contextes. Les travaux de [Nigon et al., 2016] et [Dato, 2021] vont généraliser l'approche à la régression. L'agent contexte perd son action au profit d'un modèle local dont l'objectif est de prédire en fonction du contexte l'évolution d'une variable cible.

Mes travaux: *Apprentissage par agents contextes*

Les travaux sur l'apprentissage par agents contextes ont montré des résultats intéressants pour les systèmes complexes [Boes et al., 2015]. L'approche repose sur la construction, la sélection et l'adaptation de modèles locaux encapsulées dans des agents. Le problème d'apprentissage est alors celui de sélection dans chaque portion de l'espace des paramètres d'entrée des agents contextes contenant les modèles locaux les plus performants. Les travaux que je présente ci-après s'inscrivent dans le paradigme de l'apprentissage par agents contextes et présentent des avancées en termes de généralisation. Les travaux [Fourez et al., 2022a, Fourez et al., 2022b, Fourez et al., 2025] ont appliqué l'approche à un problème de classification multiclasses. Ainsi, les agents contextes ont adopté une forme matricielle et les modèles locaux sont devenus multiclasse. Les travaux [Blanco-Volle et al., 2024a, Blanco-Volle et al., 2024b] ont principalement porté sur la modification de la fonction d'agrégation, qui devient maintenant un vote sous la forme d'une moyenne pondérée. L'observation du comportement des agents permet de dégager de nouvelles métriques d'explicabilité. L'ensemble de ces travaux visent à la production d'un logiciel open-source d'apprentissage par contextes (`https://github.com/nverstaevel/ciel`)

Les travaux que je présente ci-après s'inscrivent dans cette démarche de construire des modèles apprenant à l'aide de l'apprentissage ensembliste. Dans la Section 3.2.1, le modèle d'apprentissage coopératif est présenté dans sa dernière forme, dans une volonté de généralisation et de synthèse des travaux. Dans la Section 3.2.3, les principaux résultats de ces travaux sont exposés et discutés. Dans un premier temps, une analyse comparative des performances sur des jeux de données jouets permet de positionner l'approche par rapport au domaine de l'apprentissage ensembliste. Ensuite, de nouvelles métriques d'explicabilité permettant d'analyser le comportement des agents contextes sont proposées et étudiées.

3.2.2 Un algorithme d'apprentissage ensembliste coopératif

L'algorithme d'apprentissage repose sur la construction et la structuration d'un ensemble d'agents appelés agents contexte. Un oracle fournit un ensemble d'exemples associant un vecteur de variables d'entrées et un vecteur de valeurs cibles. Un agent contexte est l'association entre un modèle local (par exemple, une régression linéaire) et d'une fonction d'activation

qui définit l'espace dans lequel le modèle local réalise de bonnes prédictions. Il est donc une fonction d'association permettant de transformer l'espace des variables d'entrées vers les variables cibles. Le problème d'apprentissage pour un agent contexte est double : d'un côté, il s'agit d'apprendre l'espace local dans lequel il réalise de bonnes prédictions, et de l'autre, d'entraîner son modèle local sur les données présente dans cet espace local. L'objectif de l'organisation du collectif d'agents contextes est de permettre la bonne combinaison des modèles locaux des agents pour prédire l'évolution de la variable cible. Cette organisation passe par l'apprentissage par chacun des agents contextes de ses structures, mais aussi par la création et la suppression d'agents contextes. Dans le reste de cette section, je propose une formalisation de l'approche.

3.2.2.1 Comportement général

Soit un $X_t \in \mathbb{R}^i$ le vecteur des variables $X = (x_1, x_2, ..., x_i)$ représentant l'observation d'un système à un cycle t défini sur un vecteur de taille i et $Y \in \mathbb{R}^o$ représentant l'espace de la variable cible défini par un vecteur de taille o.

Un agent contexte est l'association d'un modèle local $\hat{y} : \mathbb{R}^i \rightarrow \mathbb{R}^o$ et d'une fonction d'activation qui détermine un sous-espace de l'espace des variables dans lequel l'agent contexte est dit *activé*.

La qualité de la prédiction d'un modèle local est évaluée par une fonction d'évaluation qui compare la prédiction d'un modèle local à l'instant t avec celle d'un oracle $oracle_t$ fournissant des données étiquetées. Ainsi on définit une fonction :

$$eval(\hat{y}_t, oracle_t) : \mathbb{R}^o \times \mathbb{R}^o \rightarrow \mathbb{R}$$

où $eval(\hat{y}_t, oracle_t)$ correspond à une mesure de distance entre la sortie du modèle $\hat{y}$ à l'instant t et la donnée labélisée fournie par l'oracle au même instant. On peut par exemple utiliser une erreur quadratique moyenne (RMSE). L'objectif du système est donc au cours de l'apprentissage de minimiser l'erreur observée entre la prédiction qu'il fait et celle qui lui est fournie par l'oracle.

On définit un hyper-paramètre $precision \in \mathbb{R}$ qui permet de fixer un seuil minimal à la qualité de cette précision. Le choix de cette valeur de $precision$ dépend du domaine d'application et de la fonction d'évaluation $eval$.

La fonction d'activation d'un agent contexte l est caractérisée par un hyper-rectangle (aussi appelé **k-cell**) h_l appartenant à l'ensemble des hyper-rectangles H et représentant le produit cartésien de i intervalles d'activation fermés $[a_x, b_x]$ avec $1 \leq x \leq i$:

$$h_l = [a_1, b_1] \times [a_2, b_2] \times ... \times [a_i, b_i]$$

où $a_i \leq b_i$ représentent respectivement les bornes inférieures et supérieures pour chaque intervalle d'activation i.

Un agent Contexte l est activé par un point $X_t = (x_1, x_2, ..., x_i)$ si et seulement si :

$$X \in h_l \Leftrightarrow \forall j \in [1, i], a_j \leq x_j \leq b_j$$

On appelle $Voisinage(X_t)$ l'ensemble des hyper-rectangles $h_l \in H$ qui valident la condition d'activation au cycle t :

$$Voisinage(X_t) = \{h_l \in H \times ... \times [a_i, b_i] | \forall j \in [1, i], a_j \leq x_j \leq b_j\}$$

Le volume v_l d'un agent contexte l se définit par :

$$v_l = \prod_{j=1}^{i} (b_j - a_j)$$

Un agent contexte dispose d'un modèle interne $\hat{y}_l(X_t) = \{y_1, y_2, ...y_o\}$ qu'il utilise pour prédire un vecteur de variable cible à partir du vecteur contenant l'ensemble des *features* X_t. On peut utiliser plusieurs types de modèle local [Fourez, 2024], dès lors qu'il permet un apprentissage en ligne (voir Section 3.2.2.2). Le choix du modèle local est à adapter à la tâche d'apprentissage (classification ou régression).

Par exemple, on peut utiliser une régression linéaire $Y = X\beta + \varepsilon$ où β définit le vecteur des paramètres de la régression $(\beta_1, \ldots, \beta_i)$, ϵ représente l'erreur, X le vecteur des *features* et Y le vecteur des variables cibles prédites.

Le modèle local $\hat{y}_t$ peut être mis à jour pour intégrer un nouveau point à l'aide de la fonction Θ :

$$\Theta(\hat{y}_l, X_t)$$

La fonction $partial_fit()$ de Scikit-learn dépend du modèle local choisi.

3.2.2.2 Inférence et apprentissage

De manière assez classique, on différencie deux cycles dans le comportement du système :

— Des cycles d'apprentissage durant lesquels la prédiction des agents contextes est comparée à celle fournie par un oracle (apprentissage supervisé). C'est la phase d'entraînement du modèle.

— Des cycles d'inférences durant lesquels les agents contexte activés utilisent leur modèle local pour réaliser une prédiction.

Un cycle d'inférence correspond au comportement nominal du système et correspond à une opération de transformation de l'espace des variables d'entrée X vers l'espace de sortie des variables cibles Y. Il se compose de trois étapes correspondant à la composition de trois fonctions :

1. Une fonction de recherche (*filter*) est appliquée sur les agents contextes pour sélectionner les agents contextes inclus dans le voisinage du point X_t.
2. Une fonction d'association (*mapping*) permet de récupérer l'ensemble des prédictions des modèles locaux des agents contextes.
3. Une fonction d'agrégation (*reduce*) permet de construire la prédiction du système à partir des propositions des modèles locaux des agents contextes (cette dernière est discutée dans la Section 3.2.2.4).

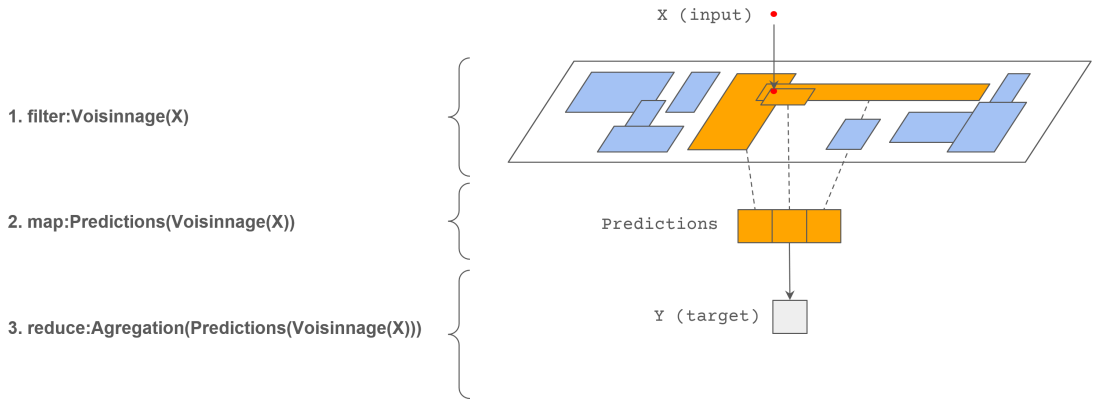


FIGURE 3.1 – Le cycle d'inférence des agents contextes projette l'espace d'entrée X dans un espace cible Y au travers de trois fonctions de transformation ©C. Blanco-Volle

Un cycle d'apprentissage intervient toujours à la suite d'un cycle d'inférence quand la valeur prédite par le système peut être comparée à la valeur fournie par un oracle. La distance entre la valeur cible prédite et la valeur cible de l'oracle permet une propagation de l'erreur vers les agents contextes. En réponse, les agents contextes adaptent leur structure interne. L'évaluation locale par les agents de leur structure produit un processus d'auto-organisation du système, modifiant son pavage de l'espace et les modèles locaux de chaque agent. Les mécanismes de coopération qui permettent ce processus d'auto-organisation sont détaillés dans la Section 3.2.2.4.

L'enchaînement de ces cycles peut être alterné de différentes manières :

— Une alternance entre un cycle d'inférence et un cycle d'apprentissage. C'est le cas pour des systèmes d'apprentissage en ligne où un système tente d'établir un modèle à court terme de prédiction des conséquences de ses actions sur l'environnement. Dans ces systèmes, la notion de cycle t est fortement liée à la notion de temps, le modèle cherchant à établir une corrélation entre les données perçues à l'instant t et leur évolution à l'instant $t+1$

— une dissociation entre les cycles d'apprentissage et d'inférence. C'est le cas pour les systèmes d'apprentissage hors ligne, où le système est d'abord entraîné sur un jeu de données puis déployé pour faire des prédictions.

— Une hybridation entre les deux précédents : le système est d'abord entraîné sur un certain nombre de cycles d'apprentissage, puis déployé en alternants cycles d'inférences et d'explorations. Cette approche permet au système de continuer à apprendre lors de son déploiement et de s'adapter à des dynamiques nouvelles (lifelong learning [Verstaevel et al., 2017b]).

3.2.2.3 L'apprentissage par les agents contextes

Du point de vue d'un agent contexte, le problème d'apprentissage est un problème d'ajustement de ses paramètres internes, c'est-à-dire de sa fonction d'activation h_j au travers de l'ajustement des bornes supérieures et inférieures de chaque dimension, et de son modèle local $\hat{y}$. A l'issu d'un cycle d'inférence, chaque agent contexte peut comparer la qualité de sa prédiction avec celle de l'oracle (quand cette valeur est disponible). En observant l'écart entre sa prédiction et la valeur de l'oracle, l'agent contexte peut localement déterminer les changements à effectuer dans son modèle local ou dans sa fonction d'activation. On peut alors reformuler son objectif comme celui de déterminer *quand* faire une prédiction et *comment* faire une prédiction. Du point de vue du collectif d'agents, le problème d'apprentissage est un problème de pavage de l'espace des paramètres d'entrée : il s'agit de collectivement construire un pavage de l'espace permettant la sélection efficace de modèles locaux pour prédire l'évolution des variables cibles. Cette approche permet d'aborder l'apprentissage comme un problème de coopération entre les différents agents contextes.

3.2.2.4 Règles de coopération

Un ensemble de 5 règles permet au système d'assurer son fonctionnement et la réorganisation de ses composants. Ces règles correpondent à l'identification et à la résolution de situation de non-coopération. Nous présentons ici ces règles :

- Initialisation du système et création des agents contextes
- Plusieurs agents contexte sont activés lors d'un cycle d'inférence
- Aucun agent contexte n'est activé lors d'un cycle d'inférence
- Il n'y a pas d'agent contexte activé lors d'un cycle d'apprentissage
- Il y a au moins un agent contexte activé lors d'un cycle d'apprentissage

Initialisation du système et création des agents contextes. Initialement, le système est vide de tout agent contexte. Le premier cycle d'apprentissage induit la création d'un agent contexte. À sa création, un agent contexte l construit un hyper-rectangle h_l centré sur le point X_t à apprendre :

$$creer(X_t) = [x_1 - d_{init,1}, x_1 + d_{init,1}] \times [x_2 - d_{init,2}, x_2 + d_{init,2}] \times ... \times [x_i - d_{init,i}, x_i + d_{init,i}]$$

où $x_i \in X_t$ représentent les valeurs du point X_t pour chaque dimension i, et $d_{init,i}$ représente un hyper-paramètre contrôlant le rayon initial de l'agent contexte pour la dimension i. Le modèle interne $\hat{y}_l$ est initialisé à l'aide de sa fonction de mise à jour pour intégrer le point courant $\Theta(\hat{y}_l, X_t)$.

Plusieurs agents contextes sont activés lors d'un cycle d'inférence. Au cours d'une inférences, plusieurs agents contextes peuvent être activés conduisant à la production d'un ensemble de prédictions des variables cibles par les différents modèles locaux. On peut voir cette situation comme un problème de prise décision entre les différents agents contextes

qui doivent alors collectivement décider quelles sont la ou les propositions à retenir pour prédire les variables cibles. L'introduction d'une fonction d'agrégation (reduce) lors de la dernière étape du cycle d'inférence permet de transformer l'ensemble de ces propositions en une unique prédiction. Cette fonction de décision peut elle-même être vue comme un mécanisme de coopération puisqu'elle assure le bon fonctionnement du cycle d'inférence. On distingue deux fonctions d'agrégation possibles : l'$argmax$ ou une fonction de pondération.

L'$argmax$ repose sur la la recherche des valeurs d'un ensemble X pour lesquelles une fonction de décision f renvoie la valeur maximum :

$$arg\,max(f, x) = \{x \in X | \forall x^{'} \in X, f(x^{'}) \leq f(x)\}$$

Ainsi [Fourez, 2024] propose l'introduction d'une valeur de confiance associée à chaque agent contexte construit à partir de l'historique des prédictions de l'agent contexte. Cette valeur est incrémentée ou décrémentée à chaque activation de l'agent contexte en fonction de la qualité de sa prédiction. Ainsi, chaque agent contexte dispose de sa propre valeur de confiance. Si plusieurs agents contextes font une prédiction, il est alors possible de sélectionner celle qui possède la valeur de confiance la plus élevée. On décrit cette valeur de confiance par la formule :

$$c_l = \sum (F_+ * \mathbb{1}_{eval(\hat{y}_l, oracle) \leq precision} - F_- * \mathbb{1}_{eval(\hat{y}_l, oracle) > precision})$$

où N_l définit le nombre d'activations de l'agent contexte l, $\mathbb{1}_{eval(\hat{y}_l, oracle) < precision}$ une fonction caractéristique sur l'ensemble définie sur le sous-ensemble des situations où la fonction d'évaluation du modèle local $\hat{y}_l$ est inférieure à la précision fixée par l'utilisateur $precision$ et F_+ et F_- deux hyperparamètres permettant de pondérer l'importance relative des bonnes prédictions par rapport aux mauvaises prédictions.

Dans nos travaux les plus récents [Blanco-Volle et al., 2024a], la fonction d'agrégation prend la forme d'une moyenne pondérée des propositions :

$$P_t = \frac{\sum_{l \in V_t} \hat{y}_l * w_l}{\sum_{l \in Voisinnage(X_t)} w_l}$$

où P_t correspond à la prédiction du système au cycle t correspond à l'ensemble des agents contextes participant à la prédiction, et w_l correspond au coefficient de pondération de l'agent contexte l. Ainsi, la prédiction du système n'est plus liée uniquement à la prédiction d'un modèle local, mais devient le résultat de la combinaison de plusieurs modèles locaux. On peut utiliser comme coefficient de pondération w la distance entre le point courant et le centre de l'hypercube caractéristique de l'agent contexte.

Aucun agent contexte n'est activé lors d'un cycle d'inférence. Lors de l'inférences, la fonction de voisinage peut retourner un ensemble vide si le point X_t n'est inclus dans aucun des hyper-rectangles des agents contextes :

$$Voisinage(Xt) = \emptyset$$

En l'absence de voisin, le système ne serait pas capable de fournir une prédiction. Pour résoudre par anticipation cette situation, nous généralisons la notion de voisinage en ajoutant un paramètre de distance d :

$$Voisinage_generalise(X_t) = \{h_l \in H | \forall j \in [1, i], a_j - d \leq x_j \leq b_j + d\}$$

Si aucun voisin n'est trouvé par la fonction de voisinage généralisé, alors l'hyper-rectangle le plus proche de X_t au sens de la distance euclidienne est sélectionné :

$$distance(hl, X_t) = (\sqrt{\sum_{j=1}^{i}(max(a_j - x_j, x_j - b_j, 0))}$$

où $max(a_j - x_j, x - j - b_j, 0)$ représente la distance à la borne la plus proche pour la $j - ème$ dimension de l'hyper-rectangle h_l. Ainsi, par construction, le système admet toujours un voisin dès lors que l'ensemble des agents contextes est non vide.

Il n'y a pas d'agent contexte activé lors d'un cycle d'apprentissage. Lors d'un cycle d'apprentissage, la fonction de voisinage $Voisinage(Xt)$ permet de filtrer les agents voisins du point X_t. Si $Voisinage(Xt) = \emptyset$, alors aucun agent contexte n'est directement activé par le point courant. Il s'agit ici d'une situation d'incompétence puisque le système n'est pas encore parvenu à paver l'espace correspondant au point. Deux mécanismes sont proposés pour permettre la réorganisation du système : rechercher dans le voisinage étendu un agent contexte réalisant une bonne prédiction et l'étendre pour intégrer le point courant (généralisation) ou créer un nouvel agent contexte pour encapsuler le point courant (spécialisation). Le choix de l'un ou de l'autre est effectué en fonction de la qualité de la prédiction effectuée par le voisinage étendu, par rapport au seuil de précision fixé en hyperparamètre ($precision$) :

— **Si au moins un agent contexte dans le voisinage étendu fournit une bonne prédiction** :

$$\exists l \in Voisinage_generalise(Xt) : eval(\hat{y}_{t,l}, oracle_t) < precision$$

alors l'agent contexte l met à jour sa fonction d'activation h_l à l'aide d'une fonction de dilatation α :

$$dilatation(h_l) = h_l * \alpha$$

Plusieurs fonctions de dilatation peuvent être utilisées, comme par exemple une dilatation de chaque borne de chaque dimension par un coefficient $\alpha_i > 1$:

$$h_l = [a_1 * \alpha_1, b_1 * \alpha_1] \times [a_2 * \alpha_2, b_2 * \alpha_2] \times ... \times [a_i * \alpha_i, b_i * \alpha_i]$$

De plus, le modèle local $\hat{y}_l$ est mis à jour en ajoutant le point courant X_t :

$$\hat{y}_l = \Theta(\hat{y}_l, X_t)$$

— **Aucun agent contexte dans le voisinage étendu ne fournit de bonne prédiction** :

$$\nexists l \in Voisinage_generalise(Xt) : eval(\hat{y}_{t,l}, oracle_t) < precision$$

alors un nouvel agent contexte est créé selon la règle $creer(h_l)$ pour couvrir le point courant.

Il y a au moins un agent contexte activé lors d'un cycle d'apprentissage : Similairement, lors d'un cycle d'apprentissage, la fonction de voisinage $Voisinnage(X_t)$ peut activer plusieurs agents contextes. Il est alors possible pour chaque agent contexte activé d'évaluer localement la qualité de sa prédiction par rapport à la donnée étiquetée fournie par l'oracle et d'adapter ses paramètres en conséquence. Deux mécanismes sont proposés pour permettre cette réorganisation selon la qualité de prédiction de l'agent contexte : soit l'agent contexte réalise une prédiction imprécise, dans ce cas il doit mettre à jour sa fonction d'activation pour exclure le point courant (spécialisation), soit l'agent contexte réalise une prédiction suffisamment précise et peut intégrer le point courant à son modèle interne :

— **Pour tous les agents contexte inclus dans le voisinage $Voisinage(X_t)$ qui fournissent une prédiction supérieure au seuil de précision** :

$$\forall l \in Voisinage(Xt) : eval(\hat{y}_{t,l}, oracle_t) > precision$$

chaque agent contexte l met à jour sa fonction d'activation h_l à l'aide dune fonction de rétractation ρ :

$$retractation(h_l) = h_l * \rho$$

Plusieurs fonctions de rétractation peuvent être utilisées, comme par exemple une rétractation de chaque borne de chaque dimension par un coefficient $0 < \alpha_i < 1$:

— **Pour tous les agents contexte inclus dans le voisinage $Voisinage(X_t)$ qui fournissent une prédiction inférieure au seuil de précision** :

$$\forall l \in Voisinage(Xt) : eval(\hat{y}_{t,l}, oracle_t) < precision$$

alors le modèle local $\hat{y}_l$ est mis à jour en ajoutant le point courant X_t :

$$\hat{y}_l = \Theta(\hat{y}_l, X_t)$$

3.2.2.5 Synthèse

Le tableau 3.1 présente un résumé des principales notations de notre algorithme. L'apprentissage y est le résultat de l'organisation des structures internes d'un ensemble d'agents contextes. Un agent contexte est l'association entre une fonction d'activation (caractérisée par un hyperrectangle défini sur l'espace des dimensions d'entrée) et un modèle local. Notre modèle comporte deux cycles : un cycle d'inférence conduisant à prédire une variable cible, et un cycle d'apprentissage supervisé qui peut déclencher des mécanismes de réorganisation.

Le cycle d'inférence correspond à la combinaison de trois opérations filter/map/reduce : (1) la sélection des agents contextes activés voisins du point courant (filter), (2) la prédiction des variables cibles par les agents contextes activés (map), puis (3) l'agrégation des prédictions (reduce). Cinq règles de coopération sont présentés et assurent la création des agents contexte, l'évolution de la fonction d'activation et l'apprentissage des modèles locaux. La section suivante 3.2.3.1 présente et discute les résultats de l'étude du comportement de notre modèle sur deux expérimentations : une première qui vise à étudier les frontières de décision sur un jeu de données jouet, et la seconde qui s'intéresse à l'apport de l'auto-organisation à l'explicabilité du modèle et de la dynamique de la fonction à approximer.

$X_t \in \mathbb{R}^i$	Vecteur des observations au cycle t de dimension i
$Y \in \mathbb{R}^o$	Vecteur représentant l'espace des variables cibles de dimension o
$creer(X_t) = [x_1 - d_{init,1}, x_1 + d_{init,1}] \times [x_2 - d_{init,2}, x_2 + d_{init,2}] \times ... \times [x_i - d_{init,i}, x_i + d_{init,i}]$	Fonction d'initialisation de la fonction d'activation d'un agent contexte selon un paramètre d_{init}
$\hat{y}_l : \mathbb{R}^i \to \mathbb{R}^o$	Modèle local d'un agent context l
$\Theta(\hat{y}_l, X_t)$	Fonction de mise à jour d'un modèle local
$eval(\hat{y}_t, oracle_t) : \mathbb{R}^o \times \mathbb{R}^o \to \mathbb{R}$	Fonction d'évaluation de la qualité d'une prédiction d'un modèle local
$X \in h_l \Leftrightarrow \forall j \in [1, i], a_j \leq x_j \leq b_j$	Fonction d'activation d'un agent contexte l définie par un hyperrectangle h_l
$Voisinage(X_t)$	Fonction de filtrage des voisins du point X_t
$Voisinage_generalise(X_t)$	Fonction étendue de filtrage des voisins du point X_t selon le paramètre de distance d
$dilatation(h_l) = h_l * \alpha$	Fonction de dilatation de la fonction d'activation d'un agent contexte selon un paramètre α
$retractation(h_l) = h_l * \rho$	Fonction de rétractation de la fonction d'activation d'un agent contexte selon un paramètre ρ
$\exists l \in Voisinage_generalise(Xt) : eval(\hat{y}_{t,l}, oracle_t) < precision$	Condition de dilatation d'un agent contexte et de mise à jour du modèle local selon le paramètre *precision*
$\forall l \in Voisinage(Xt) : eval(\hat{y}_{t,l}, oracle_t) > precision$	Condition de rétractation d'un agent contexte selon le paramètre *precision*
$\forall l \in Voisinage(Xt) : eval(\hat{y}_{t,l}, oracle_t) < precision$	Condition de mise à jour du modèle locale selon le paramètre *precision*
$\nexists l \in Voisinage_generalise(Xt) : eval(\hat{y}_{t,l}, oracle_t) < precision \vee Voisinage_generalise(X_t) = \emptyset$	Condition de création d'un agent contexte selon le paramètre *precision*

TABLE 3.1 – Résumé des principales notations

3.2.3 Discussion des résultats

Le modèle est implémenté et évalué dans les travaux de thèse respectifs de Thibault Fourez [Fourez, 2024] et de Clement Blanco-Volle [Blanco-Volle et al., 2024a].

3.2.3.1 Études comparatives sur jeu de données jouet

Dans sa thèse (dont les contributions applicatives sont présentées dans la Section 3.3), T. Fourez [Fourez, 2024] a produit une implémentation du modèle sous le nom de *Smapy* sous le langage Python dont nous avons étudié les performances sur trois jeux de données jouets de classification binaire à deux variables d'entrées inclus dans la librairie *scikit-learn* [Pedregosa et al., 2012] et régulièrement utilisés à des fins de comparaison de modèles :

- *Moons* : Deux nuages de points entrelacés expliqués par deux variables, avec le paramètre `noise=0.3`.
- *Circles* : Un nuage de point circulaire enclavé dans un autre nuage en forme d'anneau, avec les paramètres `noise=0.2` et `factor=0.5`.
- *Linearly separable* : Deux nuages de points avec une frontière linéaire expliquée par une seule des deux variables

Chaque jeu de données contient 100 points. Ils sont centrés et réduits à l'aide du modèle `StandardScaler` de *scikit-learn* avant apprentissage.

L'objectif de l'expérimentation est de comparer la performance entre quatre types de classifieurs linéaires utilisés comme modèle local dans *Smapy* avec la performance du classifieur seul.

Les quatre classifieurs utilisés pour l'expérimentation sont parmi ceux disponibles dans la librairie scikit-learn :

- Un régression logistique (Logit)
- Linear Support Vector Clasification (SVC)
- Deux algorithmes passifs-agressifs (PA-I et PAII)

Dans un premier temps, les combinaisons optimales des hyper-paramètres des quatre classifieurs sont obtenues en recherchant la combinaison de paramètres obtenant le meilleur score de précision selon une exploration exhaustive de paramètres (grid-search) en utilisant une validation croisée à 5 blocs.

Une fois ces combinaisons obtenues, nous recherchons la combinaison optimale des paramètres de *Smapy* pour chaque classificateur linéaire parmi une grille de paramètres avec une validation croisée à 5 blocs. Les agents contextes des instances *Smapy* encapsulent comme modèle interne le modèle linéaire correspondant, entraîné avec les paramètres de sa combinaison optimale obtenue précédemment. Ce protocole est répété pour chaque jeu de données afin d'obtenir 12 instances de *Smapy* et 12 instances de classificateur linéaire correspondantes, toutes optimisées par validation croisée. Les instances de *Smapy* optimisées sont ensuite comparées aux classificateurs linéaires à l'aide de deux mesures d'évaluation :

- Précision de la classification (multiclasses) moyennée sur les cinq itérations de validation croisée

— Frontières de décision des modèles (linéaires ou *Smapy*) entraînés avec les meilleures combinaisons de paramètres obtenues par validation croisée.

La table 3.2 présente les performances obtenues entre les modèles linéaires (meilleure combinaison de paramètres) seuls et l'encapsulation de ces mêmes modèles par *Smapy*.

	Modèle seul	**Modèle + SMA**
	MOONS	
Logit	0.83	**0.89**
SVM linéaire	0.86	**0.89**
PA-I	0.82	**0.89**
PA-II	0.84	**0.87**
	CIRCLES	
Logit	0.49	**0.83**
SVM linéaire	0.53	**0.83**
PA-I	0.53	**0.83**
PA-II	0.53	**0.83**
	LINEARLY SEPARABLE	
Logit	**0.92**	0.91
SVM linéaire	0.90	**0.91**
PA-I	0.89	**0.90**
PA-II	**0.89**	**0.89**

TABLE 3.2 – Comparaison des précisions de classification obtenues pour chaque dataset et pour chaque modèle. [Fourez et al., 2022b]

Les résultats ne montrent pas de différence significative en termes de précision pour le jeu de données linéairement séparable *Linearly separable*. Les classificateurs linéaires obtiennent déjà un score élevé malgré le bruit dans les données. Cependant, pour les deux autres jeux de données, nous observons une amélioration de la précision avec les instances *Smapy*. En particulier, nous observons une amélioration de $\sim 30\%$ pour l'ensemble de données Circles, pour lequel les classificateurs linéaires seuls donnent un résultat faible (50%). La faible performance de ces classificateurs s'explique par la faible séparabilité linéaire du jeu de données. Les précisions obtenues sur le jeu de données *Moons* (cas intermédiaire en termes de séparabilité linéaire) sont légèrement meilleures avec l'approche *Smapy*, mais les classificateurs linéaires seuls permettent d'obtenir des scores satisfaisants.

La Figure 3.2 offre une représentation graphique des frontières de décision obtenues par les classifieurs linéaires seuls et par *Smapy*. On observe que les classificateurs linéaires seuls donnent des frontières linéaires qui conviennent au problème de classification pour les jeux de données *Moons* et *Linearly separable*. L'approche *Smapy* sur ces deux ensembles de données reproduit ce comportement linéaire dans les frontières. En revanche, pour l'ensemble de don-

nées *Circles*, les modèles linéaires seuls sont incapables de séparer les deux nuages de points enfermés, contrairement à l'approche *Smapy*. Cela illustre la capacité de notre modèle à faire émerger des frontières de décision complexes qui résultent des interactions et de l'organisation des fonctions d'activation des agents contextes.

Cette première expérimentation permet d'illustrer et de comparer les performances de notre approche sur une tâche de classification. L'approche ensembliste, visant à combiner les prédictions de plusieurs modèles, permet ici d'améliorer les résultats de classification comparativement à l'utilisation des modèles locaux seuls. Ce résultat n'est pas surprenant, puisque les modèles linéaires sont par nature incapables de représenter des distributions de données complexes. Cependant, l'étude des frontières de décision permet d'illustrer une propriété fondamentale de notre approche : l'émergence de ces frontières à la suite d'un processus d'auto-organisation des agents contextes. Ainsi, la structuration de ces frontières évolue en fonction des feedbacks successifs envoyés aux agents contextes. L'organisation du système à un instant t est donc informative de la difficulté d'approximation de la fonction. En effet, l'existence ou non de conflits entre agents (que l'on peut notamment observer aux frontières de décision) présente un potentiel intéressant en termes d'explicabilité. Il nous a alors semblé intéressant de poursuivre l'exploration des propriétés de ces frontières et des propriétés qui en découlent. La section suivante présente une nouvelle expérimentation qui vise à apporter de nouvelles métriques d'explicabilité.

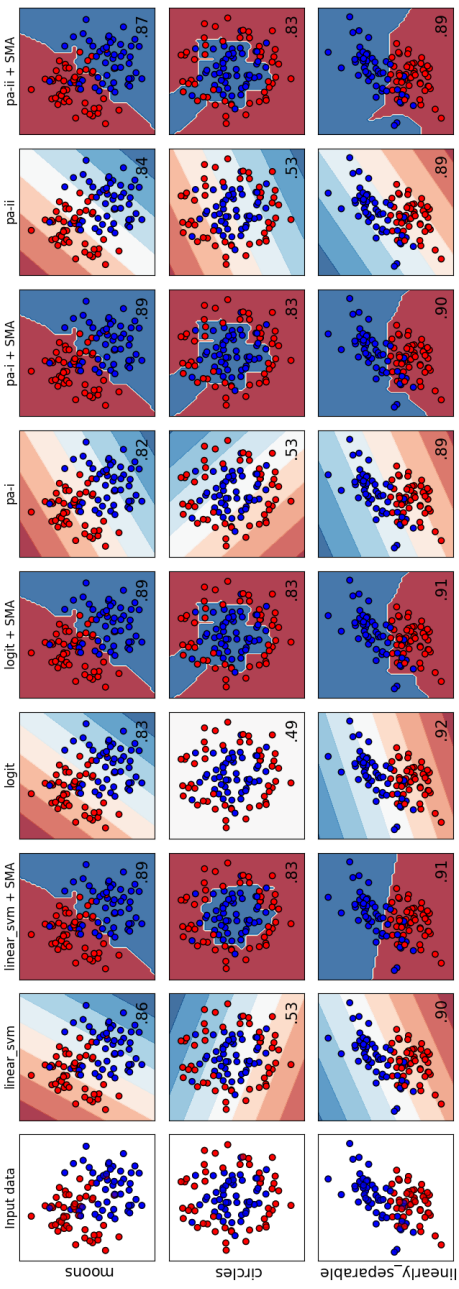


FIGURE 3.2 – Représentations graphiques des frontières de décision obtenues pour chaque dataset (lignes) et pour chaque modèle linéaire seul ou dans une instance de Smapy (colonnes). La précision de classification obtenue est indiquée en bas à droite pour chaque cas [Fourez, 2024].

3.2.3.2 Apports de l'auto-organisation à l'explicabilité

Dans les travaux de C. Blanco-Volle [Blanco-Volle et al., 2024a], nous nous sommes intéressés à l'étude des propriétés des frontières de décision dans notre système pour dégager de nouvelles métriques d'explicabilité. Pour cette étude, nous choisissons quatre fonctions bidimensionnelles sélectionnées pour leurs variations et la difficulté qu'elles posent lors de tâche d'optimisation de par la présence d'optimum local et de variations non linéaires [Jamil and Yang, 2013] :

- SSR functions : $f(x,y) = \sin\left(\sqrt{x^2+y^2}\right)$
- Booth : $f(x,y) = (x+2y-7)^2 + (2x+y-5)^2, \quad -10 \leq x,y \leq 10$
- Goldstein-Price : $f(x,y) = \left[1+(x+y+1)^2(19-14x+3x^2-14y+6xy+3y^2)\right] \cdot \left[30+(2x-3y)^2(18-32x+12x^2+48y-36xy+27y^2)\right], \quad -2 \leq x,y \leq 2$
- Fonction de Beale : $f(x,y) = (1.5-x+xy)^2 + (2.25-x+xy^2)^2 + (2.625-x+xy^3)^2, \quad -4.5 \leq x,y \leq 4.5$

Pour chacune de ces fonctions (visibles dans la Figure 3.3), nous avons généré des ensembles de données synthétiques contenant 8000 observations. Les observations sont échantillonnées uniformément dans l'espace d'entrée.

Nous choisissons comme modèle local une régression linéaire et comparons les performances de notre modèle d'apprentissage ensembliste avec des modèles issus de la littérature scientifique tels que les arbres de décision [Breiman and Friedman, 2017], les *Support Vector Machines* (SVMs) [Chang and Lin, 2011], les régressions linéaires [Weisberg, 2005], le *gradient boosting* [Friedman, 2001], les forêts aléatoires *random forests* [Breiman, 2001], XGBoost [Chen and Guestrin, 2016] et LightGBM [Ke et al., 2017]. Les deux derniers ont été choisis car ils offrent tous deux d'excellentes performances en termes de vitesse d'apprentissage et de généralisation [Bentéjac et al., 2021] : XGBoost pour sa fiabilité et son efficacité, tandis que LightGBM pour sa performance d'apprentissage extrêmement rapide.

Les données d'entrée sont normalisées linéairement entre -1 et 1. Le meilleur ensemble d'hyper-paramètres est trouvé en effectuant une recherche par grille de valeurs dans le but de minimiser l'erreur quadratique moyenne obtenue par validation croisée 5 fois. Les meilleurs ensembles d'hyper-paramètres trouvés sont présentés dans la Table 3.3 et correspondent aux paramètres utilisés dans scikit-learn [Pedregosa et al., 2012], XGBoost [Chen and Guestrin, 2016], et LightGBM [Ke et al., 2017].

Les performances des algorithmes sont évaluées à partir du meilleur jeu d'hyper-paramètres pour déterminer l'erreur quadratique R^2, l'erreur quadratique moyenne (MSE) et l'erreur moyenne absolue (MAE). Le tableau 3.4 présente les résultats que nous avons obtenus.

	hyperparameters	SSR	Booth	Goldstein-Price	Beale
Notre algorithme	R	0.1	0.35	0.1	0.05
	S_{good}	0.01	0.15	0.01	0.1
	S_{bad}	0.2	0.2	0.2	0.3
	α	0.4	0.1	0.2	0.2
	memory_length	20	50	200	20
XG Boost	learning_rate	0.1	0.05	0.05	0.1
	max_depth	9	9	9	9
	n_estimators	300	300	300	300
	objective	abs. error	abs. error	squ. error	abs. error
Light GBM	learning_rate	0.1	0.1	0.1	0.1
	max_depth	9	5	9	3
	n_estimators	5	5	5	5
	objective	300	300	200	300
	min_child_samples	huber	l2	tweedie	tweedie
Random Forest	bootstrap	true	true	true	true
	criterion	abs. error	poisson	poisson	poisson
	max_depth	9	9	9	9
	max_features	null	null	null	null
	min_samples_leaf	1	1	1	1
	min_samples_split	2	2	2	2
	n_estimators	300	200	300	300
Decision Tree	criterion	abs. error	poisson	poisson	poisson
	max_depth	9	9	9	9
	max_features	null	null	null	null
	min_samples_leaf	1	2	2	1
	min_samples_split	2	2	2	2
Gradient boosting	learning_rate	0.1	0.1	0.2	0.2
	loss	abs. error	huber	squ. error	huber
	max_depth	9	9	5	5
	max_features	null	null	null	null
	min_samples_leaf	2	4	1	1
	min_samples_split	2	5	2	2
SVM	epsilon	0.1	0.1	0.1	0.5
	gamma	scale	scale	scale	scale
	kernel	rbf	rbf	poly	rbf
Linear Reg.	fit_intercept	true	true	true	true

TABLE 3.3 – Valeurs des hyperparamètres après *grid-search* sur les résultats de la validation croisée à 5 blocs

		R^2	MSE	MAE
Beale	Decision Tree	0,983	6,94e+06	1,07e+03
	Gradient boosting	0,995	2,08e+06	6,19e+02
	LightGBM	0,996	1,61e+06	4,75e+02
	Linear Reg.	-0,001	4,16e+08	1,19e+04
	MAS	**0,997**	1,34e+06	**2,53e+02**
	Random Forest	0,995	2,02e+06	5,23e+02
	SVM	-0,139	4,74e+08	8,28e+03
	XGBoost	**0,997**	**1,29e+06**	4,11e+02
Booth	Decision Tree	0,994	1,29e+03	2,60e+01
	Gradient boosting	0,999	1,39e+02	7,44e+00
	LightGBM	0,999	1,38e+02	8,09e+00
	Linear Reg.	0,426	1,17e+05	2,63e+02
	MAS	**1,000**	**9,52e+00**	**9,91e-01**
	Random Forest	0,998	3,57e+02	1,31e+01
	SVM	0,811	3,89e+04	7,85e+01
	XGBoost	**1,000**	8,72e+01	6,01e+00
Goldstein-Price	Decision Tree	0,994	1,02e+08	5,29e+03
	Gradient boosting	**0,999**	2,37e+07	2,62e+03
	LightGBM	**0,999**	1,80e+07	1,82e+03
	Linear Reg.	0,249	1,22e+10	6,79e+04
	MAS	**0,999**	**1,21e+07**	**7,02e+02**
	Random Forest	0,998	3,98e+07	3,38e+03
	SVM	-0,127	1,83e+10	5,17e+04
	XGBoost	**0,999**	1,46e+07	1,61e+03
SSR	Decision Tree	0,960	1,89e-02	9,30e-02
	Gradient boosting	0,997	1,22e-03	2,30e-02
	LightGBM	0,998	7,68e-04	1,98e-02
	Linear Reg.	0,000	4,77e-01	6,09e-01
	MAS	**0,999**	**4,97e-04**	**1,39e-02**
	Random Forest	0,978	1,03e-02	6,48e-02
	SVM	0,972	1,32e-02	7,90e-02
	XGBoost	**0,999**	5,93e-04	1,65e-02

TABLE 3.4 – Comparaison des performances R^2, MSE, MAE entre notre approche et les algorithmes de référence

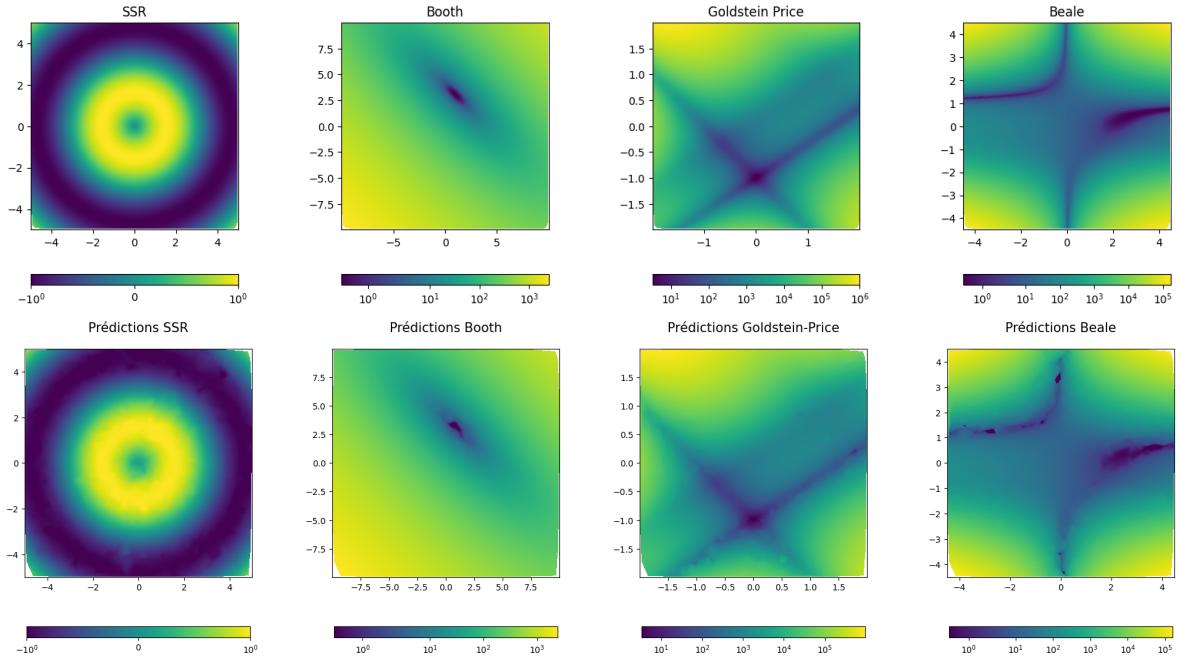
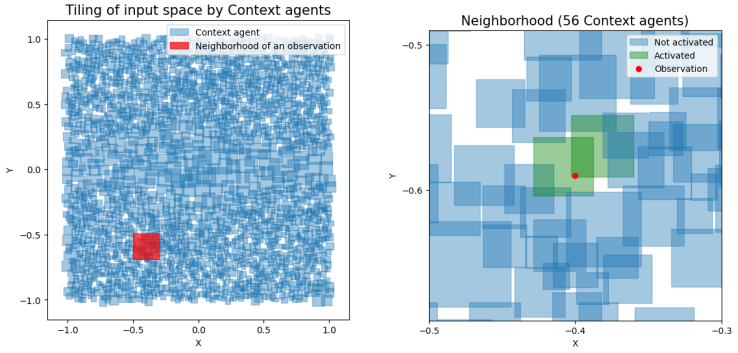


FIGURE 3.3 – Visualisation des fonctions 2D utilisées pour générer les ensembles de données pour l'expérience (ligne du haut) et des fonctions approximées par notre modèle (ligne du bas). Les niveaux de couleur approchant le jaune correspondent à des valeurs plus élevées, tandis que les niveaux de couleur approchant le bleu correspondent à des valeurs plus faibles [Blanco-Volle et al., 2024a].

Notre approche obtient la meilleure MAE et le meilleur coefficient de détermination pour les quatre fonctions étudiées. Il obtient également le meilleur MSE pour les fonctions SSR, Goldstein-Price et Booth. XGBoost reste meilleur en termes d'erreur quadratique moyenne sur la fonction de Beale. Nous pouvons observer que notre approche atteint des performances comparables à celles de XGBoost et de LightGBM pour la plupart des fonctions étudiées tout en dépassant les performances de *Random Forest*, *Decision Tree*, *Gradient Boosting* et *SVM*. En général, notre approche est capable d'apprendre les variations de la fonction sous-jacente à partir des données comme l'illustre la Figure 3.3.

Dans cette étude, nous avons étudié comment la structure l'organisation spatiale des agents contextes dans l'espace des entrées peut être étudiée au travers de nouvelles métriques permettant d'analyser et expliquer le comportement du système. La Figure 3.4a présente une visualisation de l'espace de pavage des agents contextes obtenue sur la fonction de Beale. Cette fonction présente un régime de fortes variations sur son espace de définition, avec des pics marqués aux coins du domaine d'entrée et une amplitude moins marquée sur le plateau central.

Après apprentissage, l'organisation et la forme des agents contextes peuvent être visualisées



(a) (b)

FIGURE 3.4 – Visualisation du pavage de l'espace (normalisé entre −1 et 1) par les agents contextes pour la fonction Beale. Chaque rectangle bleu représente un agent *Context*, et le rectangle rouge est un exemple du voisinage généralisé d'une observation. Visualisation des agents *Context* dans le voisinage d'une observation (3.4b). [Blanco-Volle et al., 2024a]

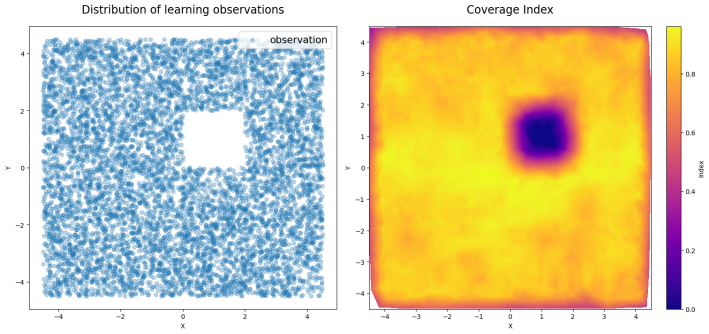


FIGURE 3.5 – Comparaison de la carte de distribution des observations utilisées pour entraîner le modèle (à gauche) et de la visualisation de l'indice de couverture associé à ce modèle (à droite). [Blanco-Volle et al., 2024a]

dans un plan en deux dimensions (voir Figure 3.4a) où il est possible de projeter l'ensemble des hyper-rectangle définissant les fonctions d'activation des agents contextes sur l'espace de définition de la fonction. Ainsi, chaque rectangle bleu définit l'espace couvert par la fonction d'activation d'un agent contexte.

Cette interprétation spatiale des agents contextes permet de définir deux nouvelles métriques pour évaluer l'incertitude liée à cette organisation spatiale :

— **Incertitude épistémique** : la Figure 3.5 affiche un pavage de l'espace par un ensemble d'agents contextes. On observe l'existence de zones d'espace non couvertes par les agents contextes, ainsi que des espaces couverts par plusieurs agents contextes. Il est possible pour un agent contexte d'évaluer le degré de couverture de sa fonction

d'activation et ainsi de calculer le volume couvert par les fonctions d'activation des agents contextes inclus dans le voisinage :

$$p_{\text{coverage}}(X_t) = \frac{V_{agents}}{V_{\text{neighborhood}}}$$

où $V_{\text{neighborhood}}$ représente le volume de l'hyper-rectangle représentant le voisinage du point X_t et V_{agents} le volume couvert par les fonctions d'activation des agents contextes inclus dans ce voisinage.

Le calcul du volume par les agents contextes V_{agents} peut être complexe à calculer du fait de la superposition des hyper-rectangles. Ainsi, nous proposons d'approximer cette valeur à l'aide d'une approche par criblage uniforme. On discrétise l'espace du voisinage en un espace composé de N points $p_1, p_2, ..., p_N$ répartis de manière uniforme autours du point X_t. On définit une fonction indicatrice $I_R(p_i)$ où R définit l'ensemble des hyper-rectangles des agents contextes inclus dans le voisinage, et chaque p_i tel que :

$$I_R(p_i) = \begin{cases} 1, & \exists r_j \in R, \quad r_j = \prod_{k=1}^{d} [a_j^k, b_j^k], \quad \text{tel que } a_j^k \leq p_i^k \leq b_j^k, \quad \forall k \in \{1, \ldots, d\} \\ 0, & \text{sinon} \end{cases}$$

On peut alors définir $p_{\text{couverture}}$ par :

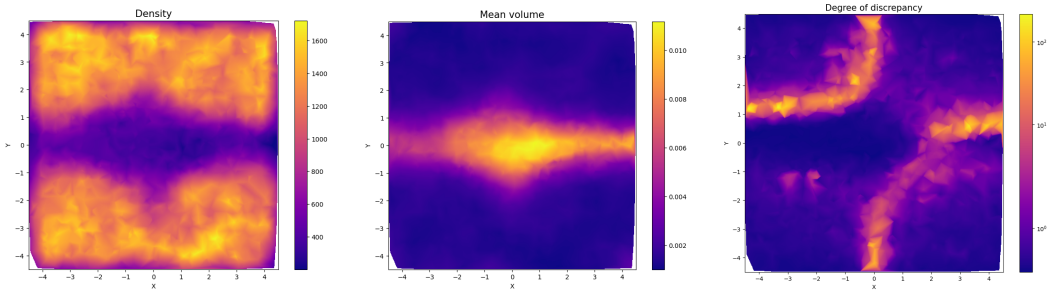
$$p_{\text{couverture}}(X_t) = \frac{1}{N} \sum_{i=1}^{N} I_R(p_i)$$

Ainsi, une valeur $p_{\text{couverture}}$ proche de 1 informe de la bonne couverture de l'espace par les agents contextes : les agents contextes se positionne comme compétent sur cette région de l'espace. À l'inverse, une valeur proche de 0 informe de l'existence de points non couverts. L'existence de points non couvert dans l'espace des variables d'entrée peut fournir des indications sur la présence d'anomalies dans l'apprentissage ou d'une mauvaise couverture des données d'entraînement. La Figure 3.5 montre un exemple d'anomalie sur un scénario où notre système apprend à partir d'un jeu de données incomplet. Le calcul de l'indice de couverture sur cet espace permet de localiser les portions de donnée manquantes.

— **Incertitude aléatoire** : un second niveau d'analyse du comportement des agents porte sur le consensus dans la prédiction. Quand une observation est fournie au système, les agents contextes activés fournissent chacun une prédiction. On peut calculer le degré de consensus entre les prédictions des modèles locaux $\hat{y}_l$ des agents contextes activés :

$$\sigma_{\text{consensus}}(X_t) = \sqrt{\sum_{\hat{y}_l} \frac{(\hat{y}_l(X_t) - p_{\text{mean}})^2}{|Voisinage(X_t)|}}$$

où p_{mean} est la moyenne des valeurs prédites par l'ensemble des modèles locaux $\hat{y}_l$ des agents contextes activés. Cette valeur permet ainsi d'estimer le degré de désaccord dans les prédictions réalisées par un ensemble agents contextes activés par un point d'observation.



(a) (b) (c)

FIGURE 3.6 – Visualisation de la densité (3.6a), du volume moyen (3.6b), et du degré de consensus (3.6c) des agents contextes [Blanco-Volle et al., 2024a].

La distribution des agents contextes dans l'espace des entrées émerge des interactions au cours des phases d'apprentissage. Nous formulons donc l'hypothèse que cette organisation spatiale peut être informative de la nature et de la dynamique de la fonction que l'on cherche à approximer. La Figure 3.6a montre la carte de densité des agents contextes après apprentissage sur la fonction de Beale pour une taille de voisinage donnée. On constate un couloir au centre de la figure pour $y \in [-1, 1]$ dans lequel la densité d'agents est faible. Sur le reste de la figure, la densité d'agents est plus élevée. Similairement, la Figure 3.6b montre le volume moyen des agents contextes selon le même voisinage. On y observe que les zones à forte densité d'agents contiennent les agents les plus petits et inversement. Ces deux zones correspondent à des variations très différentes de la fonction de Beale. La zone contenant les agents les plus volumineux (peu dense) correspondant à un plateau dans lequel l'amplitude du gradient de la fonction présente une faible variation. Au contraire de la zone contenant les plus petits agents (plus dense) qui correspond à une région de l'espace dans laquelle l'amplitude du gradient de la fonction varie fortement à mesure que l'on se rapproche de la bordure de la zone de définition.

Un dernier niveau d'analyse repose dans l'analyse des contradictions entre les prédictions des modèles locaux des agents contextes. Le degré de contradiction κ pour un voisinage donné peut être obtenu par le ratio entre le degré de consensus $\sigma_{\text{consensus}}$ et la moyenne des prédictions des agents contextes du voisinage p_{mean} :

$$\kappa = \frac{\sigma_{\text{consensus}}}{|p_{\text{mean}}|} \tag{3.1}$$

La Figure 3.6c présente la distribution du degré de contradiction dans l'espace de définition de la fonction. Une valeur κ proche de 0 (en bleu) signifie que les modèles locaux des agents contextes voisins de la zone convergent dans leurs prédictions. Ainsi, la fonction sous-jacente aux données présente une faible variabilité dans le voisinage de l'observation. En revanche, une valeur élevée indique que le régime de variation de la fonction sous-jacente est susceptible de changer brutalement dans cette zone ou de difficultés pour les agents contextes à couvrir cet

espace. Le degré de consensus permet une cartographie des régions de l'espace des variables d'entrée dans lesquelles l'approximation de la fonction sous-jacente est la plus difficile. Pour la fonction de Beale, le degré de consensus met en évidence les régions de l'espace comportant les variations les plus complexes (cf Figure 3.6c).

L'introduction de nouvelles métriques portant sur l'analyse de l'organisation spatiale des agents contextes et le degré de consensus (ou de contradiction) dans leurs propositions des modèles locaux présente un intérêt en termes d'explicabilité, à la fois pour expliquer le comportement du système apprenant, mais aussi pour expliquer la nature de la fonction sous-jacente. Les résultats obtenus restent préliminaires et présentent comme principale limitation de porter sur des fonctions de faible dimension, mais reconnues pour leur nature complexe. Cependant, l'existence de ce lien entre organisation structurelle des agents contextes et dynamique de la fonction sous-jacente présente un intérêt certain pour la construction de nouvelles métriques d'apprentissage actif (ce point est discuté dans la Section 5.2 présentant les perspectives de recherche).

3.2.4 Synthèse

Dans cette première partie du chapitre, nous avons présenté un algorithme d'apprentissage ensembliste coopératif (cf Section 3.2). Ce système, construit sur des travaux précédents (cf Section 3.2.1), propose d'aborder l'approximation d'une fonction comme un problème d'organisation par un ensemble d'agents appelés agents contextes. Nous avons présenté une nouvelle formalisation du système (cf Section 3.2.2) et deux expérimentations pour comparer et étudier la dynamique de notre système, l'une sur des jeux de données jouets pour mettre en évidence l'émergence de frontières de décision complexes entre les classes de points (cf Section 3.2.3.1, et l'autre, pour dégager l'existence de nouvelles métriques permettant d'étudier le comportement du système et ces fonctions sous-jacentes (cf section 3.2.3.2). Ces deux expérimentations ont montré des performances similaires aux algorithmes issus de la littérature, mais présente la limitation, pour rester didactique, d'être appliqués à des problèmes à faible nombre de dimension. L'extension de ces expérimentations à des problèmes de plus grande dimension est en cours au travers d'une implémentation open source de notre modèle qui vise à facilité la comparaison des performances de notre approche. Les évolutions sont discutés dans la section 5.2 de ce manuscrit. Nous nous intéressons notamment à l'utilisation de notre modèle dans un cadre de commande prédictive (Model Predictive Control) appliqué aux véhicules connectés et dans des travaux de détection d'anomalies explicables dans le domaine de la robotique de service.

3.3 Analyse de la mobilité : classification des modes de transport

Dans le Chapitre 2 nous avons discuté de la possibilité offerte par les nouvelles technologies à générer des traces à partir des déplacements des citoyens. L'analyse des traces de mobilité est un problème intéressant pour l'apprentissage supervisé. En effet, l'exploitation de ces traces implique de construire des modèles permettant de lier la trace (par une analyse de ses caractéristiques) à un comportement d'utilisateur. Il s'agit donc bien d'un problème de construction de modèle associatif à partir de jeu de données exemples, dans le but de prédire (et donc de classifier) ou d'inférer un comportement d'utilisateur. Dans les travaux présentés dans cette section, nous nous sommes spécifiquement intéressés à la classification des modes de transports à partir de traces générées par des applications mobiles, et plus spécifiquement en exploitant des données de géopositionnement et d'accéléromètre. Ces travaux sont issus de la thèse de Thibault Fourez [Fourez, 2024] dans le cadre d'une convention industrielle de formation par la recherche (CIFRE) avec l'entreprise CITEC, un bureau d'études en ingénierie des mobilités.

Dans la Section 3.3.1 nous présentons le contexte scientifique des travaux, en identifiant les différentes étapes de l'analyse de traces pour la détection des modes de transport. Dans la Section 3.3.2, nous présentons une chaîne de traitements permettant la classification du mode de transport. La nouveauté de cette chaîne de traitements repose dans la prise en compte des écarts temporels dans les points de données. La chaîne de traitements est appliquée à plusieurs algorithmes de classification sur des jeux de données issus de la littérature et sur un nouveau jeu de données en accès libre que nous avons produit.

3.3.1 Contexte des travaux

Détection de mode de transport. La connaissance par les gouvernements locaux de l'état de la mobilité des usagers sur leur territoire est nécessaire pour éclairer les choix d'urbanisme et de développement des offres de transports [Bachir et al., 2019]. [Fourez et al., 2025] présentent 5 questions pour analyser la mobilité :

1. **Qui** sont les gens qui se déplacent ?
2. **Où** se déplacent-ils ?
3. **Quand** se déplacent-ils ?
4. **Comment** se déplacent-ils ?
5. **Pourquoi** se déplacent-ils ?

L'identification des modes de transport utilisés par des citoyens par l'observation de l'utilisateur ou de l'environnement est un sujet de recherche en plein essor. En effet, la généralisation

Cette section s'appuie sur l'article: Thibault Fourez, Nicolas Verstaevel, Frédéric Migeon, Frédéric Schettini, Frédéric Amblard. **Transport Mode Detection on GPS and accelerometer data : a temporality based workflow**. *Transportation Research Procedia, 82, 3454-3471.* 2025.

de l'usage des téléphones et autres dispositifs connectés constitue une grande opportunité pour les décideurs locaux de mesurer et modéliser l'impact des politiques d'urbanisme et de transports publics [Sauerländer-Biebl et al., 2017]. Ainsi, le nombre de sources de données et de modèles dans le domaine de la mobilité et du transport a fortement proliféré au cours de la dernière décennie, offrant de nouvelles opportunités pour analyser la mobilité [Bellini et al., 2024]. Les enquêtes de déplacement réalisées par les gouvernements auprès d'un grand nombre de citoyens demeurent l'outil principal d'évaluation de la mobilité. Cependant, ces enquêtes sont peu fréquentes (deux à trois fois par décennie) car coûteuses et essentiellement déclaratives (les données proviennent des déclarations des usagers et ne sont pas observées de façon précise et objective) [Bachir et al., 2019, Gong et al., 2012]. Un enjeu de taille pour les collectivités est donc d'avoir une bonne estimation de l'état de la mobilité tel qu'il serait donné par une enquête de grande ampleur, sur une période et un territoire donné. La nécessité de s'adapter à des changements rapides des environnements et des usages (par exemple l'impact de la COVID-19) induit de nouveaux besoins en matière de modélisation des déplacements, et suscite l'intérêt pour de nouvelles méthodes de collecte des comportements de déplacement, notamment à l'aide d'applications pour téléphones [Lawson et al., 2023].

Données. Dans un premier temps, nous nous sommes intéressées aux sources de données disponibles pour permettre l'analyse de la mobilité. [Fourez, 2024] propose une typologie en trois catégories :

- Les données **contextuelles** qui regroupent les données indépendantes des utilisateurs et les informations sur le contexte spatio-temporel des déplacements : on y retrouve les données des réseaux routiers (HERE Map Content (anciennement Navstreets) [HERE, 2024] fournies par l'entreprise HERE ou le réseau d'OpenStreetMap (OSM) [OpenStreetMap contributors, 2017]), les informations des transports en commun (via le format General Transit Feed Specification GTFS [Google, 2023]), le découpage administratif (IRIS [Insee, 2016]), ou encore les points d'intérêt (commerces, hôpitaux, services, etc.).
- Les données **agrégées** qui sont le résultat de l'analyse du comportement d'un groupe d'usagers dans un contexte spatial, temporel et social. Elles sont généralement reliées à un ou plusieurs types de données contextuelles et viennent y apporter des informations statistiques macroscopiques sur la population. On y retrouve les données de comptage en section, les flux d'origine destination, les enquêtes ménage déplacement ou encore les données des fournisseurs de services numériques (ex. : télécom).
- Les données **utilisateur**, qui sont des séries temporelles de mesures successives collectées par des capteurs embarqués sur des personnes. On y retrouve principalement les données de géolocalisation (GNSS [Nawaz et al., 2020b], Téléphonie mobile [Bachir et al., 2019], Wifi [Shu et al., 2015], Bluetooth à basse consommation [Yuan and Mills, 2019]) et les données de matrices inertielles (IMU [Iskanderov and Guvensan, 2020]).

La Figure 3.7 présente un schéma récapitulatif des différents types de données.

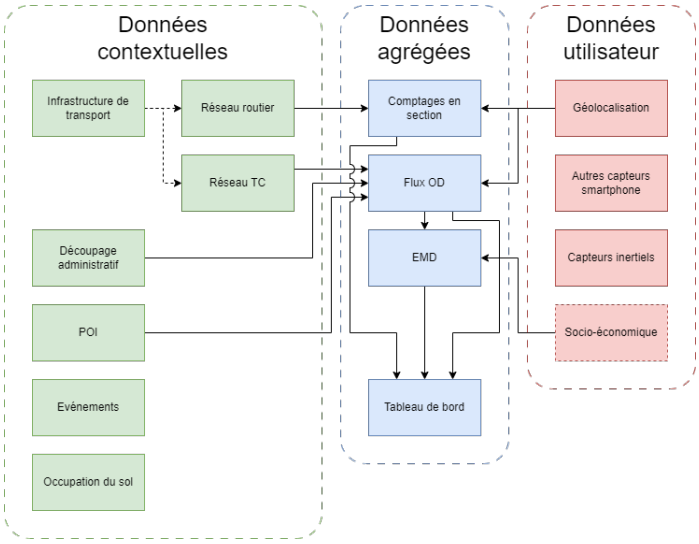


FIGURE 3.7 – Hiérarchie des différents types de données selon [Fourez, 2024]

Les données utilisateurs offrent de nouvelles opportunités pour l'analyse de la mobilité individuelle. En effet, l'usage des données GNSS permet de suivre les traces des déplacements individuels à une plus large échelle spatio-temporelle. [Sadeghian et al., 2021] propose une revue des méthodes de détection des modes de transport basées sur les données de suivi GPS. Les auteurs classifient les méthodes selon trois catégories : approches statistiques, approches à base de règles et apprentissage machine. La vitesse moyenne, la vitesse maximale et l'accélération sont les trois variables les plus couramment utilisées pour détecter un mode de transport. Les résultats de leur étude montrent qu'il n'existe pas d'algorithme standard utilisé pour la détection des modes de transport et qu'il est actuellement difficile de proposer une méthode optimale pour tous les ensembles de données. De plus, l'évaluation des performances des algorithmes souffre d'un manque de procédures standard et d'un manque de jeux de données dédiés.

Détection du mode de transport. Le problème de détection du mode de transport (TMD) est un problème de classification supervisé dans lequel des données utilisateur sont utilisées pour inférer le mode de transport utilisé lors d'un déplacement [Biljecki et al., 2013].

La **trace** d'un utilisateur est une série temporelle de points d'observations (potentiellement multi-dimensionnels et de dimensions différentes) mesurée sur un seul utilisateur. Elle est composée d'**arrêts** et de **trajets**.

— Un **trajet** est une période durant laquelle un utilisateur est en déplacement. Il est délimité par une origine et une destination qui sont des lieux d'intérêts pour l'utilisateur (dans la mesure où ils justifient son déplacement). Un trajet peut être multimodal et est composé de *segments* monomodaux.

— Un **segment** est une période durant laquelle un utilisateur se déplace avec un seul mode de transport. Il est délimité par un point de départ et un point d'arrivée. Ces deux points peuvent être des points d'intérêt pour l'utilisateur ou des correspondances entre deux modes de transport différents.

La détection du mode de transport implique la réalisation de quatre étapes pour traiter les traces d'utilisateurs [Fourez, 2024] :

— **Segmentation** : la trace d'un utilisateur est une série temporelle de mesures successives. L'étape de segmentation consiste à identifier les segments présents dans la trace en identifiant les arrêts. Deux approches sont présentes dans la littérature : la première consiste à considérer les arrêts comme l'une des classes à prédire. Cela nécessite que les points d'arrêt soient correctement labélisés dans le jeu de données d'apprentissage et l'utilisation d'indicateurs statistiques (*features*) calculés sur un groupe de points à l'aide d'une fenêtre temporelle statique ou glissante afin de lisser les valeurs des attributs [Yang et al., 2018]. La seconde approche consiste à détecter les points d'arrêts dans la trace de l'utilisateur, soit en effectuant un pré-traitement utilisant des règles basées sur le temps et la distance [Nawaz et al., 2020b], soit directement via l'application de collecte [Chen et al., 2022].

— **Calcul des caractéristiques (*features*)** : pour permettre une meilleure identification du mode, il est possible de calculer pour chaque segment des caractéristiques. On distingue deux approches dans la littérature : l'utilisation d'indicateurs statistiques (moyenne, médiane, etc.), ou l'extraction de caractéristiques profondes (*deep features*) dans le cas des approches à apprentissage profond [Nawaz et al., 2020a]. Des approches permettent de sélectionner les caractéristiques les plus discriminantes, telles que les importances relatives des variables d'entrée calculées avec le critère de Gini à l'issue de l'algorithme Random Forest (RF) [Iskanderov and Guvensan, 2020].

— **Classification** : l'étape de classification consiste à associer à chaque segment son mode de transport. De nombreuses références utilisent l'apprentissage automatique pour effectuer cette tâche. Un algorithme est entraîné sur un jeu de données labélisées pour permettre la classification des nouveaux segments. [Fourez, 2024] propose une liste des algorithmes les plus utilisés dans ce cadre : la régression logistique (logit), les arbres de décision (CART), les classifieurs bayésiens naïfs, les réseaux bayésiens, les machines à vecteurs de support (SVM) et les modèles de Markov cachés. Des approches ensemblistes sont également étudiées, parmi lesquelles le bagging, les forêts aléatoires (RF) et l'algorithme Gradient Boosting. Des réseaux de neurones artificiels (ANN) denses et récurrents (LSTM) sont régulièrement utilisés dans la littérature.

— **Post-Traitement** : enfin, une dernière étape est possible pour filtrer le bruit qui peut être présent sur les classes de sortie. [Guvensan et al., 2017] utilise par exemple une méthode *Healing* où le mode est filtré à la suite d'un processus de vote majoritaire. Dans [Giri et al., 2022], un algorithme similaire appelé "homogénéisation" est utilisé en utilisant une fenêtre temporelle glissante pour réaliser le vote majoritaire et lisser les prédictions.

La Figure 3.8 résume les différentes étapes de la chaîne de traitement.

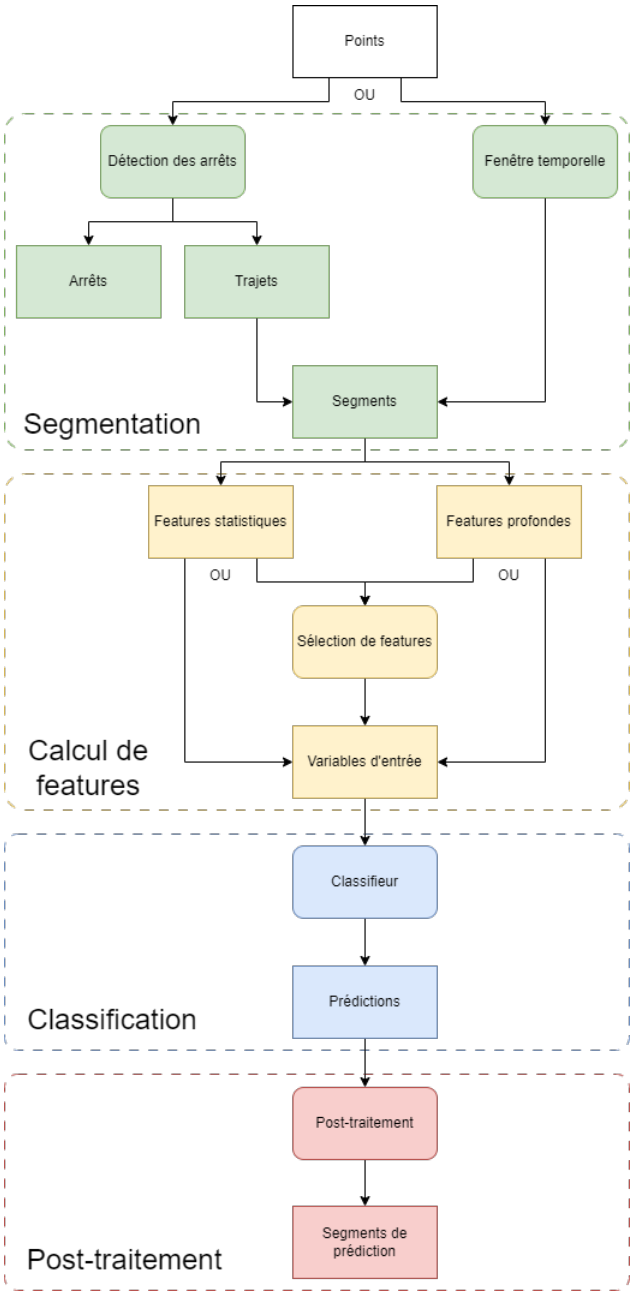


FIGURE 3.8 – Schéma récapitulatif des étapes de la détection du mode de transport [Fourez, 2024]

Mes travaux: *Classification des modes de transports*

La classification des modes de transports aborde la construction d'un modèle associatif à partir de sources de données utilisateurs. Dans nos travaux, nous nous sommes d'abord intéressés à la caractérisation des jeux de données disponibles (cf Section 3.3.2). Cette caractérisation nous a permis une première contribution via un nouveau jeu de données de traces utilisateur collecté par smartphone : OCC-TMD [Fourez et al., 2025]. Nous avons ensuite proposé et évalué un pipeline de traitements dont la nouveauté repose sur la prise en compte de l'écart temporelle entre deux points, améliorant ainsi comparativement les performances de classification par rapport à l'état de l'art [Fourez et al., 2025]. L'utilisation de *Random Forest* et des importances de Gini permet d'identifier l'influence des nouvelles features sur la qualité de la prédiction.

Dans la prochaine section, nous décrivons l'implémentation et évaluons comparativement les performances d'algorithmes de classification dans une chaîne de traitements pour la détection du mode de transport.

3.3.2 Évaluation d'un pipeline d'apprentissage machine pour la détection des modes de transport

Dans les travaux de thèse de Thibault Fourez, nous avons voulu comparer les performances de plusieurs classifieurs pour résoudre le problème de la détection du mode de transport à partir de données de géolocalisation et d'accéléromètre mesurées sur un smartphone. Dans un premier temps, nous présentons chacun des jeux de données, puis nous introduisons notre chaîne de prétraitement, pour entraîner et comparer différents modèles d'apprentissage.

Jeux de données. Nous avons identifié 2 jeux de données issu de la littérature scientifique : US-Transportation Mode (US-TMD) [Carpineti et al., 2018] et Microsoft GeoLife [Zheng et al., 2009], mais nous avons aussi constitué notre propre jeu de données open source, OCC-TMD [Fourez et al., 2025] dans le cadre du projet Vilagil [IRIT, 2019]. Pour permettre la comparaison sur les différents jeux de données, nous ne retenons que les modes *immobile*, *train*, *marche*, *voiture*, *bus* et *métro*.

OCC-TMD. Occitania Transport Mode (OCC-TM) [Fourez et al., 2025] est un jeu de données de mobilité que nous avons collecté à l'aide d'une application pour smartphone. Cette étude se concentre sur les données collectées par un utilisateur de 25 ans. Cet utilisateur a ensuite ajouté une étiquette correspondant au mode de transport (marche, voiture, bus, vélo, train ou métro) de chaque point d'observation. Le smartphone utilisé pour la collecte est un Samsung Galaxy A32 équipé du système d'exploitation Android 11. Cette application collecte passivement les positions GPS (voir tableau 3.5) et les signaux d'accéléromètre (voir tableau 3.6) du smartphone. La mise à jour des coordonnées GPS se fait sous la double condition d'un déplacement d'au moins 50 mètres depuis le dernier point de collecte et d'un écart de

10s entre deux mesures. Similairement, l'accélération a un écart d'au moins 1$m.s^{-}2$ avec le point précédent et au moins 1s entre deux-points. Les données du jeu de données ont été collectées par un seul utilisateur de manière discontinue du 26 juillet 2022 au 10 août 2022. Cet utilisateur s'est déplacé dans la région Occitanie dans le sud de la France (entre Toulouse et Montpellier), notant pour chaque déplacement l'heure de début, l'heure de fin et le mode de transport utilisé. Le jeu de données est présenté dans l'article [Fourez et al., 2025] et disponible à l'url https://zenodo.org/records/7386788. Le jeu de données présente un total de 36752 points d'observation. La répartition des modes de transports est illustrée dans la figure 3.10.

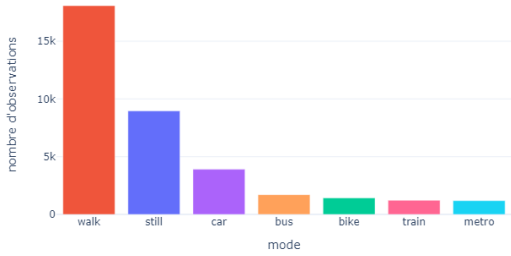


FIGURE 3.9 – Histogramme du nombre de points par mode de transport [Fourez, 2024].

TABLE 3.5 – Attributs des données de localisation

Attribut	**Description**	**Unité**
timestamp	Date et heure	Heure Unix (ms)
lat	Latitude	Système de coordonnées WGS 1984
lon	Longitude	Système de coordonnées WGS 1984
location_accuracy	Précision des coordonnées	m (mètres)
location_speed	Vitesse (depuis le point précédent)	$m.s^{-1}$ (mètres par seconde)
location_speed_accuracy	Précision de la vitesse	$m.s^{-1}$ (mètres par seconde)
location_heading	Relèvement (par rapport au Nord)	degrés [0,360)

TABLE 3.6 – Attributs des données d'accéléromètre

Attribut	Description	Unité
timestamp	Date et heure	Heure Unix (ms)
x	Accélération sur l'axe x corrigée de Gx	$m.s^{-2}$ (mètre par seconde au carré)
y	Accélération sur l'axe y corrigée de Gy	$m.s^{-2}$ (mètre par seconde au carré)
z	Accélération sur l'axe z corrigée de Gz	$m.s^{-2}$ (mètre par seconde au carré)

GeoLife. Microsoft GeoLife [Zheng et al., 2009] est un jeu de données créé par Microsoft Research Asia collecté par 182 utilisateurs sur une période de 3 ans comprise entre avril 2007 et août 2012. Il contient un semble de 17621 trajectoires GPS représentées par une séquence de points horodatés, chacun contenant les informations de latitude, de longitude, d'altitude et un mode de transport associé. Ces trajectoires ont été enregistrées par différents enregistreurs GPS et téléphones GPS, et ont des taux d'échantillonnage variés. 91 % des trajectoires sont enregistrées dans une représentation dense, par exemple toutes les 1 à 5 secondes ou tous les 5 à 10 mètres par point. Après un premier filtrage pour ne retenir que les modes qui nous intéressent, nous obtenons 5.15 millions de points d'observations. Le mode still (absence de déplacement) n'est pas présent dans le jeu de données. Le jeu de données ne contenant pas d'information de vitesse, les attributs *location_speed* et *location_heading* (voir Table 3.7) sont estimés et les valeurs aberrantes sont filtrées (vitesse >400km/h). Le jeu de données utilisé contient 4.7 millions de points d'observation. La répartition des modes de transports est illustrée dans la Sigure 3.10.

US-TMD. US-Transportation Mode (US-TMD) [Carpineti et al., 2018] est un jeu de données collecté par l'Université de Bologne en 2017 à l'aide d'une application mobile de traçage utilisée par 13 volontaires. Chaque utilisateur a lancé plusieurs acquisitions correspondant à certains de ses déplacements. Les points collectés sont ensuite labélisés par l'utilisateur avec le mode de transport correspondant (absence de déplacement, marche, voiture, bus ou train). Le dataset contient des mesures acquises par différents capteurs du téléphone. Seules les données issues de l'accéléromètre sont utilisées, le dataset ne contenant pas de donnée GPS. Cela représente 1,4 million de points. La répartition des modes de transports est illustrée dans la Figure 3.11.

Pré-traitement et calcul des features. En plus des attributs des points de localisation et d'accéléromètre décrit précédemment, 4 attributs supplémentaires sont calculés : l'écart temporel et la distance entre les deux derniers points de localisation et la distance entre les deux magnitudes de l'accéléromètre (voir Table 3.7). Notre hypothèse (que l'on souhaite vérifier

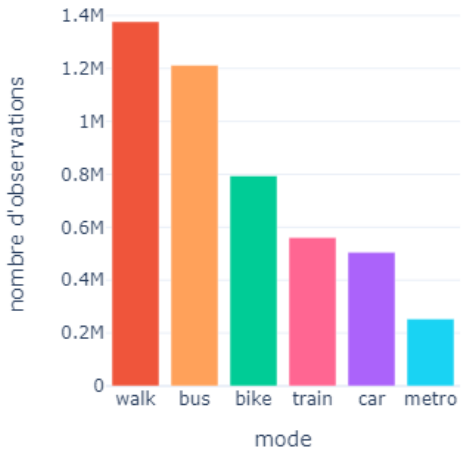


FIGURE 3.10 – Diagramme en barres du nombre de points par mode de transport dans le jeu de données GeoLife à l'issue du pré-traitement [Fourez, 2024].

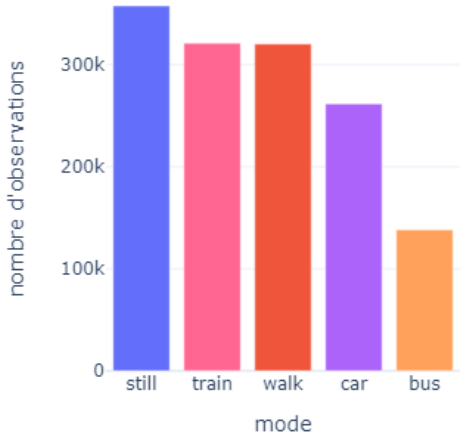


FIGURE 3.11 – Histogramme du nombre de points retenus par mode de transport dans le détaché US-TMD [Fourez, 2024].

dans notre expérimentation) est que l'ajout de ces attributs aide à améliorer la classification des modes en fournissant une information portant sur la vitesse d'acquisition des points.

TABLE 3.7 – Attributs additionnels calculés sur les points de localisation (2 premières lignes) et sur les points d'accéléromètre (2 dernières lignes).

Attribut	**Description**	**Unité**
location_time_delta	Écart temporel avec le point précédent	s (secondes)
location_distance_delta	Distance (à vol d'oiseau) au point précédent	m (mètres)
accelerometer_time_delta	Écart temporel avec le point précédent	s (secondes)
accelerometer_magnitude	Magnitude de l'accéléromètre	$m.s^{-2}$

À partir des points de localisation, des points d'accéléromètres et des attributs additionnels, nous avons extrait un ensemble de données statistiques pour construire l'espace des attributs de notre problème de classification. Le calcul de ces données repose sur l'utilisation d'une fenêtre temporelle (fixée à $60s$). Pour chaque fenêtre de $60s$, les données calculées sont les cinq indicateurs statistiques `min` (minimum), `max` (maximum), `mean` (moyenne), `median` (médiane) et `std` (écart-type) calculés sur quatre attributs de localisation de base (`speed` (vitesse), `speedAccuracy` (précision de la vitesse), `locationAccuracy` (précision de la localisation) et `heading` (direction)) et les 4 attributs additionnels décrits précédemment. Au total, **40 features** sont calculées pour chaque point d'observation.

Afin de gérer les données manquantes, un remplissage arrière (*backward fill*) est réalisé, c'est-à-dire que pour chaque attribut manquant la première valeur trouvée dans les points suivants est propagée.

Apprentissage. On souhaite comparer les résultats de quatre classifieurs utilisés pour la résolution du problème de classification du mode de transport :

- **KNN** : k plus proches voisins
- **RF** : Forêt aléatoire
- **ANN** : Réseau de neurones artificiels
- **SVM** : Machine à vecteur support

Les implémentations utilisées proviennent de la librairie python *scikit-learn* [Pedregosa et al., 2012].

Pour chaque jeu de données, les paramètres de chaque classifieur sont choisis par validation croisée à 5 blocs à partir d'une grille de paramètres (*grid search*) selon la Table 3.8.

L'entraînement s'effectue sur 80% de données choisies aléatoirement, et l'évaluation sur 20% des données restantes.

Discussion des résultats

TABLE 3.8 – Grilles de valeurs pour l'optimisation des paramètres par validation croisée. Les autres paramètres gardent leurs valeurs par défaut dans l'implémentation de *scikit-learn*.

Paramètre	**Grille de valeurs**		
	KNN		
`n_neighbors`	5	10	15
`weights`	uniform	distance	
	RF		
`n_estimators`	100	200	300
	ANN		
`hidden_layer_sizes`	100	200	500
`alpha`	1e-4	1e-3	1e-2
`learning_rate_init`	1e-3	1e-2	
	SVM		
`kernel`	rbf	poly	
`C`	1	50	100

OCC-TMD. Sur le jeu de données OCC-TMD, on a souhaité évaluer les performances des algorithmes dans quatre situations : D_{full} contient l'ensemble des 40 *features*, $D_{location}$ ne contient que 30 *features* issues des informations de localisation, $D'_{location}$ contient 20 *features* ne retenant que les données de localisation sans les informations de précision sur la position et la vitesse, et enfin $D_{accelerometer}$ qui ne retient que les 10 *features* concernant l'accéléromètre. La Table 3.9 présente la liste des *features* dans chacun des jeux de donnée.

TABLE 3.9 – Sous-ensembles de features des différentes variantes du dataset. 5 features sont calculées à partir de chaque attribut (moyenne, minimum, maximum, écart-type et médiane).

Attribut	D_{full}	D_{location}	D'_{location}	$D_{\text{accelerometer}}$
location_accuracy	✓	✓		
location_speed	✓	✓	✓	
location_speed_accuracy	✓	✓		
location_heading	✓	✓	✓	
location_distance_delta	✓	✓	✓	
location_time_delta	✓	✓	✓	
accelerometer_magnitude	✓			✓
accelerometer_time_delta	✓			✓
Nombre de features	**40**	**30**	**20**	**10**

La création de ces quatre variations du jeu de données permet d'étudier l'impact de chacune des features sur les performances des algorithmes. La Table 3.10 présente la précision de

classification obtenue par les quatre algorithmes.

TABLE 3.10 – Comparaison des précisions de classification sur les quatre jeux de données.

	D_{full}	D_{location}	D'_{location}	$D_{\text{accelerometer}}$
RF	**99.57%**	**97.06%**	**97.02%**	**98.65%**
SVM	96.57%	94.36%	88.91%	74.49%
ANN	98.14%	95.24%	90.41%	85.33%
KNN	99.01%	96.44%	96.41%	94.79%

Le classifieur **RF** obtient la meilleure précision. On observe que la meilleure performance (99.57%) est obtenue sur le jeu de donnée complet (D_{full}). Pour chacun des classifieurs, la meilleure performance est aussi obtenue avec le jeu de données complet.

La Figure 3.12 présente la mesure d'impureté de Gini calculée lors de l'apprentissage de l'instance **RF** ayant donné la meilleure précision. Cette mesure permet d'estimer la capacité de chacune des *features* d'entrée à discriminer les classes, et fournit donc une mesure d'importance relative. On observe que la *feature* la plus importante est `std_location_distance_delta`, c'est-à-dire l'écart-type de la distance entre deux points de localisation successifs. Sur l'ensemble des *features*, celles issues des écarts temporels ont une importance moyenne plus élevée que les autres (0.0296 contre 0.0235). Les *features* issues de l'accéléromètre ont une importance moyenne légèrement supérieure à celle des autres (0.0258 contre 0.0247), ce qui explique les performances plus élevées du classifieur Random Forest sur le sous-ensemble $D_{\text{accelerometer}}$.

Les deux *features* suivantes dans l'ordre d'importance sont issues des attributs d'écarts temporels dans les *features* d'accéléromètre et de localisation. Afin de visualiser la capacité de discrimination de ces deux *features*, leurs distributions pour chaque mode sont présentées dans la Figure 3.13 sous forme de boîte de Tukey. Il apparaît que les écarts temporels dans les *features* d'accéléromètre permettent de discriminer facilement les modes *train* et *bus*, tandis que ceux issus des *features* de localisation permettent de séparer les modes *train*, *metro* et *still* des autres modes de manière significative. Cela s'explique par la différence de fréquence d'observation pour ces modes en particulier, en raison des règles d'acquisition du jeu de données pour les modes *still* (fréquence très faible) et *bus* (fréquence très élevée), et de la perte de signal GNSS pour les modes *metro* et *train*.

Microsoft GeoLife. Similairement, on découpe le jeu de données GeoLife en quatre sous jeux de données : $D^{test}_{geolife}$ qui contient un sous-ensemble de 40000 points utilisés pour l'apprentissage, $D_{geolife}$ qui contient l'ensemble des points, et enfin, $D'^{test}_{geolife}$ et $D'_{geolife}$ qui sont privés des attributs différentiels (*location_time_delta* et *location_distance_delta*) afin d'étudier l'influence de l'ajout de ces nouvelles features sur la classification. Le tableau 3.11 présente les résultats obtenus par les quatre algorithmes. Random Forest obtient le meilleur score sur le jeu d'entraînement, mais ANN obtient le meilleur score sur le jeu de donnée complet. On y observe aussi une amélioration des performances de classification dans les jeux

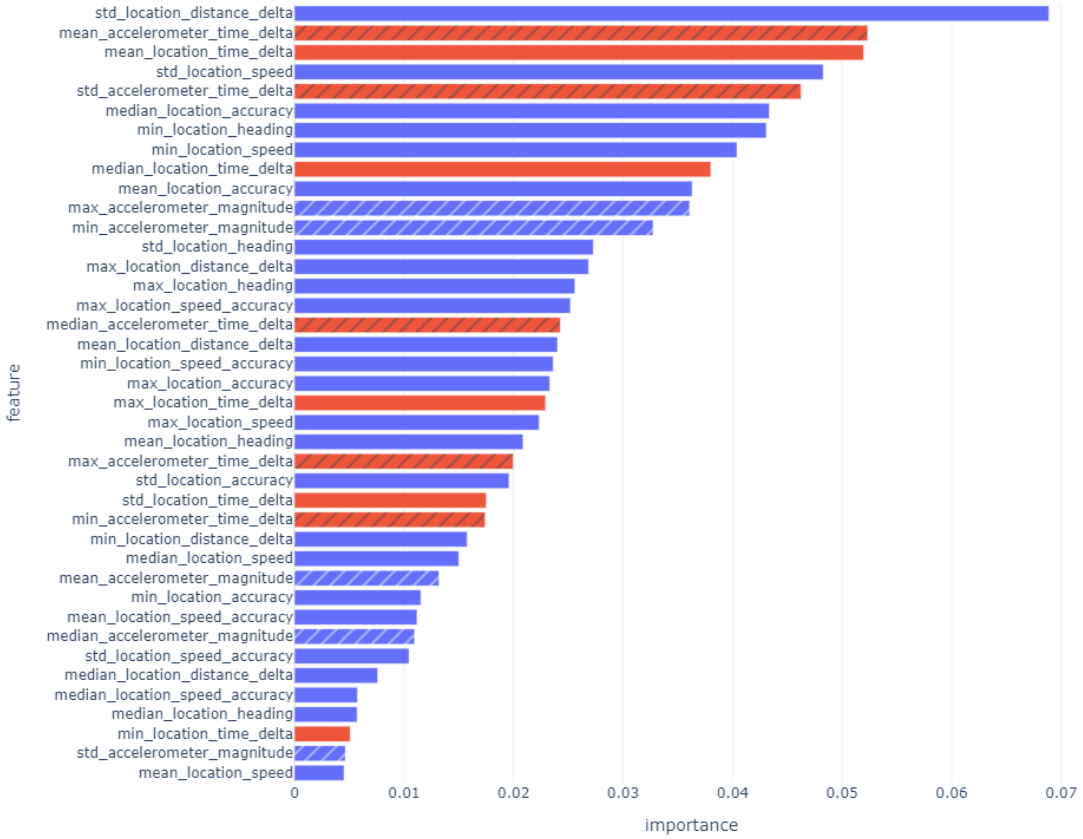


FIGURE 3.12 – Importances de Gini pour le classifieur Random Forest entraîné avec la meilleure combinaison de paramètres (sélectionnée par validation croisée). Les features d'écarts temporels sont représentées en rouge. Les features issues des données d'accéléromètre sont représentées hachurées [Fourez, 2024].

de données incluant les données d'écart temporels. Les performances des sous-échantillons de tests sont légèrement plus élevées que sur les jeux de données complets.

US-TMD. Les résultats obtenus avec le jeu de données US-TMD sont similaires à ceux de Microsoft GeloLife (voir table 3.12). L'intégration des écarts temporels ici aussi améliore les performances de classification. En comparant les résultats à ceux issus de la littérature ([Carpineti et al., 2018, Vakili et al., 2020]), on observe que l'intégration des écarts temporels améliore grandement les résultats de classification (de l'ordre de 10%), confirmant ainsi l'apport de notre approche.

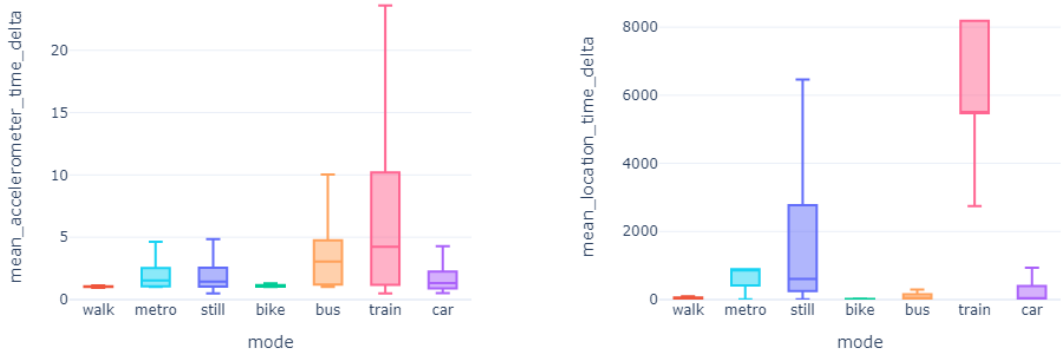


FIGURE 3.13 – Distribution des features `mean_accelerometer_time_delta` (gauche) et `mean_location_time_delta` (droite) en fonction du mode de transport. Les données sont représentées sous forme de diagramme en boite sans les outliers [Fourez, 2024].

TABLE 3.11 – Comparaison des précisions de classification sur les différents sous-ensembles du dataset GeoLife. Les précisions des jeux de données complets D_{geolife} et D'_{geolife} sont obtenues respectivement avec les modèles entraînés sur les sous-ensembles $D^{\text{test}}_{\text{geolife}}$ et $D'^{\text{test}}_{\text{geolife}}$.

	$D^{\text{test}}_{\text{geolife}}$	D_{geolife}	$D'^{\text{test}}_{\text{geolife}}$	D'_{geolife}
RF	**77.39%**	70.42%	**73.08%**	**71.66%**
SVM	71.49%	69.87%	71.19%	69.81%
ANN	73.43%	**71.83%**	71.23%	70.14%
KNN	70.15%	68.87%	69.74%	68.78%

3.3.3 Synthèse

Dans cette section, nous avons présenté et appliqué une chaîne de traitement de données pour la classification du mode de transport. Une première contribution porte sur l'ingénierie des features en proposant d'ajouter les écarts temporels entre les points comme variable explicative. Les résultats sur les jeux de données issus de la littérature montrent une amélioration des performances de classification. Nous avons proposé différentes variations des jeux de données pour évaluer l'importance de ces nouvelles variables dans le processus de classification. Une première approche a consisté à entraîner et comparer les modèles sur des sous-parties du jeu de données. Ainsi, on a pu observer une dégradation des performances lorsque l'on retire les données temporelles du dataset. Dans un second temps, une analyse d'importance de gini sur le classifieur Random Forest (qui a obtenu les meilleures performances de classification) permet de mettre en avant l'importance relative des données d'écart temporel. Ce travail, qui

TABLE 3.12 – Comparaison des précisions de classification sur les différents sous-ensembles du jeu de données US-TMD avec les précisions obtenues dans [Carpineti et al., 2018] et [Vakili et al., 2020] sur le jeu de donnée complet. Les précisions des datasets complets D_{ustmd} et D'_{ustmd} sont obtenues respectivement avec les modèles entraînés sur les sous-ensembles $D^{\text{test}}_{\text{ustmd}}$ et $D'^{\text{test}}_{\text{ustmd}}$.

	$D^{\text{test}}_{\text{ustmd}}$	D_{ustmd}	$D'^{\text{test}}_{\text{ustmd}}$	D'_{ustmd}	[Carpineti et al., 2018]	[Vakili et al., 2020]
RF	**99.39%**	96.82%	**98.46%**	96.88%	**89.00%**	**85.00%**
SVM	91.70%	91.25%	80.89%	81.56%	86.00%	79.00%
ANN	95.74%	95.04%	91.76%	91.81%	87.00%	75.00%
KNN	98.64%	**98.61%**	98.15%	**97.92%**		80.00%

s'inscrit dans le cadre d'un partenariat industriel, a permet d'établir un ensemble de recommandations sur la conception d'une plateforme d'analyse de la mobilité, dont un prototype a été déployé et évalué [Fourez, 2024].

3.4 Conclusion et perspectives

Ce chapitre présente mes contributions à l'apprentissage artificiel pour des tâches d'apprentissage supervisé et détaille deux contributions de natures différentes :

- Un modèle d'apprentissage ensembliste coopératif où l'apprentissage est issu de l'auto-organisation d'un ensemble d'agents contextes. Une formalisation du modèle est proposée et ses performances sont évaluées sur des problèmes jouets. Une étude permet de proposer de nouvelles métriques d'explicabilité permettant de lier la structure de l'organisation des agents et la dynamique de la fonction sous-jacente.
- Une application d'une chaîne de traitements appliquée au problème de la classification du mode de transport, qui exploite les écarts temporels entre les points d'observations pour améliorer les performances de classification.

Ces deux travaux sont originaux quant à la construction de modèles par l'apprentissage artificiel. Les résultats permettent de dresser un ensemble de limitations et de perspectives de recherche :

- **De la donnée utilisateur aux modèles.** Nos travaux sur la classification des modes de transport permettent d'adresser un des 5 axes de questionnement présenté dans ce chapitre : "Comment se déplacent les usagers ?". L'étape suivante est de s'intéresser à la question du "pourquoi ?", c'est-à-dire d'identifier dans les traces des utilisateurs des éléments caractéristiques des motifs de déplacement. Des pistes d'extension de ces tracaux ont été dégagées dans la thèse de Thibault Fourez [Fourez, 2024]. Elles portent sur l'intégration de nouvelles features portant sur l'environnement du déplacement en exploitant les informations des points d'intérêts des sources de données tels qu'OpenStreetMap et Yelp. Ainsi, il est possible de caractériser, pour les points d'origine et de

destination du déplacement, les probabilités de distance et de disponibilité associées à chacun des motifs possibles de déplacement (loisir, travail, restauration...). Dans un contexte plus général, les travaux ouvrent donc des poursuites dans la construction automatique de modèles à partir de traces d'utilisateurs.

— **Développer et évaluer l'apprentissage coopératif ensembliste.** Les résultats obtenus par l'apprentissage coopératif ensembliste sont intéressants : les modèles parviennent à obtenir des performances satisfaisantes tout en offrant de nouvelles propriétés grâce à l'analyse de l'organisation des agents contextes. Ainsi deux perspectives pour ces travaux sont envisagés. La première porte sur la diffusion et l'analyse comparative des performances du modèle. Les développements successifs des modèles à base d'agent contexte ont permis d'aboutir à une structure qui offre des perspectives intéressantes en termes d'optimisation du temps de calcul. Ainsi, nous travaillons actuellement à une des opérations de sélection et de mise à jour des agents contextes en exploitant l'algèbre des tenseurs, pour permettre d'accélérer les opérations grâce aux GPU. L'objectif est de fournir une implémentation open source de l'algorithme (https ://github.com/nverstaevel/ciel) et de benchmarker ses performances sur des jeux de données de classification et de régression. Une validation applicative dans les domaines du contrôle et de la détection des anomalies sont en cours au travers de deux thèses CIFRE (cf Chapitre 5), ce qui permettra de ne pas limiter les résultats aux modèles jouets.

— **Explicabilité.** L'explicabilité est une approche issue de l'apprentissage machine qui étudie les décisions prises par un modèle boîte noire [Štrumbelj and Kononenko, 2014]. Les travaux présentés dans ce chapitre apportent des contributions au domaine de l'explicabilité. Dans le cas des agents contextes, de nouvelles métriques d'organisation permettent d'extraire de l'information à partir de la structure des agents contextes. L'hypothèse est que des changements dans cette structure peuvent être informatifs de la nature de la fonction sous-jacente. Dans des travaux en cours, nous explorons l'utilisation de ces informations dans des processus d'optimisation (voir Chapitre 5). Dans le cas des travaux sur la classification du mode, l'étude des importances de Gini a permis d'évaluer l'impact des variables temporelles que nous avons ajoutées. Ces deux résultats permettent d'alimenter une nouvelle question de recherche que je propose en conclusion du manuscrit, à savoir l'usage de métriques d'explicabilité lors du cycle d'apprentissage à l'inverse de SHAPE et LIME qui sont deux approches couramment utilisées pour permettre l'explicabilité de boîtes noires après l'apprentissage [Salih et al., 2025].

Dans ce chapitre, j'ai positionné mes travaux de recherche dans le contexte de l'apprentissage supervisé de modèles. Une application à la classification des modes de transports illustre que le contexte urbain est propice au développement et à l'évaluation de nouveaux algorithmes d'apprentissage. Dans le Chapitre 4, je présente des travaux liés à la simulation de systèmes urbains, principalement par la modélisation de foules denses. Dans le Chapitre 5, je détaille mon projet de recherche original qui fait le lien entre ces trois problématiques : la collecte de

données, la construction de modèles, et la simulation.

Chapitre 4

Simulation et Prédiction dans des Foules Denses

Contents

4.1 Introduction 88
4.2 Simulation à base d'agents de phénomènes urbains 88
4.2.1 La simulation à base d'agents 88
4.2.2 La modélisation multi-échelles et le couplage de modèles 90
4.2.3 La simulation de foules 92
4.3 Contributions à la simulation de foules denses 94
4.3.1 Cas d'étude : la Fête des Lumières à Lyon 94
4.3.2 Couplage de modèles mesoscopique et microscopique pour la simulation de foules : application à la fête des lumières 97
4.3.3 Prédiction de trajectoires de piétons en foules denses 113
4.4 Conclusion et perspectives 123

4.1 Introduction

DANS le chapitre 2, de nouvelles techniques permettant l'acquisition de données urbaines à larges échelles temporelles et spatiales ont été présentées. Dans le chapitre 3, des contributions à l'apprentissage de modèles, notamment à partir de traces de mobilités, ont été détaillées. Ce nouveau chapitre décrit mes contributions au domaine de la simulation et notamment à la modélisation de foules denses. Les travaux sont positionnés dans deux domaines : celui de la modélisation à base d'agents avec des contributions en terme de génie logiciel pour aborder des problématiques de couplage de modèles, et celui de la prédiction de trajectoires de piétons qui repose sur l'utilisation de réseaux de neurones profonds. Dans la Section 4.3.2, un modèle de simulation calibré à partir de données acquises à partir de flux vidéo est présenté. La Section 4.3.3 présente une extension d'un modèle de réseaux de neurones pour la prédiction de la trajectoire de piétons. En ce sens, ce chapitre crée un lien orignal entre les chapitres 2 et 3 en proposant un cadre d'outils et de méthodes pour la construction et l'exploration de simulations dirigée par la données. Les contributions s'appuient sur la collecte de nouvelles données pour la calibration des simulations agents et sur l'utilisation de l'apprentissage machine. Les travaux ont été réalisés dans le cadre de la thèse de Dang Huu-Tu (soutenue le 16/01/2025) au sein du projet ANR-DFG-MADRAS (https://anr.fr/Projet-ANR-20-CE92-0033). Les travaux présentés dans ce chapitre font références aux publications : [Erdelyi et al., 2021b], [Dang et al., 2023c], [Dang et al., 2022b], [Dang et al., 2023a], [Dang et al., 2024a], [Korbmacher et al., 2022a], [Korbmacher et al., 2023], [Chraibi et al., 2023], [Dufour et al., 2024], [Dang et al., 2022a], [Korbmacher et al., 2024], [Korbmacher et al., 2022d], [Dang et al., 2024b], [Dang et al., 2022c], [Dang et al., 2023b], [Dang et al., 2024e], [Korbmacher et al., 2022c]

4.2 Simulation à base d'agents de phénomènes urbains : contexte des travaux

4.2.1 La simulation à base d'agents

La simulation à base d'agents est un paradigme informatique ancré dans les principes des systèmes multi-agents et de la modélisation informatique qui propose d'aborder la modélisation de systèmes complexes en s'intéressant aux interactions entre un ensemble d'agents et un environnement, dans le but d'étudier et comprendre les dynamiques de ces systèmes [Bandini et al., 2009]. Un agent peut représenter des individus, des organisations ou même des entités logicielles, et est caractérisé par sa capacité à prendre des décisions, à s'adap-

Cette section s'appuie sur l'article: Erdelyi, J. F., Amblard, F., Gaudou, B., Kaddoum, E., & N. Verstaevel. **Exploration of model coupling strategies in a hybrid agent-based traffic simulation**. *International Workshop on Multi-Agent Systems and Agent-Based Simulation (pp. 153-167). Cham : Springer International Publishing.* 2021.

Cette section s'appuie sur l'article: Dang, H. T., Gaudou, B., & Nicolas Verstaevel. **A literature review of dense crowd simulation**. *Simulation Modelling Practice and Theory, 102955.* 2024.

ter à son environnement et à interagir avec les autres sur la base de règles prédéfinies [Russell and Norvig, 1995]. L'environnement peut être vu comme l'ensemble des éléments externes à un agent qui influencent son comportement et sur lequel l'agent peut agir. Ces éléments incluent des objets physiques, des agents voisins, des ressources disponibles et des lois ou règles qui régissent les interactions [Railsback and Grimm, 2019]. Cette définition large d'agent et d'environnement permet d'appliquer le paradigme dans un large panel d'applications. La simulation à base d'agents s'est développée dans les domaines du transport, de l'énergie, de la diffusion des technologies [Mehdizadeh et al., 2022] ou afin d'analyser la mobilité en tant que phénomène émergent complexe [Divasson-J et al., 2025]. Cette diversification des usages s'appuie aussi sur une diversification des environnements technologiques supports à la simulation, et la multiplication des plateformes telles que SUMO [Lopez et al., 2018], MATsim [W Axhausen et al., 2016] ou GAMA [Taillandier et al., 2019].

Les plateformes telles que GAMA (GIS Agent-based Modeling Architecture) permettent d'intégrer les données SIG (Systèmes d'Information Géographique) dans les modèles. Ce type d'outil ouvre de nouvelles possibilités pour explorer l'impact des politiques publiques [Duc et al., 2020], anticiper les dynamiques territoriales [Gaudou et al., 2014] ou simuler des scénarios de résilience face aux catastrophes naturelles [Daudé et al., 2019]. Par conséquent, GAMA et des plateformes similaires renforcent considérablement la capacité des chercheurs à modéliser des systèmes complexes en intégrant des données du monde réel.

https://gama-platform.org/

Mes travaux: *Simulation à bases d'agents*

Les travaux présentés dans ce chapitre sont des contributions logicielles et méthodologiques à la simulation à base d'agents. Le domaine d'application principal est la ville et ses usagers. Ainsi, la simulation à base d'agents est le cadre permettant de modéliser et d'explorer les propriétés des systèmes socio-techniques urbains tout en abordant des problématiques liées au passage à l'échelle et au couplage de modèles. Dans le cadre des travaux de l'ANR-Switch [Erdelyi et al., 2021a], je me suis intéressé à la simulation de trafic routier, avec pour objectif d'aborder la problématique du passage à l'échelle, notamment grâce au couplage entre différents modèles [Erdelyi et al., 2021b]. Ces travaux, que je ne présente pas dans ce manuscrit, ont permis d'explorer les données disponibles pour simuler les déplacements quotidiens au sein de métropoles. Dans d'autres travaux non présentés dans ce manuscrit, j'ai exploré l'apport de l'affordance dans la simulation agent pour contraindre l'émergence de comportements [Doussin et al., 2022], et celui de l'optimisation sous contrainte pour la calibration de simulations [Vergnet et al., 2021], notamment par des stratégies de coopération pour éviter les optimums locaux [Vergnet et al., 2022]. Dans ce chapitre, je présente les travaux dans le cadre de l'ANR-DFG MADRAS où je me suis plus spécifiquement intéressé à la problématique de la simulation de foules denses [Chraibi et al., 2023], avec des contributions à la fois en terme d'hybridation de modèles [Dang et al., 2023b] et de prédiction de trajectoires [Dang et al., 2023c]. Ces travaux explorent la relation entre modèle, apprentissage artificiel et analyse de sensibilité. Sur le plan de l'animation scientifique, j'ai organisé l'édition 2022 du 26ème workshop MABS (International Workshop on Multi-Agent-Based Simulation) [Van Dam and Verstaevel, 2022] et organisé et participé aux GAMADAys, journées d'échanges de la communauté GAMA.

4.2.2 La modélisation multi-échelles et le couplage de modèles

L'application de la simulation à base d'agents aux espaces urbains pose de nouveaux défis en termes de passage à l'échelle, en raison de la complexité inhérente aux dynamiques spatiales et temporelles [Huang et al., 2022]. En milieu urbain, la modélisation implique souvent un grand nombre d'agents, tels que des habitants, des véhicules ou des infrastructures, interagissant dans des environnements denses et interconnectés. À cela s'ajoute la nécessité de capturer des phénomènes à des échelles multiples — des comportements individuels (micro) aux dynamiques de quartier (méso) et aux flux à l'échelle métropolitaine (macro) [Railsback and Grimm, 2019]. Ces exigences rendent les simulations particulièrement coûteuses en temps de calcul, car elles doivent traiter des données volumineuses, comme les réseaux routiers détaillés ou les horaires des transports en commun en temps réel, tout en modélisant des interactions dynamiques sur des périodes étendues. L'intégration de données géospatiales précises et les besoins en recalcul pour refléter l'évolution des contextes urbains accentuent encore la complexité des modèles. Par conséquent, le défi du passage à l'échelle reste un problème ouvert pour la communauté.

La modélisation multi-niveaux et le couplage de modèles émergent comme approche prometteuse pour relever les défis liés au passage à l'échelle dans les simulations à base d'agents [Dinaharison, 2023]. Historiquement, de nombreux modèles se sont intéressés à un niveau de modélisation spécifique :

1. **Microscopique** : À cette échelle, les modèles décrivent individuellement les agents (véhicules, piétons, etc.) et leurs interactions. Ils sont considérés comme les plus précis et les plus réalistes. Cependant, cette représentation présente certaines limites notamment lors du passage à l'échelle : le coût de calcul évolue en effet rapidement avec le nombre d'individus [Taplin, 1999, Tchappi Haman et al., 2017]. Ces modèles sont également difficiles à calibrer en raison de leur grand nombre de paramètres. Aussi, ils sont enclins à travailler sur de petites échelles spatiales (ie. à l'échelle d'une intersection, un bâtiment) et temporelles (quelques minutes à quelques heures).

2. **Macroscopiques** [Wang et al., 2022] : Cette échelle de simulation désigne un niveau d'analyse où l'on modélise et simule des phénomènes à grande échelle, en prenant en compte les comportements globaux plutôt que les détails au niveau microscopique. Les agents sont souvent agrégés au sein d'une entité sous la forme de flux et leur comportement observé au travers de variables caractéristiques. Par exemple pour la simulation de trafic, on peut assimiler le trafic sur un axe routier à un flux de fluides décrit en fonction de la vitesse, de la densité et du débit. Cette agrégation permet de travailler sur de larges échelles spatiales et temporelles.

3. **Mesoscopique** [Navarro et al., 2013] : Cette échelle propose une représentation intermédiaire entre les modèles microscopiques et macroscopiques. Contrairement au niveau macroscopique dans lequel tous les agents sont regroupés en une seule entité, l'échelle mésoscopique propose d'agréger des sous-ensembles d'agent dans l'objectif de libérer des ressources de calcul tout en conservant les caractéristiques individuelles des agents.

Chacune de ces approches de modélisation a donc ses spécificités : les modèles macroscopiques sont particulièrement pertinents pour les simulations à grande échelle (par exemple à l'échelle d'une métropole), tandis que les modèles microscopiques peuvent être appliqués pour représenter avec précision le trafic dans un petit quartier [Erdelyi et al., 2021b].

Le couplage de modèles, qui consiste à relier différentes échelles de modélisation (par exemple, micro et macro), apparaît alors comme une solution pour capturer les dynamiques multi-échelles complexes, particulièrement pertinentes en contexte urbain [Marilleau et al., 2018]. Toutefois, cette approche introduit des défis techniques, notamment la synchronisation des échelles temporelles et la gestion des données entre les modèles, qui nécessitent des solutions méthodologiques pour assurer la fiabilité du couplage.

Mes travaux: *Simulation à la modélisation multi-niveaux et le couplage de modèles*

L'existence de différents modèles dans la littérature scientifique pose la question de leurs réutilisations dans des contextes variés. Dans les travaux de [Erdelyi et al., 2021b], nous nous sommes posés la question de l'échelle de simulation dans le cadre de simulations de mobilité. Nous avons couplé un modèle microscopique (IDM [Treiber et al., 2000]) avec un modèle mesoscopique (FIFO basé sur BPR [Charypar et al., 2007]) pour démontrer qu'une stratégie d'hybridation permet de trouver un équilibre entre réalisme de la simulation et temps de calcul. Dans les travaux de la thèse de Dang Huu-Tu [Dang et al., 2023b] présentés dans ce chapitre, nous avons exploré l'apport du couplage de modèles à la simulation de foules denses. Il existe dans la littératures des modèles microscopiques propices aux foules de faible densité et des modèles mesoscopiques pour les foules denses [Dang et al., 2024e]. Dans notre approche, le couplage de modèles permet l'ajustement dynamique du modèle de contrôle d'un piéton en fonction de l'espace et de la densité. Dans les deux cas, la solution passe par la construction de fonctions de transition permettant l'échange d'informations entre les modèles pour assurer leur couplage.

4.2.3 La simulation de foules

La simulation de piétons est un domaine de recherche qui vise à comprendre et prédire le comportement collectif des individus dans divers contextes, tels que les environnements urbains, les événements de masse ou les évacuations d'urgence. Elle repose sur des modèles mathématiques et informatiques visant à reproduire les mouvements et interactions des piétons, tout en prenant en compte des facteurs tels que les caractéristiques des individus et l'influence de l'environnement. Ces approches incluent des modèles à base d'agents, où chaque piéton est représenté comme une entité autonome dotée de règles comportementales spécifiques [Chen et al., 2018], ainsi que des modèles dirigés par la donnée [Zhong et al., 2022]. [Hoogendoorn and Bovy, 2004] décrivent le comportement des piétons comme l'application d'un comportement à trois niveaux :

- Le niveau **stratégique** correspond au choix de la cible à atteindre ou de l'activité à réaliser.
- Le niveau **tactique** porte sur la planification du chemin que les piétons planifient vont prendre pour atteindre leur destination en se basant sur les informations de l'environnement.
- Le niveau **opérationnel** permet aux piétons d'exécuter le trajet en ajustant leur mouvement pour éviter les collisions et s'adapter à leur environnement.

Dans le cadre de la thèse de Dang Huu-Tu nous avons réalisé une revue de la littérature des différents modèles de simulation de foules en nous intéressant plus spécifiquement aux foules à forte densité [Dang et al., 2024e]. Celle-ci a permis d'identifier l'existence de plusieurs modèles au niveau opérationnel permettant de contrôler le déplacement des piétons,

chacun de ces modèles étant conçu pour simuler et reproduire des phénomènes spécifiques. [Dang et al., 2024e] propose une classification des approches en 3 catégories (voir figure 4.1).

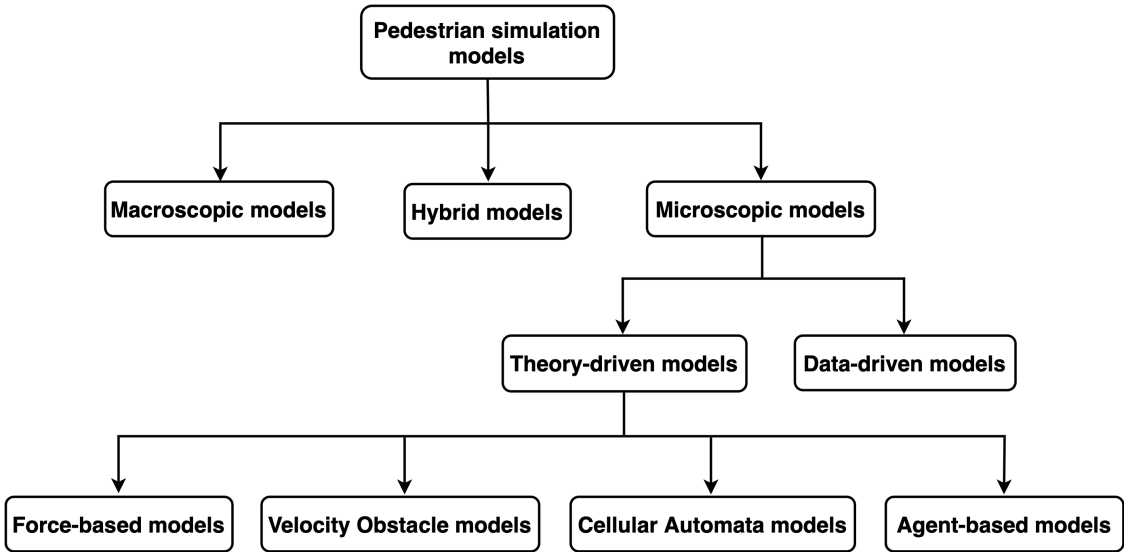


FIGURE 4.1 – Classification des différents modèles opérationnel [Dang et al., 2024e]

Ce travail d'état de l'art a mis en évidence deux axes de recherche : premièrement, dans le domaine de l'ingénierie dirigée par les modèles, le couplage des modèles opérationnels des piétons pour améliorer le passage à l'échelle des simulations de piétons dans des environnements à densité variable ; deuxièmement, dans le domaine de l'ingénierie dirigée par la donnée, l'utilisation de techniques d'apprentissage profond en intégrant des métriques liés aux collisions dans la fonction de fitness pour améliorer la capacité des modèles à produire des comportements d'évitements de collision. Ces axes combinent la modularité et l'interopérabilité des modèles avec des données terrain de foules denses pour répondre aux enjeux de réalisme et de passage à l'échelle.

Mes travaux: *Simulation de foules denses*

La simulation de foules représente un cadre applicatif intéressant pour simuler des comportements complexes dans des environnements urbains. Les travaux de la thèse Tu [Dang, 2025] ont apporté une contribution à l'état de l'art en effectuant une revue classifiant les différents modèles de simulations et leur applicabilité à des scénarios de forte densité. Les contributions présentées dans ce chapitre portent sur deux aspects. Dans un premier temps, une contribution au passage à l'échelle des simulations en permettant le couplage, via l'environnement, de modèles de simulation de granularités différentes. Cette première contribution permet d'associer à des sous-parties de l'environnement des modèles différents en fonction de la densité attendue [Dang et al., 2023b]. Une seconde contribution [Dang et al., 2023c] a consisté à améliorer les performances de SLSTM, un modèle d'apprentissage profond pour la prédiction de trajectoires, en travaillant à une meilleure prise en compte des collisions dans la fonction d'évaluation. Les deux contributions présentées dans la Section 4.3 ont le même cadre applicatif : celui de la Fête des Lumières à Lyon.

4.3 Contributions à la simulation de foules denses

La Section 4.3.1 présente le contexte de notre étude, ainsi que l'acquisition de données qui a été réalisée dans le cadre de l'ANR-DFG MADRAS. Les données collectées servent de support aux deux contributions présentées.

Dans un premier temps, la Section 4.3.2 présente et évalue une approche pour le couplage de modèles microscopiques et mescoscopiques dans le cadre de la simulation de foules denses. Cette approche est dirigée par les modèles, où chaque modèle est sélectionné puis calibré pour reproduire la dynamique des données terrain. L'originalité de l'approche repose sur la construction de zones dans l'espace urbain associé à des types de modèles différents. Cette association est directement liée à la densité des flux observés.

La Section 4.3.3 présente quant à elle une contribution à la modélisation dirigée par les données en présentant TTC-SLSTM, un nouvel outil de prédiction de trajectoires de piétons construit sur SLSTM. Ici, la contribution repose sur la prise en compte des collisions dans la fonction de fitness pour améliorer la qualité et le réalisme de la prédiction de trajectoires dans un contexte de foules denses.

4.3.1 Cas d'étude : la Fête des Lumières à Lyon

La "Fête des lumières" est un évènement initié en 1989 par la ville de Lyon autour du 8 décembre pendant quatre nuits. Initialement, la Fête des Lumières est un évènement qui s'inscrit dans la religion catholique. Ainsi, le soir du 8 décembre, des bougies sont allumées et placées dans les verres déposés sur le bord des fenêtres pour fêter l'Immaculée Conception.

https ://www.fetedeslumieres.lyon.fr



(a) Emplacement des installations. (b) Principaux flux de circulation sur la Place des Terreaux

FIGURE 4.2 – Organisation de la Fête des Lumières en 2022. [Dang, 2025]

L'évènement s'est par la suite transformé en fête populaire et aux bougies s'est ajouté un spectacle de son et lumière illuminant les principaux édifices historiques de la ville de Lyon.

En 2022, l'évènement a attiré approximativement 2 millions de visiteurs qui ont pu observer 30 installations lumineuses. La place des Terreaux (voir Figure 4.2) est l'une des principales attractions. Cette place de $7000m^2$ est l'une des plus bondées du festival accueillant jusqu'à 150000 personnes chaque nuit. La place est organisée pour permettre la circulation de la foule selon un flux unidirectionnel. Les piétons ne peuvent entrer sur la place que par une seule entrée (rue du Président Edouard Herriot) et sortir par trois accès : la rue d'Algérie, la rue Chenavard et la rue Constantine. Les autres accès sont contrôlés par des barrières de sécurité. Des agents de sécurité sont assignés à chaque entrée pour contrôler le nombre de personnes entrant sur la place pour s'assurer que celui-ci n'excède pas les deux tiers de la capacité d'accueil. Ils peuvent ainsi fermer les barrières d'accès le temps d'une représentation (environ 7 minutes) et réouvrir les accès pour permettre aux nouveaux spectateurs de rentrer après l'évacuation de la place. L'intégralité de la place n'est cependant pas évacuée, certains spectateurs pouvant choisir de rester sur la place pour revoir l'installation.

Pour ces raisons, la place des Terreaux représente un terrain d'étude intéressant pour la modélisation des foules : on peut y observer une foule se réunir, stationner pendant un évènement, puis procéder à une évacuation. L'évènement se répète plusieurs fois au cours d'une soirée, et se répète sur plusieurs jours. Ainsi, les équipes de l'ANR-DFG MADRAS ont pu réaliser une série d'acquisitions vidéos du 8 décembre au 10 décembre 2022 pour observer les dynamiques de cet évènement. La Figure 4.3 montre l'emplacement d'installation des caméras ainsi que leurs points de vue : elles permettent l'observation des entrées et sorties de la place, ainsi que la densité de la place principale.

Les vidéos obtenues ont été analysées pour produire un jeu de données qualitatif sur la dynamique des foules lors de cet évènement, notamment par l'extraction de trajectoires individuelles. On retrouve dans la thèse de [Dang, 2025] la procédure d'extraction des données.

https://www.fetedeslumieres.lyon.fr/en/map/2022-map (accédée le 31 Mai 2024).

La Table 4.1 présente les données qui sont disponibles à l'url https://madras-data-app.streamlit.app via une plateforme développée pour leur exploration.

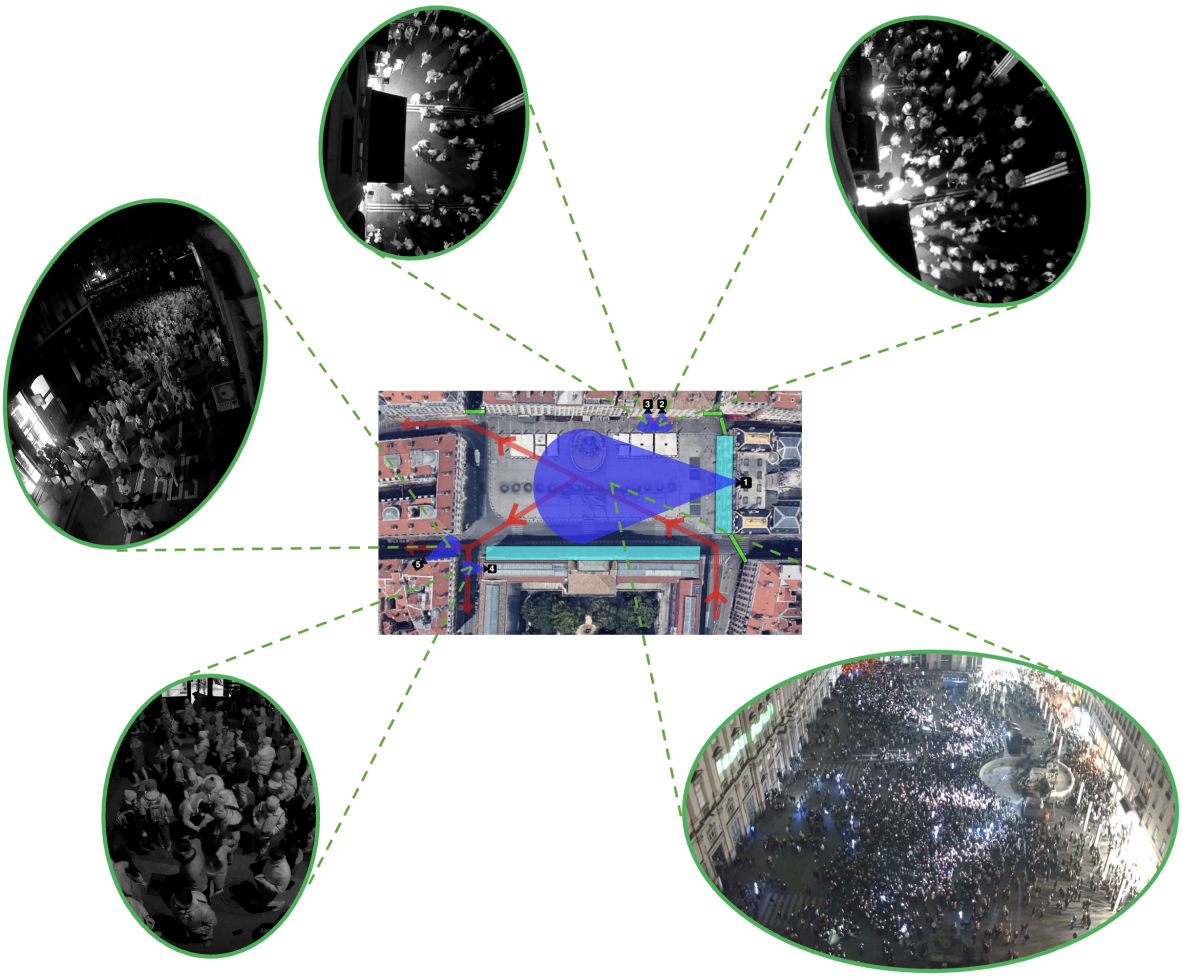


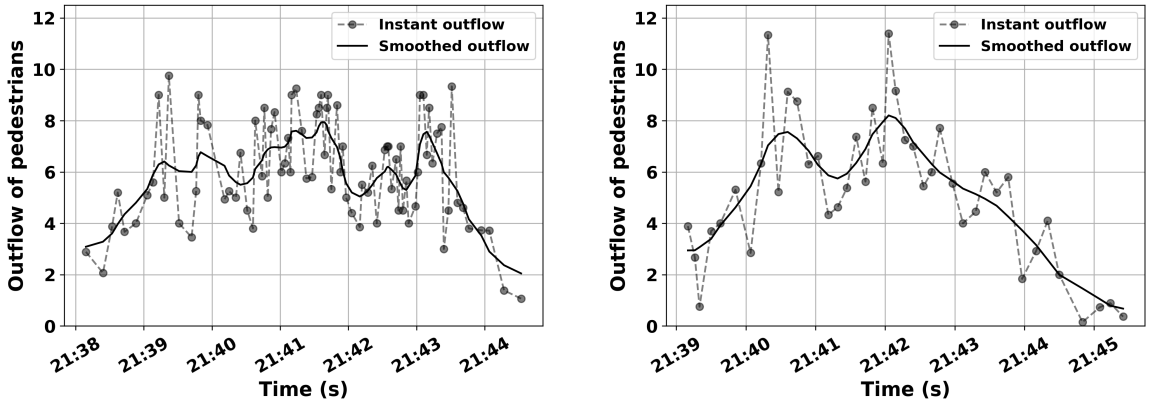
FIGURE 4.3 – Positionnement des caméras pour la captation [Dang, 2025].

La Figure 4.4 présente les flux de piétions (piétons/s) obtenus au cours d'une évacuation de la place des terreaux entre 21h38 et 21h45 pour les deux rues Chenavard et Constantine. Le flux de sortie est lissé à l'aide d'un filtre gaussien [Bishop and Nasrabadi, 2006].

Dans la section suivante, nous présentons HyPedSim, l'architecture que nous avons conçu et calibré pour reproduire cette dynamique.

File	**Start** [UTC+1]	**End** [UTC+1]	**Traj**	**Mean density** [ped/m^2]	**Max density** [ped/m^2]	**Mean speed** [m/s]	**Mean trajectory duration** [s]
TopView_1A	22 :40 :45	22 :44 :15	965	1.13	1.54	0.57	12.27
TopView_1B	22 :55 :06	22 :57 :46	685	1.07	1.44	0.52	12.64
TopView_1C	23 :10 :33	23 :13 :58	673	0.65	1.07	0.78	9.03
TopView_2A	21 :26 :27	21 :29 :07	711	1.58	2.29	0.41	18.11
TopView_2B	21 :40 :39	21 :43 :25	612	1.11	2.58	0.58	13.18
TopView_2C	22 :55 :18	22 :58 :20	693	1.06	1.32	0.54	12.94
TopView_2D	23 :10 :16	23 :12 :57	529	0.64	1.04	0.75	8.96
TopView_2E	23 :24 :59	23 :26 :11	218	0.57	1.00	0.75	8.63
TopView_2F	23 :54 :59	23 :56 :30	183	0.37	0.65	0.95	6.92
		Total	5269	0.96	1.44	0.63	12.22

TABLE 4.1 – Nom des fichiers, durées des flux, nombre de trajectoires et principales caractéristiques des flux. [Dang, 2025]



(a) Chenavard road.

(b) Constantine road.

FIGURE 4.4 – Série temporelle du flux de sortie sur les rues Chenavard et Constantine

4.3.2 Couplage de modèles mesoscopique et microscopique pour la simulation de foules : application à la fête des lumières

Dans cette section, nous présentons et évaluons un modèle permettant le couplage dynamique de modèles dans un contexte de simulation de foules dense : HyPedSim. L'objectif est d'offrir aux modélisateurs la capacité d'associer des zones de l'environnement avec les modèles

Cette section s'appuie sur l'article: Dang, H. T., Gaudou, B., & N. Verstaevel. **HyPedSim : A Multi-Level Crowd-Simulation Framework—Methodology, Calibration, and Validation**. *Sensors, 24(5).* 2024.

adéquats pour le phénomène à simuler.

Principe général : La Figure 4.5 présente le principe général de l'approche. L'environnement est discrétisé en un ensemble de zones, chaque zone décrivant un espace de navigation pour les piétons et contenant sa propre structuration urbaine. Cette partition de l'environnement peut être définie par l'utilisateur ou être issue d'une segmentation conditionnée par des caractéristiques de la foule et de l'environnement. À chaque zone est associé un modèle de simulation de déplacements piéton, composé d'un modèle stratégique, d'un modèle tactique et d'un modèle opérationnel. Ainsi, chaque piéton au sein d'une zone peut être contrôlé par le modèle associé à la zone. La définition de cette association est fixée par le modélisateur. Dans nos expérimentations, les zones sont caractérisées par des densités différentes de flux de piétons. Il est alors possible d'associer à chaque zone un modèle différent en fonction des densités observées. De plus, chaque zone est associée à une fonction de transition qui s'active lorsqu'un agent effectue une transition entre deux zones. Cette fonction de transition permet le transfert des caractéristiques individuelles des agents entre les modèles, assurant ainsi l'agrégation ou la désagrégation des informations. Les piétons sont modélisés à l'échelle individuelle et peuvent se déplacer au sein des différentes zones. À chaque fois qu'un piéton entre dans une nouvelle zone, le piéton met à jour son modèle individuel à l'aide de la fonction de transition.

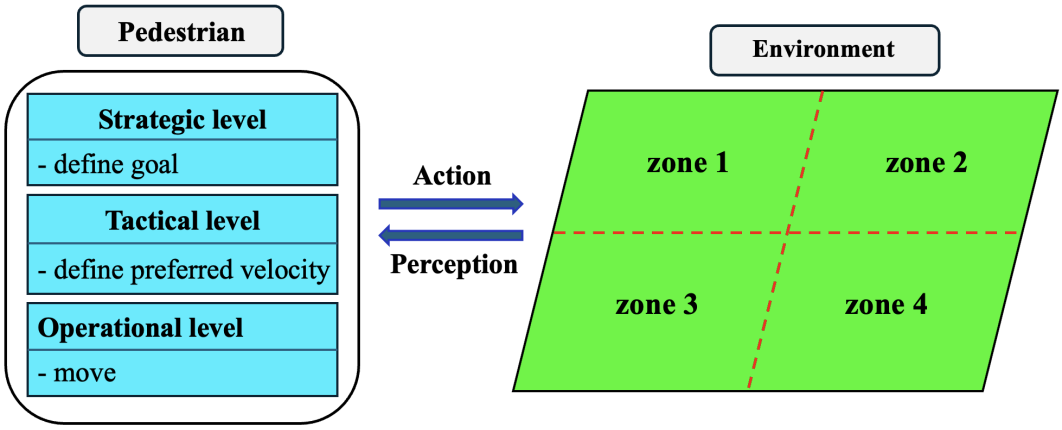


FIGURE 4.5 – Principe général de l'approche [Dang et al., 2024c].

Formalisation du problème : Soit $\mathbb{S} = \{E, A\}$ représentant l'état de la simulation composé d'un environnement E et d'un ensemble d'agents A. Le niveau stratégique du déplacement est formulé comme :

$$S : \mathbb{S} \times t \rightarrow \mathbb{R}^2$$

où S est une fonction qui détermine une cible à atteindre dans l'espace des coordonnées de la simulation dans $\mathbb{R}^2$ à partir de l'état courant $\mathbb{S}$ et de l'instant t. Le niveau tactique se définit

comme :

$$T : \mathbb{S} \times t \times \mathbb{R}^2 \rightarrow \mathbb{R}^2$$

où la fonction T calcule la vélocité de l'agent dans $\mathbb{R}^2$ à partir l'état courant de la simulation $\mathbb{S}$ à l'instant t et de la cible à atteindre. Cette vélocité représente la direction à suivre par l'agent pour son déplacement sans prendre en compte son environnement immédiat.

Le niveau opérationnel correspond à :

$$O : \mathbb{S} \times t \times \mathbb{R}^2 \rightarrow \mathbb{R}^2.$$

où O permet de déterminer la vélocité effective du piéton dans $\mathbb{R}^2$ à partir de la vélocité proposée par le modèle tactique. Cette vélocité effective est celle qui est utilisée par l'agent pour effectuer son prochain déplacement, et prend en compte les capacités de déplacement de l'agent dans son environnement immédiat. Les trois fonctions S, T et O peuvent être reformulées dans un modèle général :

$$\mathbf{v}_i(t) = O_i(\mathbb{S}, t, T_i(\mathbb{S}, t, S_i(\mathbb{S}, t)))$$

$$\mathbf{p}_i(t+1) = \mathbf{p}_i(t) + \mathbf{v}_i(t)\Delta t$$

où $\mathbf{v}_i(t)$ et $\mathbf{p}_i(t)$ représente la vélocité et la position de l'agent i dans le système de coordonnées x-y du système à l'instant t et Δt est la durée d'un pas de simulation.

Architecture de HyPedSim : De la formulation proposée au paragraphe précédent, nous dérivons une architecture logicielle permettant la modélisation des trois niveaux de décision au sein d'un agent, et l'association de ces modèles à des zones de la simulation. La Figure 4.6 présente le diagramme de classe du modèle. Cette architecture s'appuie sur l'usage du patron de conception *stratégie* [Freeman et al., 2004], qui permet de rendre interchangeable une famille d'algorithmes en les encapsulant au sein de classes séparées. Ainsi, à chaque piéton (classe **Pedestrian**) est associée pour chacun des niveaux une interface (classe abstraite ne regroupant que des méthodes) dédiée pour effectuer les opérations définies précédemment (classes **Strategic_level**, **Tactical_level** et **Operational_level**). Ainsi, l'implémentation de différents algorithmes est permise par polymorphisme au travers de l'héritage entre classes. Un piéton est associé à une unique zone (classe *Zone*) et une zone peut admettre plusieurs piétons. À une zone est associée une unique classe pour chacun des trois niveaux.

Diagramme d'activité des piétons : La Figure 4.7 présente le diagramme d'activités d'un agent piéton pour un pas de simulation. Dans un premier temps, l'agent consulte si une cible a déjà été établie et si ce n'est pas le cas met à jour la cible à l'aide du modèle stratégique associé à sa zone courante. Ensuite, l'agent consulte la vélocité désirée et si celle-ci n'est pas définie, il appelle le modèle tactique associé à sa zone. Enfin, l'agent effectue son mouvement à l'aide de son modèle opérationnel. Si l'agent n'est pas arrivé à destination, il vérifie s'il se trouve sur une frontière entre deux zones. Si tel est le cas, il met à jour ses modèles internes en interrogeant la nouvelle zone.

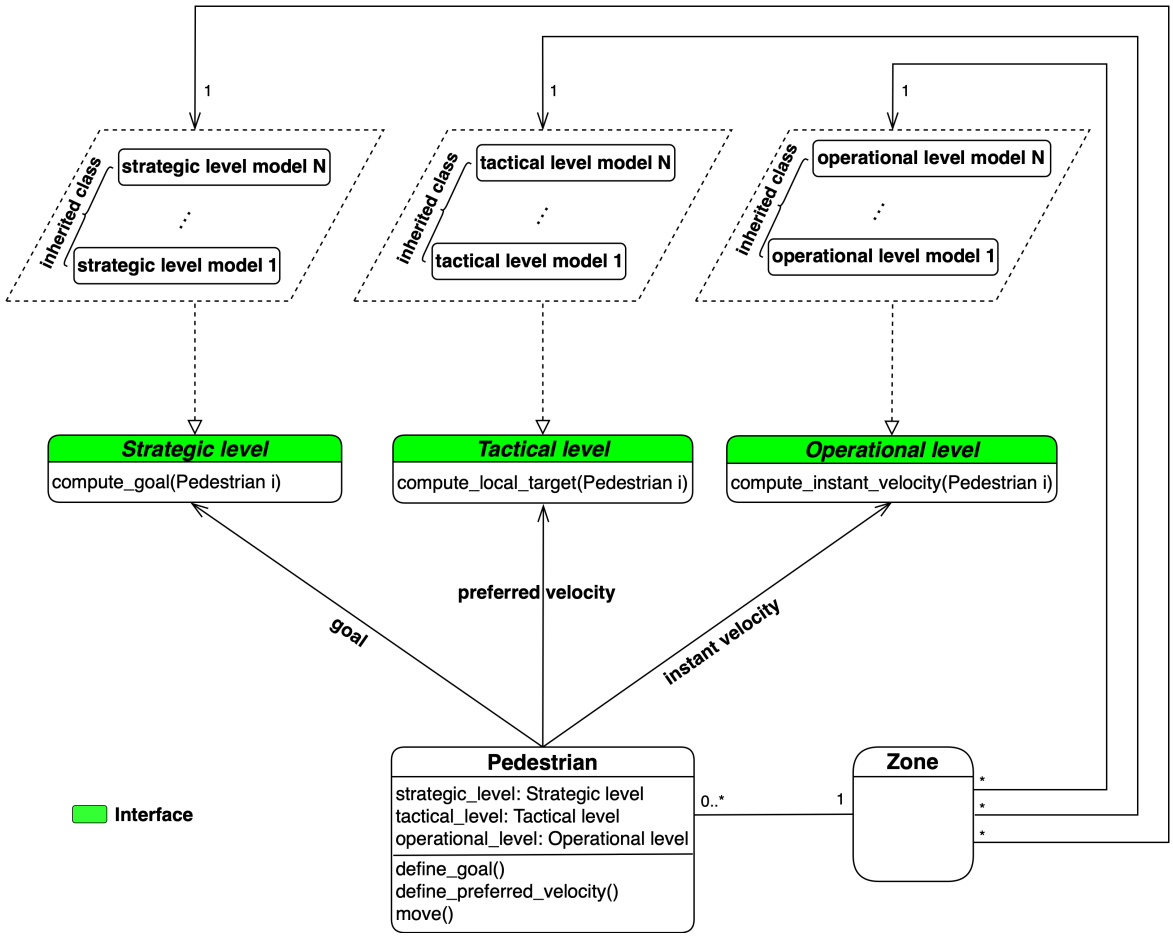


FIGURE 4.6 – Architecture de HyPedSim [Dang et al., 2024c].

Application à la Fête des Lumières : pour évaluer notre modèle, nous avons conçu une simulation dans le cadre de la Fête des Lumières afin de simuler l'évacuation de la place des Terreaux par les piétons. À la fin d'une représentation, les piétons évacuent par les rues Constantine et Chenavard pour continuer leur visite du festival selon les tracés établis par les organisateurs. L'acquisition des données terrain et l'étude des flux vidéos (cf Section 4.3.1) ont permis d'observer une forte densité sur la place et un flux de faible densité sur les deux rues d'évacuation. Cette configuration est intéressante pour étudier le couplage au niveau opérationnel entre les zones à fortes et faibles densités. Ainsi, le modèle est instancié avec trois zones : la place des Terreaux qui est une zone de forte densité et les rues Chenavard et Constantine, qui sont des zones de faible densité. Pour chaque zone on instancie un modèle opérationnel choisi dans l'état de l'art pour sa capacité à modéliser la dynamique de déplacement des piétons à la densité appropriée.

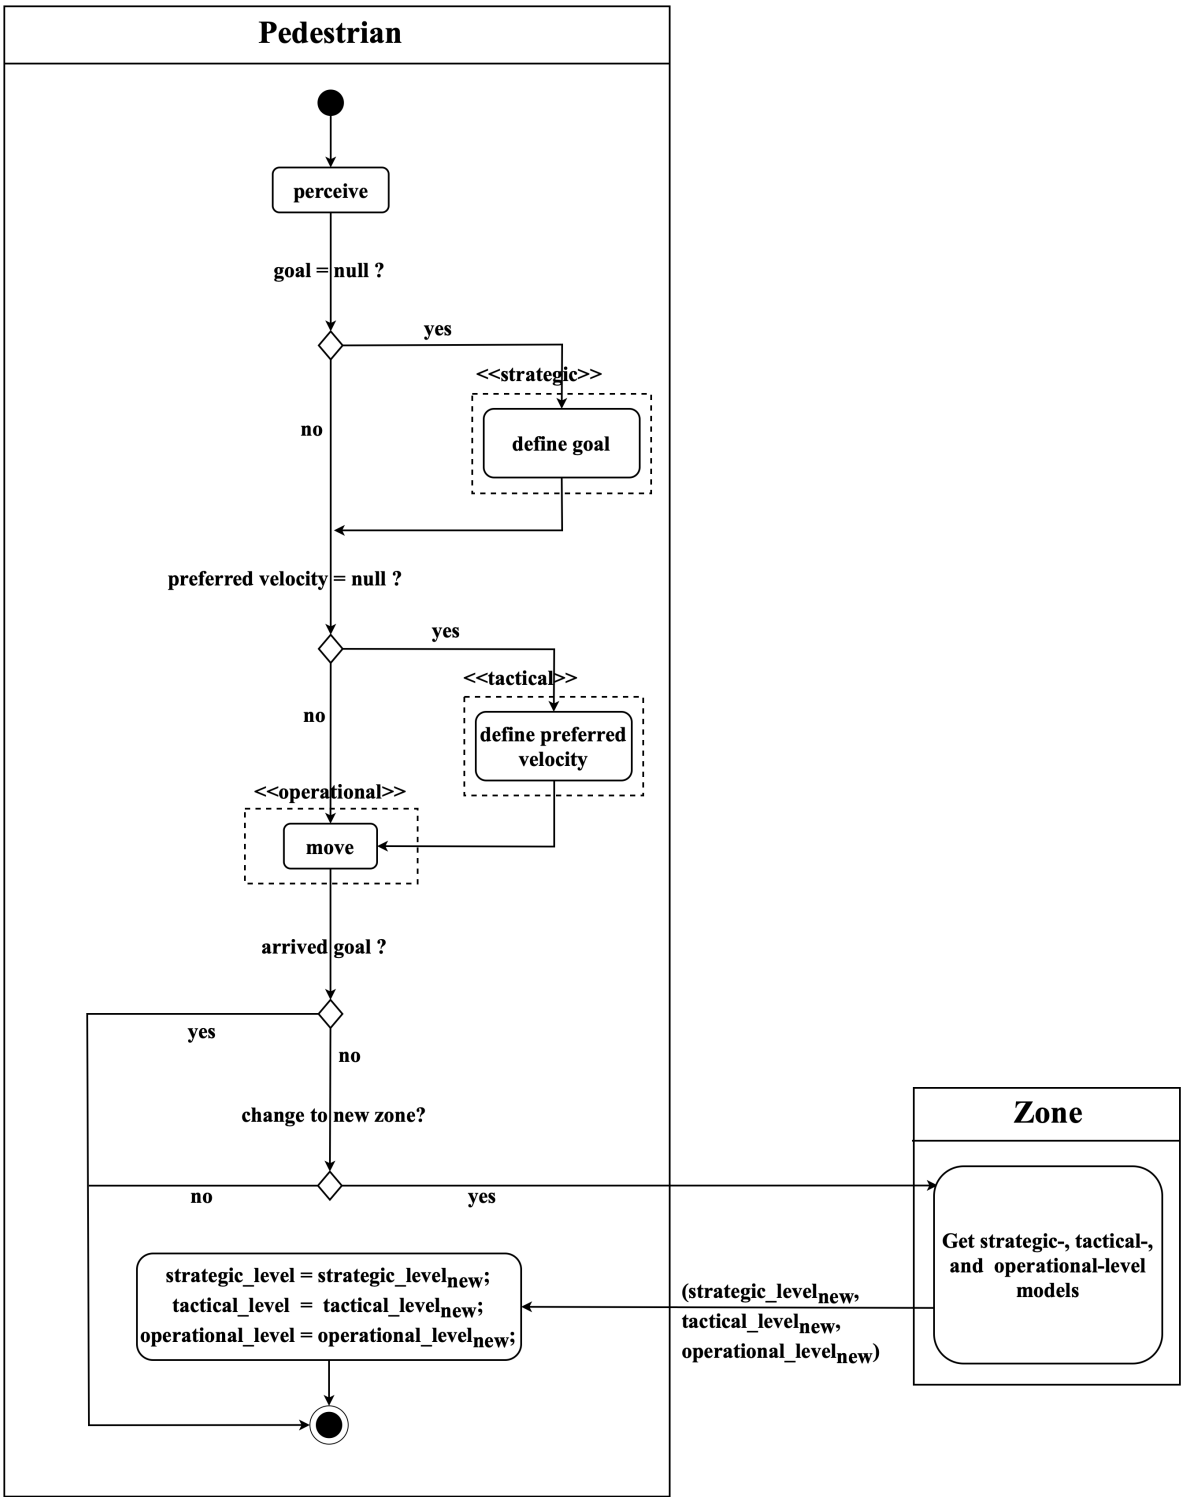


FIGURE 4.7 – Diagramme d'activité des piétons à chaque étape de la simulation [Dang et al., 2024c].

Choix des modèles opérationnels : Pour les zones de faibles densités (Chenavard et Constantine), le modèle microscopique choisi est le *Social Force Model* [Helbing et al., 2000] qui a démontré sa pertinence sur des scénarios de faible densité, notamment pour sa capacité à reproduire des phénomènes émergents tels que la formation de voies dans les flux bidirectionnels [Chen et al., 2018]. SFM propose de modéliser l'accélération d'un piéton en fonction des forces sociales et physiques qui influencent son déplacement. Ainsi, l'accélération d'un agent i, $a_i(t)$, à l'instant t est calculée par une équation basée sur la seconde loi de Newton :

$$\mathbf{a}_i(t) = \frac{\mathbf{v}_i^{pref}(t) - \mathbf{v}_i(t)}{\tau} + \sum_{j \in N(i)} \mathbf{n}_{ij}(t) A \exp^{-\frac{d_{ij}(t)}{B}} + \sum_{\mathrm{w}} \mathbf{n}_{i\mathrm{w}}(t) A_{\mathrm{w}} \exp^{-\frac{d_{i\mathrm{w}}(t)}{B_{\mathrm{w}}}}$$

où $\mathbf{a}_i(t)$ et $\mathbf{v}_i(t)$ représentent respectivement le vecteur accélération et le vecteur vitesse à l'instant t de l'agent i. La vitesse préférentielle du piéton i est désignée par $\mathbf{v}_i^{pref}$.

Le premier terme de l'équation décrit l'accélération du piéton i pour atteindre sa vélocité préférentielle dans un temps de réaction τ.

Le second terme représente les forces de répulsions par rapport à l'ensemble des voisins $N(i)$ du piéton i, avec A et B décrivant la force d'interaction des forces de répulsion.

La distance de séparation entre les piétons i et j à l'instant t est notée $d_{ij}(t)$, tandis que $\mathbf{n}_{ij}(t)$ représente représente le vecteur unitaire dirigé de $\mathbf{x}_j(t)$ vers $\mathbf{x}_i(t)$.

$$d_{ij}(t) = \|\mathbf{x}_i(t) - \mathbf{x}_j(t)\| - (r_i + r_j) \quad \text{and} \quad \mathbf{n}_{ij}(t) = \frac{\mathbf{x}_i(t) - \mathbf{x}_j(t)}{\|\mathbf{x}_i(t) - \mathbf{x}_j(t)\|}$$

où $\mathbf{x}_i(t)$ et r_i représentent respectivement la position et le rayon du piéton i à l'instant t.

Le troisième terme décrit les forces de répulsion des murs proches, avec $\mathbf{n}_{i\mathrm{w}}(t)$ représentant le vecteur normalisé perpendiculaire au mur W du piéton i et $d_{i\mathrm{w}}(t)$ représentant la distance à ce mur au temps t. En outre, A_{w} et B_{w} désignent l'intensité et la plage d'interaction de ces forces de répulsion. Ces valeurs sont fixées à $A_{\mathrm{w}} = 3,0$ et $B_{\mathrm{w}} = 0,1$, sur la base de valeurs calibrées provenant d'études antérieures issues de l'état de l'art [Johansson et al., 2007, Moussaïd et al., 2009]. Ainsi, dans notre modèle hybride, le modèle SFM admet quatre paramètres, à savoir A, B, V^{pref} et τ.

Pour la zone de forte densité (place des Terreaux), le modèle *Continuous Crowd model* (CC) introduit par [Treuille et al., 2006] est selectionné pour sa capacité à simuler le mouvement comme un flux continu indépendamment des caractéristiques individuelles des piétons. Ce modèle utilise un champ potentiel dynamique pour la navigation globale par l'intermédiaire de l'équation eikonale inspirée de la propagation des ondes en physique :

$$\|\nabla\phi(\mathbf{x})\| = C$$

$$\mathbf{v} = -f(\mathbf{x}, \theta)\frac{\nabla\phi(\mathbf{x})}{\|\nabla\phi(\mathbf{x})}$$

où ϕ est la fonction potentielle et C représente le coût unitaire estimé le long de la direction du gradient $\nabla\phi$. Le modèle calcule le coût pour atteindre l'objectif en tenant compte de plusieurs

facteurs, notamment la distance spatiale, le temps et l'inconfort potentiel. La vitesse du piéton est calculée de manière à ce que sa direction soit opposée au gradient et sa magnitude est égale au champ de vitesse $f(\mathbf{x}, \theta)$ évalué à la position $\mathbf{x}$ avec la direction de déplacement θ.

CC propose de discrétiser l'environnement en cellules contenant un ensemble de piétons. Au sein d'une même cellule, les piétons se déplacent vers la même cible et à la même vélocité. La magnitude de la vélocité dans chaque cellule est déterminée par la densité locale via l'équation :

$$f(\mathbf{x}, \theta) = f_{\max} - \frac{\rho(\mathbf{x} + r\mathbf{n}_\theta) - \rho_{\min}}{\rho_{\max} - \rho_{\min}}(f_{\max} - f_{flow}(\mathbf{x}, \theta))$$

où $\rho_{\max}$ et $\rho_{\min}$ correspondent respectivement au seuil de densité maximum et minimum influençant la valeur de la vitesse. En outre, $f_{flow}(\mathbf{x}, \theta)$ représente la vitesse moyenne du flux dans la direction θ à la position $\mathbf{x}$. De même, $\rho(\mathbf{x} + r\mathbf{n}_\theta)$ signifie la densité locale évaluée à l'endroit $\mathbf{x} + r\mathbf{n}_\theta$, qui se trouve à une distance r de $\mathbf{x}$ dans la direction θ.

La vitesse des piétons atteint sa valeur maximale $f_{\max}$ lorsque la densité est inférieure à $\rho_{\min}$. Inversement, lorsque la densité est supérieure à $\rho_{\max}$, la vitesse des piétons est fixée à la vitesse moyenne du flux de foule. La limite inférieure de la vitesse moyenne du flux de foule est notée $f_{\min}$. À l'intérieur de ces seuils de densité, la vitesse des piétons diminue linéairement de la valeur maximale à la valeur minimale à mesure que la densité augmente de $\rho_{\min}$ à $\rho_{\max}$.

Ainsi, dans notre application, le modèle CC admet pour paramètres $f_{\min}, f_{\max}, \rho_{\min}$ et $\rho_{\max}$.

Simulation et hybridation des modèles : notre contribution a été de coupler dans notre modèle hybride le modèle SFM avec le modèle CC au sein de la même simulation, et ce dans le but de reproduire les dynamiques observées lors de la collecte de données pendant le festival des lumières. La simulation s'effectue avec un pas de temps de $\Delta_t = 0.1s$ et inclus un total de 3883 piétons (ce nombre est issu des analyses terrain). Les piétons sont initialement distribués uniformément sur la place des Terreaux. La simulation s'arrête lorsque tous les piétons ont atteint la fin des rues d'évacuation. Les bâtiments et obstacles sont représentés à l'aide des données obtenus à partir d'OpenStreetMap. Les simulations sont réalisées sur la plateforme GAMA [Taillandier et al., 2019] et exécutées sur un MacBook Pro M1 doté de 32GB de RAM.

Le modèle CC est implémenté sur la place des Terreaux et les piétons ont pour objectif d'atteindre la sortie située dans le coin inférieur gauche de la place, en direction des rues Chenavard et Constantine. La place est divisée en cellules, chaque cellule stockant les informations sur la densité et la vélocité moyenne. Il est à noter que dans le modèle CC, les piétons sont modélisés à l'échelle individuelle, seule leur vélocité est contrôlée par la cellule sur laquelle ils se trouvent. Le modèle SFM est utilisé pour simuler la sortie des piétons au sein des deux rues Chenavard et Constantine. Les deux modèles proposant une modélisation individuelle des piétons, il n'est pas nécessaire d'effectuer d'opération d'agrégation ou de désagrégation lorsqu'un piéton effectue la transition entre les deux modèles. Pour modéliser l'existence d'une transition entre la place des Terreaux et les deux rues de sortie, on introduit un paramètre $t_{delay} \in [0, 1]$ simulant un bref arrêt durant la transition. Enfin, les piétons sortant de la place

des Terreaux peuvent évacuer selon deux rues. Pour modéliser ce choix, nous introduisons deux paramètres α et β contrôlant respectivement la probabilité de choisir la rue Constantine ou la rue Chenavard. Ainsi, si le piéton est le plus proche de la rue Constantine, il aura une probabilité de $1-\alpha$ de choisir cette rue. S'il est plus proche de la rue Chenavard, cette probabilité sera de $1-\beta$. Notre modèle introduit donc trois paramètres pour assurer la transition entre les deux modèles : t_{delay}, α et β. Ces paramètres, ainsi que ceux des modèles SFM et CC, ont été calibrés en utilisant les données collectées par l'analyse des flux vidéos.

Calibration : La Table 4.2 liste les paramètres à calibrer ainsi que leurs valeurs minimum et maximum (selon [Helbing et al., 2000, Treuille et al., 2006]).

TABLE 4.2 – Liste des paramètres et de leur domaine de définition.

Modèle	ϕ	$\phi^{\mathbf{min}}$	$\phi^{\mathbf{max}}$
Hybrid	t_{delay}	0.0	1.0
	α	0.0	1.0
	β	0.0	1.0
SFM	A	0.5	5.0
	B	0.1	0.5
	V^{pref}	0.8	1.5
	τ	0.4	0.6
CC	f_{min}	0.05	0.25
	f_{max}	0.8	1.6
	ρ_{min}	0.05	0.5
	ρ_{max}	6.0	8.0

Pour calibrer ces onze paramètres, un algorithme génétique a été utilisé. Cette approche est utile pour un espace de recherche large et continu [Zeng et al., 2017]. De plus, les données terrain utilisées pour calibrer le modèle sont des données macroscopiques sur les flux de piétons. Ces données ne peuvent pas être facilement et directement utilisées avec des méthodes statistiques pour estimer les paramètres liés aux caractéristiques individuelles telles que la vitesse préférée.

Au cours d'une simulation, $N = 20$ points d'échantillonnages (un point toutes les 20 secondes) mesurent les flux de sorties observés sur les deux rues. Ainsi un score de fitness est associé à chaque individu. La fonction de *fitness* utilisée est définie comme suit :

$$fitness = \frac{1}{N}\sum_{i=1}^{N}\left(\frac{|f_i^{obs} - f_i^{sim}|}{f_i^{obs}}\right)_{Constantine} + \left(\frac{|f_i^{obs} - f_i^{sim}|}{f_i^{obs}}\right)_{Chenavard}$$

où f_i^{obs} et f_i^{sim} représentent respectivement les flux de piétons observés et simulés au $i$ème point temporel. La fonction de *fitness* quantifie l'erreur absolue moyenne normalisée entre le

flux de piétons observé et le flux de piétons simulé sur N points temporels. Plus la valeur de la fonction de *fitness* est faible, plus elle correspond au flux réel. Elle peut être abordée comme l'erreur moyenne sur les N pas de temps pour les deux flux de sorties des piétons, à savoir les rues Chenavard et Constantine.

Une population de 128 chromosomes contenant 11 gènes, chacun associé à un paramètre et dont la valeur est initialisée de manière aléatoire dans son domaine de définition. Chaque individu représente une configuration des paramètres de simulation à évaluer.

Une fois les 128 solutions évaluées, nous appliquons une sélection parmi les individus ayant obtenu le score de fitness le plus faible. Le taux de sélection est fixé à 50%. Les indidividus sélectionnés ayant la plus petite valeur de *fitness* sont conservés dans la génération suivante et serviront de parents aux nouveaux individus.

Les parents choisis à l'étape précédente sont combinés pour générer une progéniture qui constitue 50% de la population suivante. Le matériel génétique des parents est fusionné à l'aide d'un croisement uniforme, où chaque gène du chromosome de la progéniture a une probabilité de 50% de provenir de l'un ou l'autre parent. La Figure 4.8 illustre le processus de croisement uniforme entre deux chromosomes parents, où chaque gène de la progéniture est dérivé des gènes correspondants (le gène sélectionné étant coloré en rouge) de l'un ou l'autre des chromosomes parents.

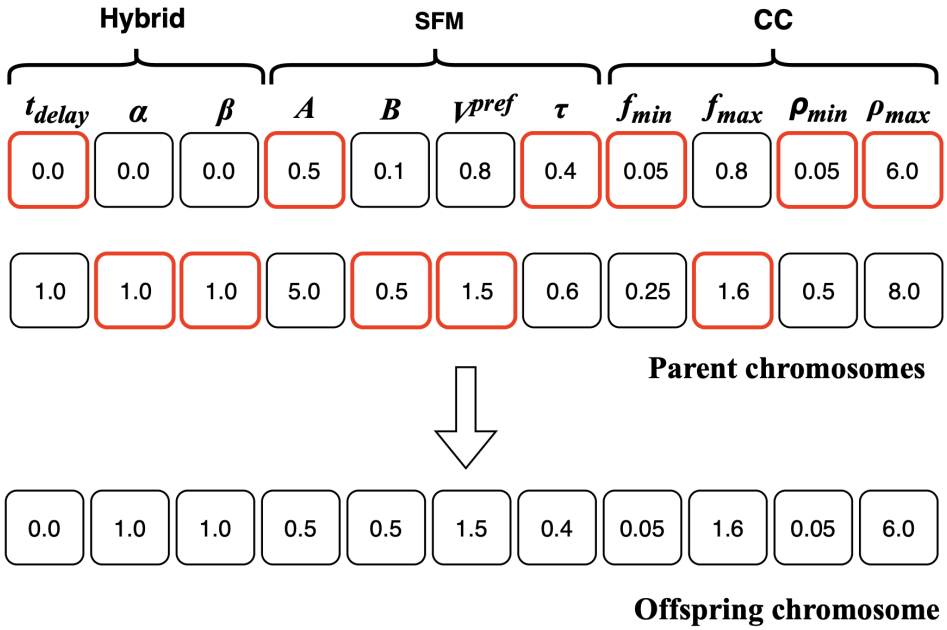


FIGURE 4.8 – Illustration du processus de croisement uniforme entre deux chromosomes [Dang et al., 2024c].

Enfin, une mutation aléatoire est appliquée aux gènes des chromosomes afin de maintenir la diversité génétique au sein de la population. Cette étape empêche l'algorithme GA de rester

bloqué dans un optimum local en augmentant les chances d'explorer de nouvelles solutions potentielles. Un taux de mutation de 1% est appliqué à chaque gène d'un chromosome. Si une mutation se produit pour un gène spécifique ϕ_i sa nouvelle valeur est calculée à l'aide de la formule suivante :

$$\phi_i + 1 = \phi_i^{min} + \gamma(\phi_i^{max} - \phi_i^{min}), \quad 0 \leq \gamma \leq 1. \tag{4.1}$$

où γ est une valeur aléatoire comprise entre 0 et 1.

Le processus de calibration est effectué sur 150 générations. La figure 4.9 présente la valeur moyenne et la meilleure valeur de fitness dans la population sur 150 générations. La Table 4.3 montre le résultat de la calibration sur la meilleure solution obtenue par la procédure de calibration.

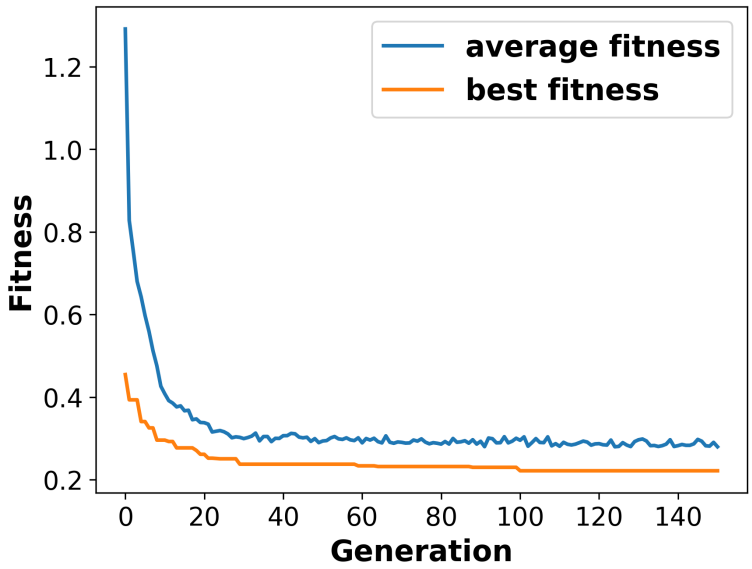


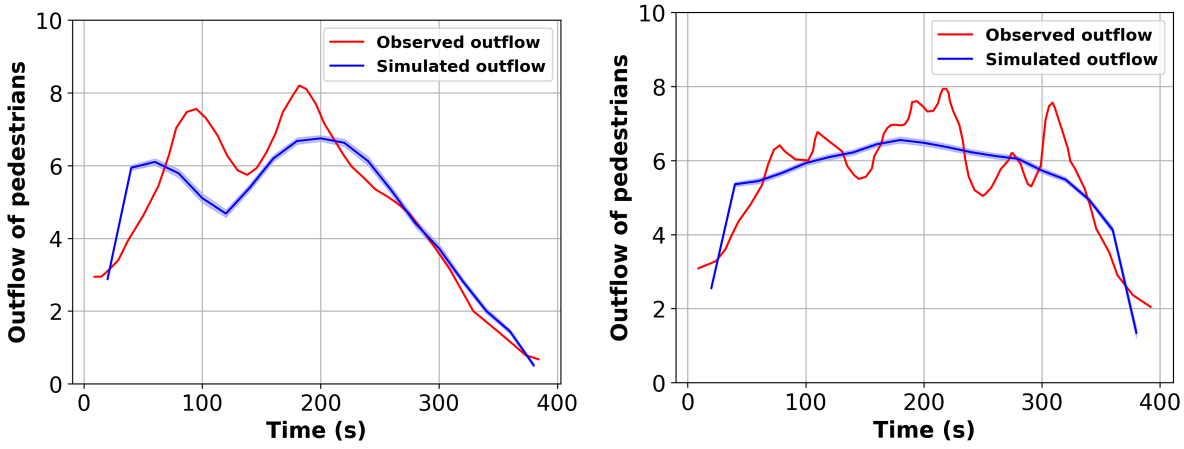
FIGURE 4.9 – Moyenne et meilleure valeurs de fitness sur 150 générations [Dang et al., 2024c].

TABLE 4.3 – Valeurs des paramètres obtenus à l'issue du processus de calibration.

Parameter ϕ_i	t_{delay}	α	β	A	B	V^{pref}	τ	$f_{\min}$	$f_{\max}$	$\rho_{\min}$	$\rho_{\max}$
Best value	0.9	0.91	0.76	1.83	0.45	1.25	0.57	0.15	1.35	0.11	6.36

Validation du modèle : 90 simulations ont été effectuées en utilisant le jeu de paramètres trouvé par calibration. Le flux moyen de piétons simulé est calculé avec un intervalle de confiance de 95%. La figure 4.10 montre la comparaison entre le débit piéton moyen simulé et le débit piéton observé pour les deux rues de sortie. Dans l'ensemble, les débits observés

présentent des pics plus marqués, tandis que les débits simulés sont plus lisses, tout en reflétant les tendances générales des débits réels. Pour la rue de Constantine, le flux sortant simulé capture qualitativement les deux pics du flux sortant réel, comme le montre la Figure 4.10a. Inversement, pour la rue de Chenevard, le débit simulé a tendance à atténuer les variations rapides du débit réel, ce qui donne une représentation plus moyenne, comme le montre la figure 4.10b.



(a) (b)

FIGURE 4.10 – Comparaison des débits observés et simulés (moyenne sur 90 simulations) pour les deux routes de sortie : (**a**) Route de Constantine. (**b**) Route de Chenavard [Dang et al., 2024c].

Analyse de sensibilité : Nous réalisons une étude de sensibilité locale (*one parameter at a time*) pour étudier l'impact de chacun des paramètres sur la sortie du modèle. Pour chacun des paramètres, nous faisons varier les valeurs entre -25% et +25%, avec un incrément de 5%. Les autres paramètres sont fixés pendant l'analyse locale d'un paramètre donné. La Figure 4.11 présente les résultats de l'analyse de sensibilité pour les 11 paramètres. On y observe que les paramètres ayant un impact significatif comprennent les trois paramètres d'hybridation : t_{delay}, α, et β, ainsi que deux paramètres du modèle CC : $f_{\min}$ et $f_{\max}$. En outre, l'analyse confirme à nouveau que la fonction de fitness atteint la meilleure valeur lorsque les paramètres sont fixés à leurs valeurs calibrées et tend à se détériorer si l'un des paramètres influant s'écarte de sa valeur calibrée.

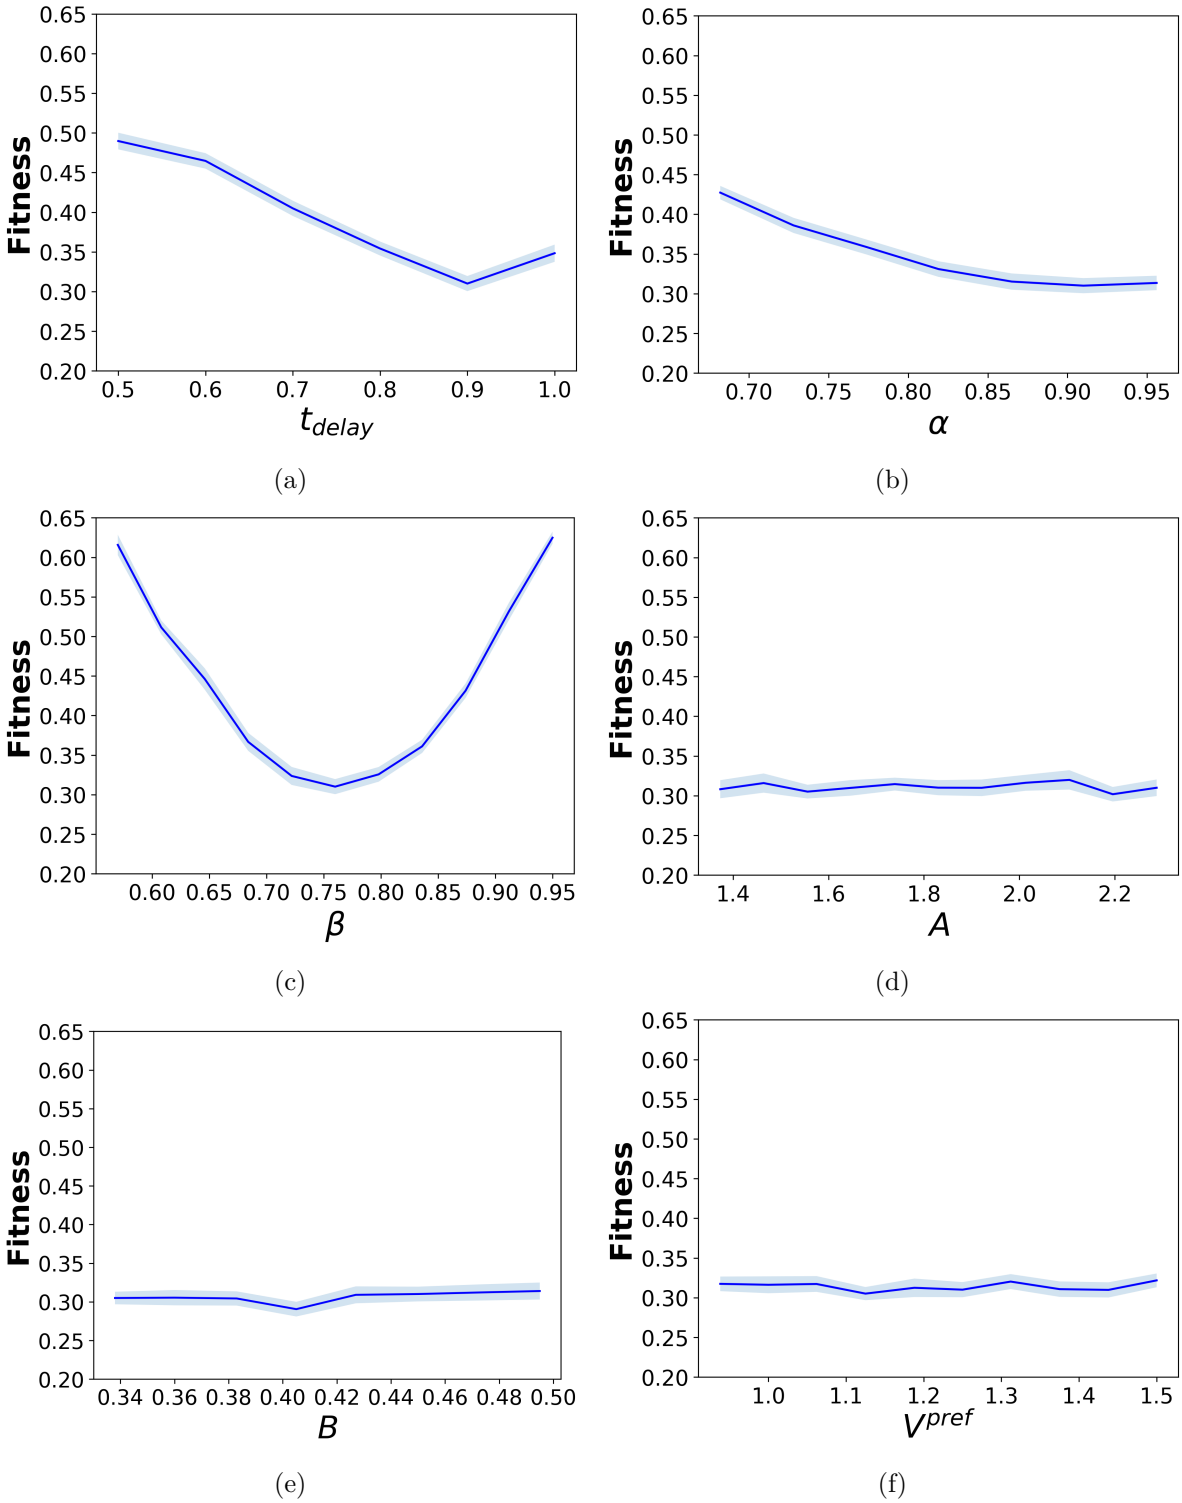


FIGURE 4.11 – Analyse de sensibilité locale sur les 11 paramètres du modèle (**a**) t_{delay}, (**b**) α, (**c**) β, (**d**) A, (**e**) B, (**f**) V^{pref}, (**g**) τ, (**h**) $f_{\min}$, (**i**) $f_{\max}$, (**j**) $\rho_{\min}$, (**k**) $\rho_{\max}$ [Dang et al., 2024c].

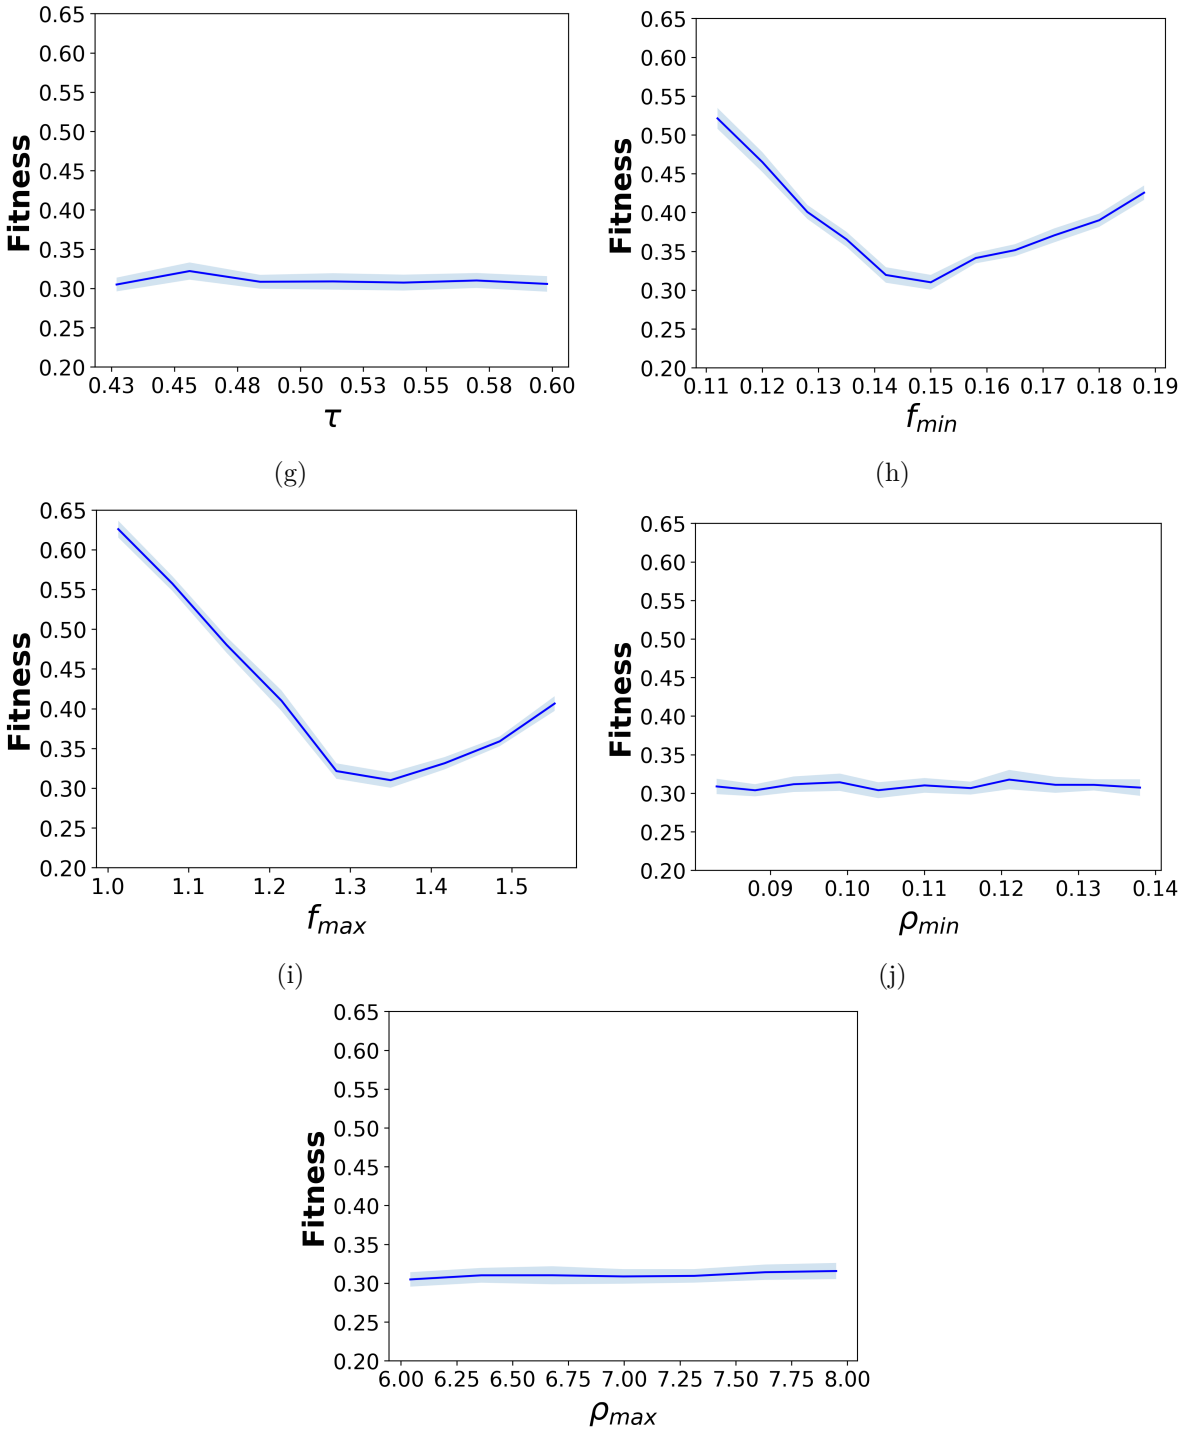


FIGURE 4.11 – Analyse de sensibilité locale sur les 11 paramètres du modèle (**a**) t_{delay}, (**b**) α, (**c**) β, (**d**) A, (**e**) B, (**f**) V^{pref}, (**g**) τ, (**h**) $f_{\min}$, (**i**) $f_{\max}$, (**j**) $\rho_{\min}$, (**k**) $\rho_{\max}$ [Dang et al., 2024c].

Analyse des performances : Les performances de notre approche ont été étudiées en la comparant avec trois autres modèles :

— Un modèle *SFM-only* où le modèle SFM est utilisé dans les 3 zones.
— Un modèle *3-CC-1* où chaque zone dispose de son propre modèle CC. Ce modèle comprend trois modèles CC distincts, chacun simulant la dynamique des piétons dans une zone. Étant donné que les piétons de chaque zone se déplacent dans des directions similaires, chaque modèle CC est conçu avec une seule cellule cible. Le modèle est donc appelé modèle 3-CC-1.
— Un modèle *1-CC-2* qui utilise un seul modèle CC pour simuler la dynamique des piétons dans l'ensemble de l'environnement en tant que zone unique. Le modèle CC est conçu avec deux cellules cibles différentes pour simuler deux groupes de piétons se dirigeant vers les deux rues de sortie, d'où le nom de modèle 1-CC-2. Il est important de noter que la complexité du modèle CC augmente avec le nombre de cellules cibles.

Chaque modèle est exécuté 15 fois en utilisant les valeurs de paramètres obtenus lors de la calibration du modèle HyPedSim. La figure 4.12 affiche les cartes de densité des différents modèles simulant 6000 agents piétons à trois moments précis de la simulation : $t = 60$ s, 150 s, et 240 s. Elle illustre la différence qualitative des modèles, SFM produisant une densité moyenne et homogène sur l'ensemble des zones, contrairement au modèle CC qui produit une forte densité sur l'ensemble des zones. Notre approche (*Hybrid model*) montre à l'inverse une densité forte sur la place, mais un flux plus faible sur les zones de sorties. Une visualisation détaillée de la simulation du modèle hybride est présentée dans la Figure 4.13, où les piétons de la place sont simulés à l'aide du modèle CC et représentés en rouge, tandis que les piétons des deux routes de sortie sont simulés à l'aide de SFM et illustrés en bleu.

La durée moyenne requise pour effectuer une étape de simulation est calculée pour un nombre d'agents initiaux (exprimé en milliers d'agents) et comparée dans la figure 4.14. Les résultats indiquent que les modèles SFM seul et 3-CC-1 prennent le plus de temps pour effectuer chaque étape de simulation, la durée augmentant de manière significative lorsque le nombre d'agents augmente. Le modèle 1-CC-2 présente des durées similaires à celles des modèles SFM-only et 3-CC-1 lorsqu'il simule moins de 9 K agents, mais il devient plus rapide lorsque le nombre d'agents dépasse 9 K. Inversement, le modèle hybride présente la durée la plus courte pour différents nombres d'agents simulés, avec une nette différence de vitesse par rapport aux autres modèles. Ces résultats illustrent le potentiel des mécanismes de couplage de modèle pour le passage à l'échelle des simulations. Ces résultats sont similaires à ceux que nous avions précédemment obtenus lors d'expérimentation sur le couplage de modèles pour des simulations de trafic [Erdelyi et al., 2021b].

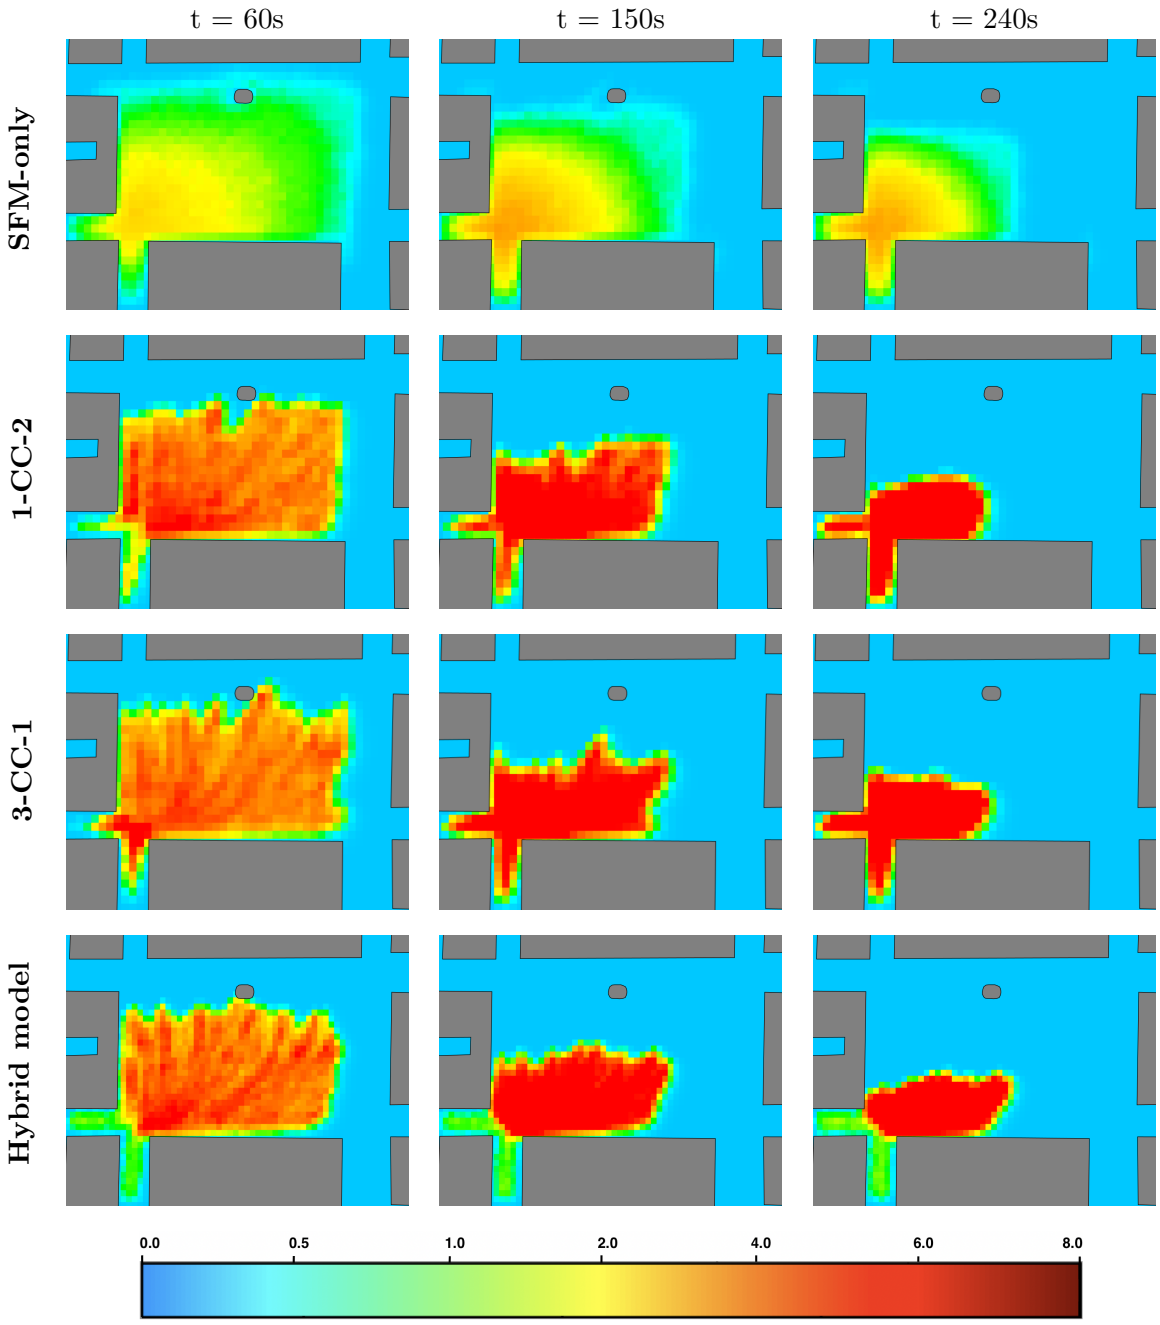


FIGURE 4.12 – Carte de densité pour chacun des modèles avec 6000 agents simulés [Dang et al., 2024c].

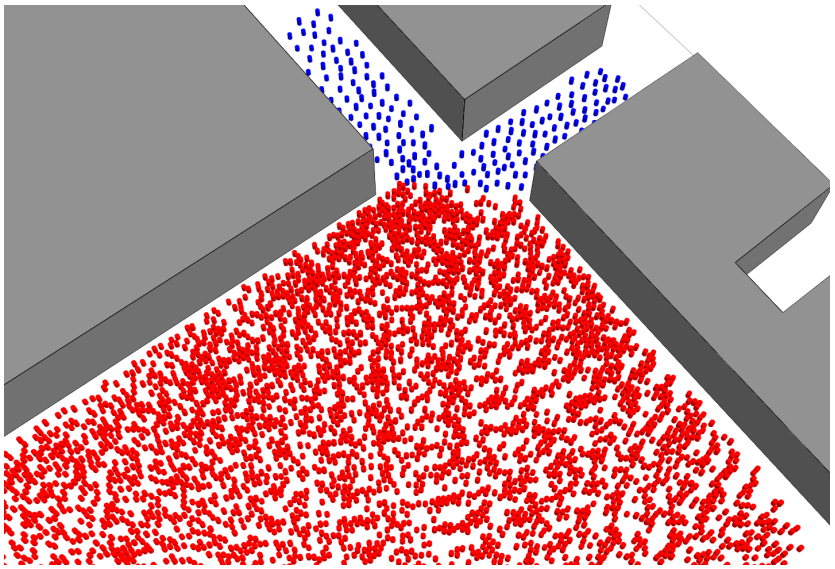


FIGURE 4.13 – Visualisation de la simulation avec 6000 agents. Les agents de couleur rouge sont contrôlés par le modèle CC, alors que les agents de couleur bleue sont contrôlés par le modèle SFM [Dang et al., 2024c].

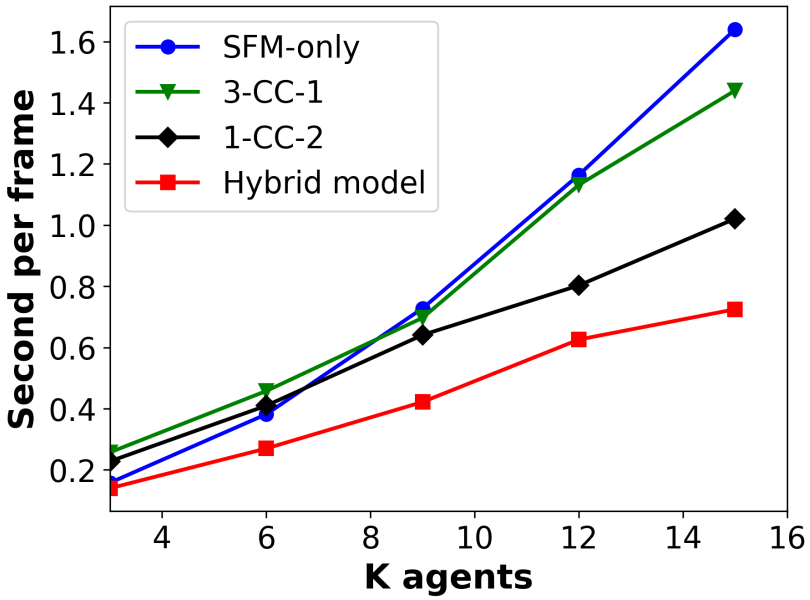


FIGURE 4.14 – Comparaison des temps de calcul pour différents nombre d'agents (en milliers) [Dang et al., 2024c].

4.3.3 Prédiction de trajectoires de piétons en foules denses

Modèles dirigés par la donnée : La dernière décennie a vu le développement de l'usage des réseaux neuronaux d'apprentissage profond pour la prédiction de trajectoires de piétons [Korbmacher and Tordeux, 2022]. Contrairement aux modèles traditionnels fondés sur la connaissance, les modèles de réseaux neuronaux sont appris à partir des données sans s'appuyer sur des règles prédéfinies. Des études empiriques ont montré que les modèles d'apprentissage profond, notamment LSTM (*Long-Short Term Memory*) et les réseaux adverses génératifs (GAN), surpassent les modèles traditionnels basés sur la physique en termes de précision des prédictions basées sur la distance [Korbmacher and Tordeux, 2022]. LSTM est un type de réseau de neurones réucrrents (RNN) introduisant dans l'architecture du réseau des cellules mémoires, permettant ainsi au réseau de traiter des dépendances à long terme. LSTM est utilisé pour prédire l'évolution d'une série temporelle, c'est-à-dire dans notre cas pour prédire une trajectoire de piétons à partir des informations de l'environnement. Pour permettre la prise en compte de la composante sociale dans les interactions entre piétons, [Alahi et al., 2016] ont présenté Social-LSTM qui incorpore une couche de mise en commun des informations des visions du piéton en couche appelée social-pooling. Cette couche regroupe les états cachés des piétons voisins afin de permettre aux réseaux de prendre en compte les interactions entre les piétons dans la prédiction de la trajectoire.

Social-LSTM représente chaque trajectoire de piéton dans la scène par un LSTM qui génère un état caché à chaque pas de temps. Soit h_t^i l'état caché du LSTM correspondant au $i$ème piéton, qui capture sa représentation latente au temps t. Le tenseur d'état caché social H_i^t est créé avec une taille de $N_0 \times N_0 \times D$ par pooling structuré en grille pour la trajectoire du $i$ème piéton :

$$H_i^t(m,n,:) = \sum_{j \in N_i} 1_{mn}[x_j^t - x_i^t, y_j^t - y_i^t] h_j^{t-1}$$

où D et N_0 représentent respectivement la dimension de l'état caché et la taille du voisinage. Le terme $1_{mn}[x,y]$ sert d'indicateur binaire déterminant si un point (x,y) se trouve dans la cellule (m,n) de la grille. En outre, N_i représente l'ensemble des piétons voisins dans un rayon spécifique pour le piéton i. Cette couche capture les interactions entre les piétons en agrégeant les informations spatiales et temporelles de la dynamique des piétons voisins et en partageant ces informations entre les LSTM voisins.

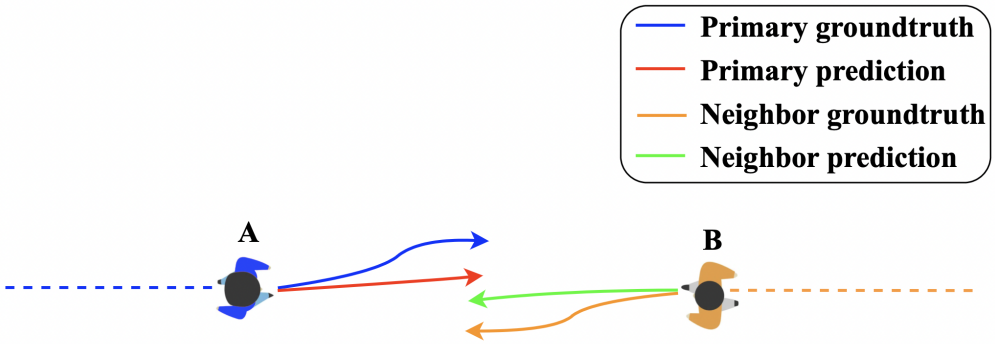
Une *negative log-likelihood loss* (NLL) est utilisée pour entraîner le modèle SLSTM original. Cette perte calcule le logarithme négatif de la probabilité que le modèle attribue à la trajectoire réelle. En minimisant cette perte au cours du processus de formation, le modèle apprend à attribuer des probabilités plus élevées aux vraies trajectoires et des probabilités plus faibles aux trajectoires incorrectes, ce qui permet de prédire des trajectoires avec une grande précision en termes de distance.

Ces réseaux neuronaux sont entraînés à l'aide d'une fonction de perte qui se concentre principalement sur l'optimisation de l'erreur de distance entre les trajectoires prédites et les trajectoires réelles. Cependant, des études récentes indiquent que les prédictions faites par ces modèles aboutissent souvent à de nombreuses collisions, en particulier dans les situations de

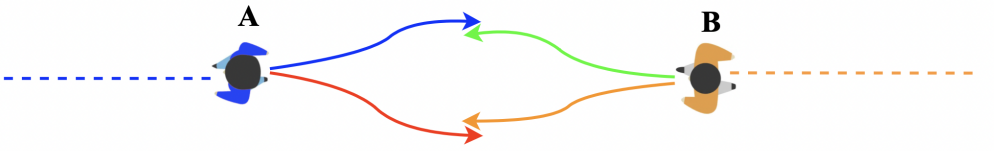
forte densité [Korbmacher et al., 2024][Kothari et al., 2021].

Dans sa formulation originale, Social-LSTM peut potentiellement produire des trajectoires qui ne reflètent pas les comportements réalistes des piétons, notamment en violant les contraintes physiques du monde réel, ce qui se traduit par des trajectoires physiquement peu plausibles avec des taux de collision élevés, en particulier dans les scénarios de forte affluence [Korbmacher et al., 2022c].

La figure 4.15a montre une prédiction avec une grande précision de distance mais un faible réalisme car les trajectoires prédites entraînent une collision. En revanche, la figure 4.15b montre une prédiction moins précise en terme de distance mais plus réaliste par un évitement de collision.



(a) High distance-based accuracy, low realism.



(b) Low distance-based accuracy, high realism.

FIGURE 4.15 – Exemples de trajectoire produisant une bonne précision en terme de distance mais conduisant à une collision (a) et une trajectoire d'évitement de collision (b) [Dang et al., 2024c].

Intégrer la distance à la collision : Dans le cadre de l'ANR-DFG-MADRAS (https://anr.fr/Projet-ANR-20-CE92-0033) et de la thèse de Dang Huu-Tu, nous avons souhaité adresser la propension à générer un trop grand nombre de collisions dans des situations de forte densité. Ainsi, nous avons proposé *TTC-LSTM*, une extension de Social-LSTM qui intègre un terme de collisions dans la fonction de perte. Ce nouveau terme est construit sur le temps avant collision (*time-to-colision*), un concept fréquemment utilisé pour estimer le

temps restant avant une collision entre deux piétons, sous l'hypothèse que les deux piétons maintiennent leur vitesse actuelle et leur direction [Karamouzas et al., 2014]. Posons que :

- Les piétons sont représentés par des agents en forme de disque, r_i représentant le rayon du piéton i.
- $\mathbf{v}_i = (v_{x_i}, v_{y_i})$ représente le vecteur vitesse du piéton i.
- La position relative et la vitesse relative du piéton i par rapport au piéton j sont désignées par $\mathbf{p}_{ij} = (x_i - x_j, y_i - y_j)$ et $\mathbf{v}_{ij} = (v_{x_i} - v_{x_j}, v_{y_i} - v_{y_j})$, respectivement.
- τ_{ij} représente le temps estimé avant une future collision potentielle entre les piétons i et j.

Si une collision entre les piétons i et j se produit à un moment donné dans le futur, leur TTC estimée est alors calculée comme suit :

$$\tau_{ij} = \frac{\mathbf{p}_{ij} \cdot \mathbf{v}_{ij} - \sqrt{(\mathbf{p}_{ij} \cdot \mathbf{v}_{ij})^2 - \|\mathbf{v}_{ij}\|^2(\|\mathbf{p}_{ij})\|^2 - (r_i + r_j)^2)}}{\|\mathbf{v}_{ij}\|^2}$$

où $\|.\|$ désigne la norme euclidienne.

[Karamouzas et al., 2014] décrivent ces interactions par une "énergie d'interaction" de temps avant collision définie comme la mesure de la répulsion mutuelle qui empêche les piétons qui s'approchent d'entrer en collision [Karamouzas et al., 2014]. [Karamouzas et al., 2014] formulent que l'énergie d'interaction de deux piétons est mieux décrite par une fonction de loi de puissance de leur temps estimé jusqu'à la collision, plutôt que par leur simple distance physique. L'énergie d'interaction entre deux piétons, i et j, est mathématiquement décrite comme suit :

$$E_{ij} = E(\tau_{ij}) = \frac{k}{\tau_{ij}^2} e^{-\tau_{ij}/\tau_0}$$

où k est une constante de normalisation, tandis que τ_0 décrit le seuil temporel représentant le fait que les piétons ont tendance à ignorer les collisions potentielles qui se produisent dans un avenir lointain.

TTC-SLSTM : Nous avons exploré avec TTC-SLSTM la possibilité d'améliorer la prise en compte des collisions en étendant SLSTM pour incorporer des contraintes physiques dans la fonction d'apprentissage. Plus précisément, la fonction de perte est complétée par un terme supplémentaire décrivant un terme de perte lié à la présence de collision par le biais de l'énergie d'interaction avec les piétons voisins :

$$\mathrm{L}_i = \mathrm{NLL}_i + \lambda \frac{1}{T_{pred}} \sum_{t=1}^{T_{pred}} \sum_{j \neq i} \tanh(E_{ij})$$

où L_i représente la nouvelle fonction de perte et NLL_i la *negative log-likelihood* résultant de la i^{th} trajectoire, tandis que λ est un poids ajouté pour ajuster l'influence du terme de perte de collision sur la perte totale. Si $\lambda = 0$, le modèle devient alors le Social-LSTM original.

L'impact des différentes valeurs de λ sur les performances de prédiction du modèle est exploré dans les expériences présentées dans la section suivante.

La fonction tanh (une fonction non linéaire utilisée dans l'apprentissage profond pour apprendre des tâches complexes) est appliquée pour normaliser les valeurs excessivement grandes de l'énergie d'interaction lorsque τ est petit. Ainsi, le second terme représente la somme totale de la fonction *tanh* appliquée à l'énergie générée lors de l'interaction entre tous les piétons voisins. Une pénalité quand le risque de collision est trop important est ajoutée à la perte d'apprentissage pour les trajectoires prédites tout en maintenant la perte de log-vraisemblance négative pour l'erreur de distance. Par conséquent, le réseau neuronal apprend à minimiser à la fois la perte de log-vraisemblance négative et la perte de collision par le biais de la fonction de perte d'apprentissage proposée.

Expérimentations : Pour évaluer notre proposition, on réalise une analyse comparative des performances entre TTC-SLSTM et Social-LSTM sur deux ensembles de jeu données publiques sur les piétons largement utilisés (ETH [Pellegrini et al., 2009] et UCY [Lerner et al., 2007]), ainsi que l'ensemble de jeu données MADRAS collecté pendant la Fête des Lumières. Ces jeux de données contiennent un ensemble de trajectoires de piétons qui ont été acquises dans des configurations différentes. Le tableau 4.4 présente les différents jeux de données en les catégorisant en deux types : ceux de faible densité et ceux de forte densité.

Type	**Source**	**Donnée**	**Configuration**	**No. Traj**	**Densité Moyenne** ($\mathbf{1/m^2}$)	**Densité Max** ($\mathbf{1/m^2}$)
Faible densité	ETH	ETH	Outdoor	361	0.15	0.52
		HOTEL	Outdoor	389	0.13	0.32
	UCY	ZARA01	Outdoor	148	0.21	0.51
		ZARA02	Outdoor	204	0.27	0.48
		UNIV	Outdoor	434	0.38	0.52
Forte densité	MADRAS	TopView_2D	Outdoor	529	0.64	1.04
		TopView_2E	Outdoor	218	0.57	1.00
		TopView_2F	Outdoor	183	0.37	0.65

TABLE 4.4 – Jeux de données utilisés par la comparaison

Quatre métriques de la littérature permettent d'évaluer les performances de prédiction des deux réseaux de neurones pour M prédictions : deux sont basées sur la distance (**Average Displacement Error (ADE)** et **Final Displacement Error (FDE)**), et deux sont basées sur le nombre de collisions (**Prediction Collision (Col-I)** et **Groundtruth Collision**

(Col-II) [Kothari et al., 2021]) :

$$\textbf{ADE} = \frac{1}{MT_{pred}} \sum_{i=1}^{M} \sum_{t=1}^{T_{pred}} \sqrt{(\hat{x}_i^t - x_i^t)^2 + (\hat{y}_i^t - y_i^t)^2}$$

$$\textbf{FDE} = \frac{1}{M} \sum_{i=1}^{M} \sqrt{(\hat{x}_i^{T_{pred}} - x_i^{T_{pred}})^2 + (\hat{y}_i^{T_{pred}} - y_i^{T_{pred}})^2}$$

$$\textbf{Col-I} = \frac{1}{M} \sum_{i=1}^{M} \min(1, \sum_{j \neq i} \sum_{t=1}^{T_{pred}} [\|\hat{\mathbf{p}}_i^t, \hat{\mathbf{p}}_j^t\| < r_i + r_j])$$

$$\textbf{Col-II} = \frac{1}{M} \sum_{i=1}^{M} \min(1, \sum_{j \neq i} \sum_{t=1}^{T_{pred}} [\|\hat{\mathbf{p}}_i^t, \mathbf{p}_j^t\| < r_i + r_j])$$

où $[\cdot]$ représente le crochet d'Iverson, avec $[P]$ égal à 1 si l'énoncé P est vrai et 0 sinon et $\|\hat{\mathbf{p}}_i^t, \hat{\mathbf{p}}_j^t\|$ représente la distance euclidienne entre les positions prédites des piétons i et j au pas de temps t. Col-I mesure le pourcentage pour un ensemble de M prédictions où des collisions se produisent entre les trajectoires prédites d'un piéton et les trajectoires prédites de ses voisins, ce qui indique la fréquence à laquelle les prédictions du modèle entraînent des collisions potentielles. De même, Col-II calcule la proportion de scènes de prédiction où des collisions se produisent entre les trajectoires prédites du piéton principal et les trajectoires réelles de ses voisins, ce qui indique la fréquence des collisions entre les trajectoires prédites et les mouvements réels des autres piétons. Les valeurs de Col-I et Col-II varient en fonction du rayon du piéton ; nous avons choisi un rayon de $0,2$ m pour la représentation des piétons en nous basant sur l'estimation heuristique de la taille des piétons proposée par [Moussaïd et al., 2011].

Une cinquième et nouvelle métrique de collision à été proposée pour évaluer la gravité des collisions dans les trajectoires prédites des piétons est proposée. Elle calcule l'énergie moyenne (AE) consommée par le piéton principal i lorsqu'il interagit avec d'autres piétons à travers tous les pas de temps de prédiction. L'énergie moyenne des M scènes de prédiction est calculée comme suit :

$$\hat{E}(\tau) = \frac{k}{\tau^2 + \epsilon} e^{-\tau/\tau_0}$$

$$\textbf{AE} = \frac{1}{MT_{pred}} \sum_{i=1}^{M} \sum_{t=1}^{T_{pred}} \sum_{j \neq i} \hat{E}^t(\tau_{ij})$$

où $\epsilon = 0,01$ est une constante ajoutée pour éviter les valeurs extrêmes de l'énergie d'interaction $\hat{E}(\tau)$ lorsque TTC approche de zéro. Bien que d'autres mesures telles que Col-I et Col-II mesurent également les collisions, elles ne peuvent pas indiquer la gravité des collisions dans une scène, car Col-I et Col-II ne fournissent que des valeurs binaires : 1 pour les collisions et 0 pour l'absence de collisions. Par exemple, deux scènes prédites avec une collision et vingt collisions auraient toutes deux des valeurs Col-I de 1. À l'inverse, la métrique AE renvoie une

valeur continue de l'énergie moyenne qui augmente avec le nombre de collisions. Ainsi, une scène prédite avec vingt collisions aura une valeur AE plus élevée qu'une scène prédite avec une seule collision.

On entraîne TTC-SLSTM et Social-LSTM sur l'ensemble des jeux de données en utilisant pour paramètres 9 points pour les observations et 12 points pour les prédictions conformément à l'état de l'art [Korbmacher and Tordeux, 2022]. Pour les ensembles de données à faible densité, il prédit une période future de $4,8$ s sur la base des observations des $3,6$ s passés. Pour l'ensemble de données à haute densité , il prédit une période future de 4.0 s sur la base des observations des 3.0 s passés. Les modèles sont entraînés pendant 8 époques avec une taille de lot de 8, en utilisant l'optimiseur ADAM avec un taux d'apprentissage de $0,001$. Une stratégie de validation non croisée est appliquée, avec 70% des données utilisées pour l'apprentissage et 15% pour la validation et 15% pour le test. Tous les calculs ont été effectués sur un MacBook Pro M1 avec 32 Go de mémoire en utilisant PyTorch. De plus, on fait varier le paramètre λ selon 5 valeurs (0.1,0.25,0.5,1.0,2.0) pour évaluer l'impact du paramètre sur la performance de TTC-SLSTM.

Le tableau 4.5 présente les résultats obtenus sur les jeux de données de faible densité, et le tableau 4.6 présente les résultats pour les jeux de données de haute densité.

Concernant les faibles densités, on observe, pour l'ensemble des métriques, une amélioration des performances de TTC-SLSTM par rapport au modèle original. On observe que les meilleurs résultats sont obtenus avec des valeurs de λ élevées, suggerant qu'une valeur plus élevée de λ améliore les performances pour ces mesures de collision. Cependant, il faut toujours faire un compromis entre l'optimisation des mesures d'erreur de distance (ADE, FDE) et les mesures de collision (Col-I, Col-II, AE). Ici, la meilleure valeur pour λ est déterminée comme étant 1.0, ce qui permet d'améliorer les mesures ADE et Col-I.

Concernant les fortes densités, on observe une dégradation des performances pour TTC-SLSTM pour les métriques basées sur la distance, mais une amélioration des métriques basées sur les collisions. Ce résultat s'explique par le fait que le modèle apprend à mieux éviter les autres piétons produisant un écart à la trajectoire initiale observée. On constate que les valeurs faibles de permettent d'obtenir les meilleurs résultats et que des valeurs élevées de λ peuvent pénaliser excessivement le modèle, entraînant un impact négatif significatif sur les métriques de collision. Il n'est donc pas possible d'appliquer un λ unique à tous les ensembles de données, et la meilleure valeur de λ doit être définie en fonction des caractéristiques de chaque jeux de données, en particulier le niveau de densité. Pour ces jeux de données à haute densité, le meilleur λ est $0,5$, car cette valeur améliore considérablement les mesures de collision tout en maintenant une précision acceptable basée sur la distance.

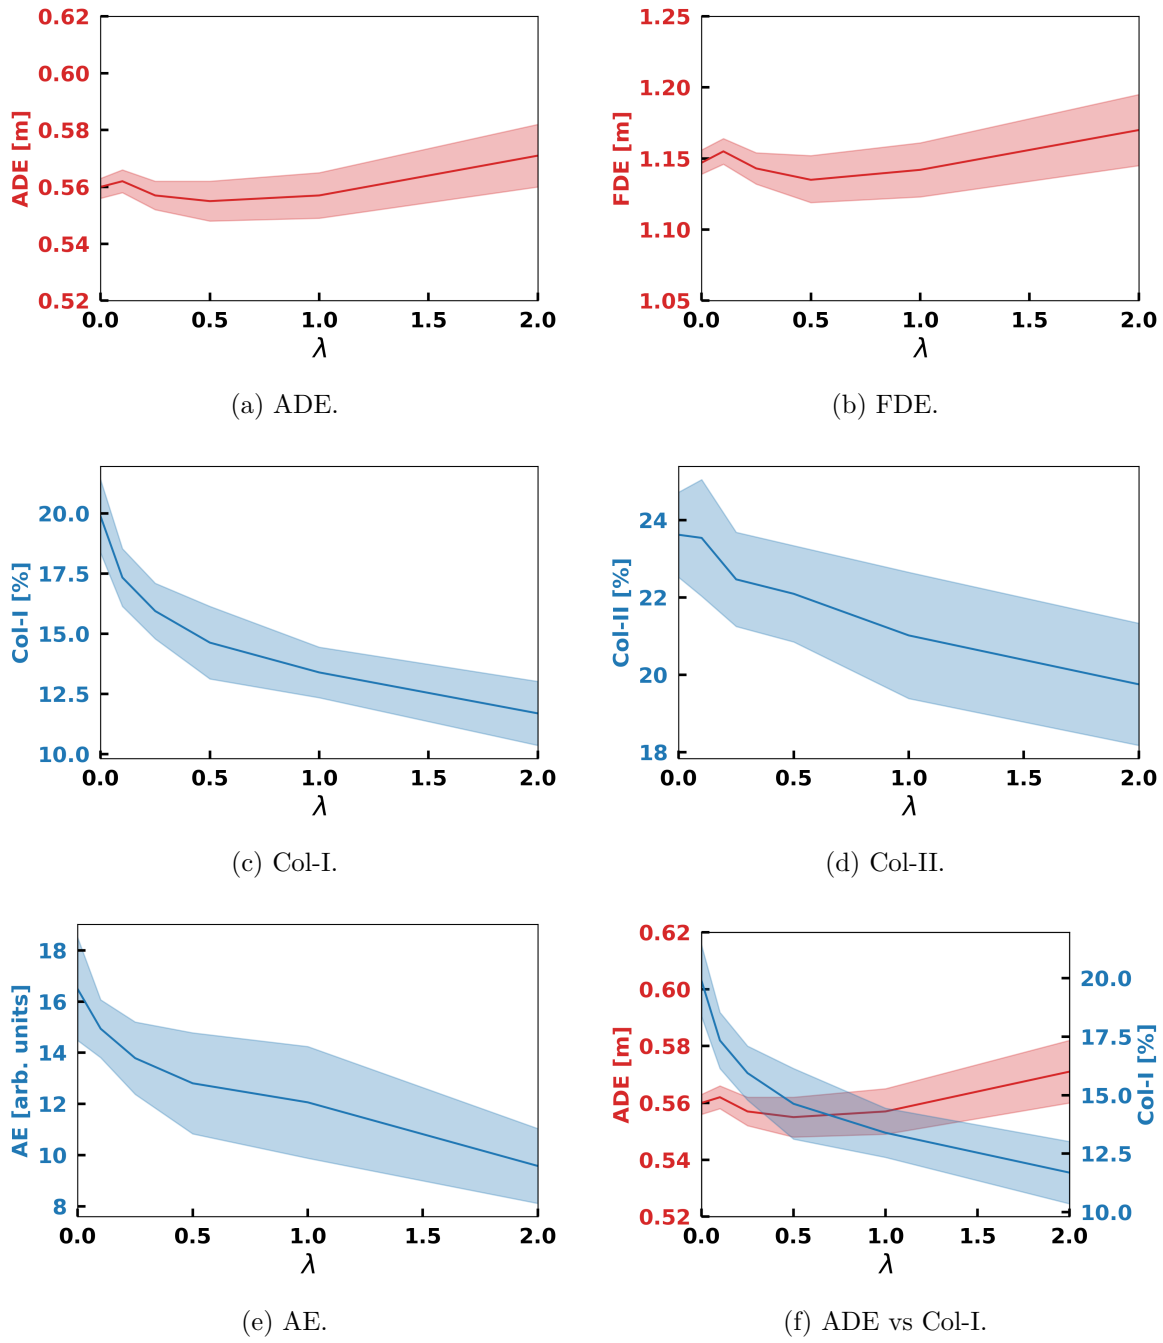
Les Figures 4.16 et 4.17 montrent la distribution moyenne des 5 métriques pour les différentes valeurs de λ. Les Figures 4.16f et 4.17f superposent les métriques ADE et Col-I pour les différentes valeurs de λ. Elle illustre le nécessaire compromis à trouver entre minimisation de la distance et minimisation du nombre de collisions, avec une sensibilité différente entre les jeux de données de faible densité et de haute densité.

TABLE 4.5 – Analyse comparative des performances de TTC-SLSTM sur les jeux de données de faible densité.

Metric	**Data**	**SLSTM**	**TTC-SLSTM**				
			λ=**0.1**	λ=**0.25**	λ=**0.5**	λ=**1.0**	λ=**2.0**
ADE	ETH	0.677	0.681	**0.676**	0.678	0.689	0.706
	HOTEL	0.484	0.484	0.477	0.473	0.473	**0.461**
	ZARA01	0.500	0.505	0.493	0.486	**0.481**	0.491
	ZARA02	**0.438**	**0.438**	0.440	0.439	0.439	0.469
	UCY	0.699	0.702	**0.697**	0.698	0.704	0.728
	Average	0.560	0.562	0.557	**0.555**	0.557	0.571
FDE	ETH	1.302	1.309	**1.296**	1.299	1.323	1.371
	HOTEL	0.882	0.890	0.878	0.865	0.875	**0.862**
	ZARA01	1.049	1.065	1.042	1.017	**1.001**	1.007
	ZARA02	0.949	0.952	0.956	**0.948**	**0.948**	1.004
	UCY	1.555	1.558	**1.543**	1.548	1.562	1.605
	Average	1.147	1.155	1.143	**1.135**	1.142	1.170
Col-I	ETH	24.568	22.828	21.661	20.218	19.855	**15.505**
	HOTEL	12.145	11.430	10.130	7.379	**4.048**	4.522
	ZARA01	17.381	9.285	5.972	5.476	4.998	**3.811**
	ZARA02	17.978	16.822	16.752	16.126	16.281	**14.814**
	UCY	27.367	26.327	25.206	23.957	21.779	**19.791**
	Average	19.888	17.338	15.944	14.631	13.392	**11.689**
Col-II	ETH	28.555	29.999	29.566	28.914	28.914	**26.525**
	HOTEL	17.857	16.668	14.287	13.336	**11.667**	11.668
	ZARA01	30.237	29.763	28.311	25.713	21.666	**17.143**
	ZARA02	19.290	**19.289**	19.612	20.060	20.678	19.752
	UCY	22.158	21.970	**20.555**	22.442	22.159	23.673
	Average	23.619	23.538	22.466	22.093	21.017	**19.752**
AE	ETH	20.605	17.509	17.544	13.631	13.081	**9.377**
	HOTEL	11.357	11.168	9.954	9.543	6.035	**3.640**
	ZARA01	10.164	6.387	3.925	**3.496**	**3.496**	6.502
	ZARA02	23.186	23.456	23.036	24.387	23.943	**16.307**
	UCY	17.126	16.177	14.492	12.982	13.768	**12.077**
	Average	16.488	14.939	13.790	12.808	12.065	**9.581**

TABLE 4.6 – Analyse comparative des performances de TTC-SLSTM sur les jeux de données de haute densité.

Metric	**Data**	**SLSTM**	**TTC-SLSTM**					
			λ=**0.1**	λ=**0.25**	λ=**0.5**	λ=**1.0**	λ=**1.5**	λ=**2.0**
ADE	TopView_2D	0.440	0.442	**0.438**	0.449	0.451	0.487	0.545
	TopView_2E	**0.419**	0.434	0.426	0.440	0.455	0.481	0.549
	TopView_2F	**0.389**	0.392	0.391	0.400	0.42	0.434	0.482
	Average	**0.416**	0.423	0.418	0.430	0.442	0.467	0.525
FDE	TopView_2D	0.897	0.900	**0.892**	0.910	0.894	0.920	0.977
	TopView_2E	**0.874**	0.900	0.893	0.904	0.940	0.972	1.045
	TopView_2F	**0.758**	**0.758**	0.762	0.781	0.816	0.823	0.867
	Average	**0.843**	0.853	0.849	0.865	0.883	0.905	0.963
Col-I	TopView_2D	42.134	41.252	38.139	**35.512**	37.448	45.833	55.082
	TopView_2E	30.474	31.095	27.240	**22.512**	29.602	34.203	52.612
	TopView_2F	19.339	17.295	16.349	**16.035**	16.822	18.709	29.718
	Average	30.649	29.881	27.243	**24.686**	27.957	32.915	45.804
Col-II	TopView_2D	55.066	54.668	53.786	53.008	**52.801**	56.827	62.898
	TopView_2E	50.125	50.373	48.011	**47.017**	49.128	53.857	63.432
	TopView_2F	32.390	33.334	30.976	32.706	**30.819**	32.705	39.938
	Average	45.860	46.125	44.258	**44.244**	44.249	47.796	55.423
AE	TopView_2D	26.000	25.751	23.824	**23.136**	23.954	30.297	31.893
	TopView_2E	22.539	21.731	19.749	**18.185**	18.505	21.899	29.613
	TopView_2F	19.520	16.282	16.196	13.473	**12.404**	16.252	27.548
	Average	22.686	21.255	19.923	**18.265**	18.288	22.816	29.685

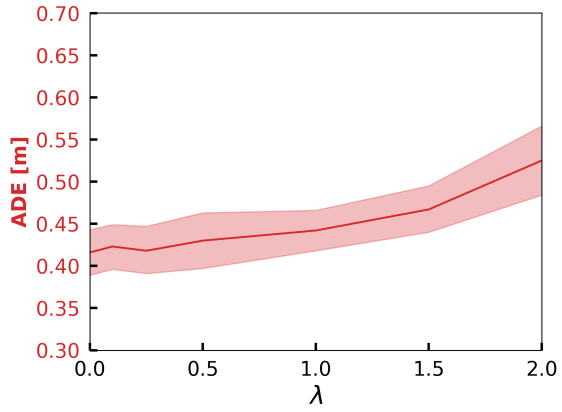


(a) ADE. (b) FDE.

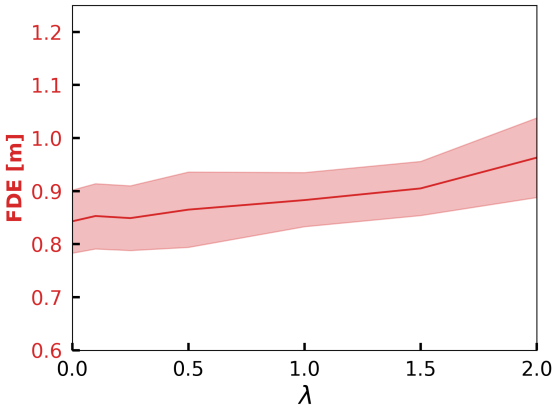
(c) Col-I. (d) Col-II.

(e) AE. (f) ADE vs Col-I.

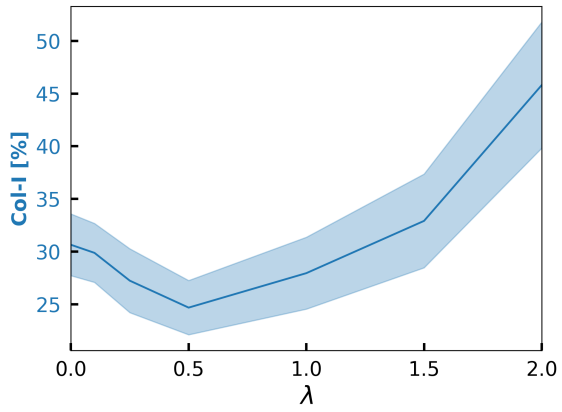
FIGURE 4.16 – Résultats d'évaluation pour différentes valeurs de λ sur les jeux de données à faible densité [Dang et al., 2024c].



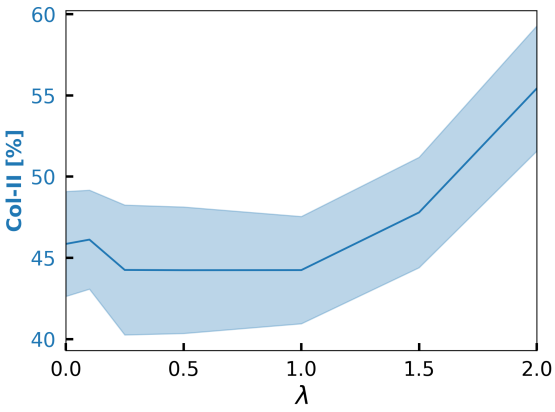
(a) ADE.



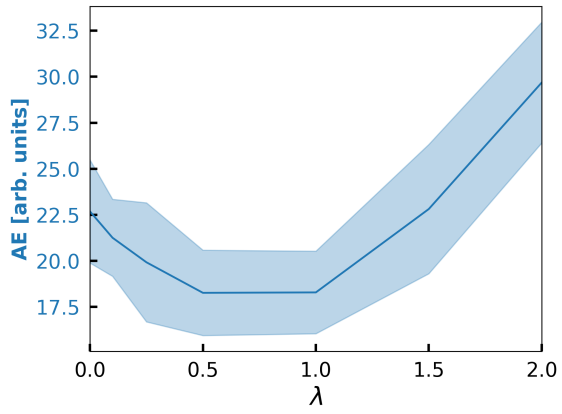
(b) FDE.



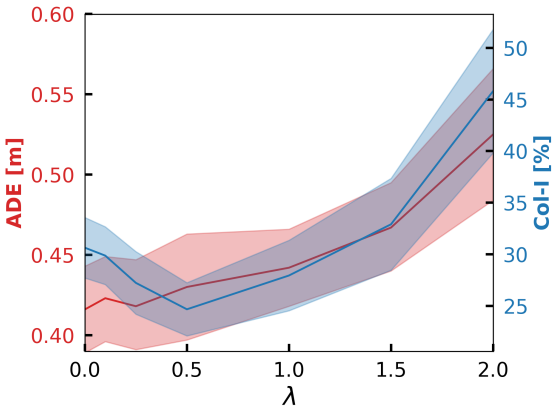
(c) Col-I.



(d) Col-II.



(e) AE.



(f) ADE vs Col-I.

FIGURE 4.17 – Résultats d'évaluation pour différentes valeurs de λ sur les jeux de données à haute densité [Dang et al., 2024c].

4.4 Conclusion et perspectives

Mes contributions à la simulation à base d'agent décrite dans ce chapitre ont pour principale application la simulation de foules denses. Deux approches distinctes à la construction de modèles ont été étudiées.

La première, dirigée par les modèles, propose de construire un ensemble de règles contrôlant le comportement des agents et leurs interactions en s'appuyant sur des modèles théoriques dérivés de connaissances expertes, d'hypothèses ou de principes établis (par ex : le modèle de force social SFM). L'objectif est de comprendre les dynamiques sous-jacentes d'un système en testant des hypothèses sous la forme de nouveaux scénarios. La validation de ces systèmes repose sur différentes stratégies telles que l'échantillonnage, le jeu de rôle avec des experts, ou l'analyse causale [Collins et al., 2024]. Dans notre cas, nous avons utilisé un processus de calibration et l'analyse de sensibilité pour étudier les sorties de notre modèle et les comparer à la donnée de terrain.

La seconde approche, dirigée par les données, propose de dériver les comportements des agents directement ou indirectement de données collectées, souvent via des techniques comme le machine learning ou l'analyse statistique. L'objectif est la reproduction fidèle du comportement observé par la prédiction des comportements futurs. Ainsi, les données de terrains sont le point d'entrée du processus de modélisation. Le modèle inféré est ensuite entraîné via la minimisation d'une fonction et sa validation repose sur l'évaluation de métriques de qualités génériques ou spécifiques au domaine. L'usage de techniques d'analyse de sensibilité ou d'explicabilité (par exemple SHAPE ou LIME) peut permettre d'extraire des comportements spécifiques du système. Dans notre cas, nous avons montré l'existence d'un point de bascule sur la fonction de perte qui permet de contrôler l'équilibre entre similarité de la trajectoire et diminution des collisions.

Mes deux contributions sont :

— **HyPedSim** : un cadre pour la simulation de foules denses où un modèle de simulation est associé à différentes zones de l'espace en fonction de la densité. Le couplage entre les modèles est permis par l'introduction de paramètres de transition qui peuvent être calibrés.

— **TTC-SLSTM** : une extension de Social-LSTM, une approche d'apprentissage profond pour prédire les trajectoires de piétons à partir de leur environnement physique et social. La contribution introduit un terme spécifique pour prénaliser le risque collisions dans la fonction grâce à un facteur de balancement λ. Une analyse de sensibilité a permis d'étudier l'influence du paramètre λ nous informant que sa valeur impacte différemment les résultats selon si la densité est faible ou élevée.

A partir des résultats et de l'expérience acquise sur ces applications, je dégage trois pistes de recherche. Deux de ces pistes font directement suite à ces travaux, la troisième est le projet de recherche que présenté dans le chapitre 5.

Perspectives pour HyPedSim : Les travaux sur HyPedSim permettent d'illustrer l'intérêt du couplage de modèles pour le passage à l'échelle des simulations à base d'agents : en couplant des modèles de granularités différentes, on parvient à réduire le temps de cal-

cul tout en conservant la dynamique du phénomène observé. Cependant, HyPedSim présente deux limitations qui ouvrent des perspectives de poursuite de travaux. La première porte sur la caractérisation des différentes zones qui sont, à l'heure actuelle, seulement définies par l'utilisateur. Bien que cette approche soit pertinente dans le cas de la fête des lumières, qui correspond à un environnement régulé où les différentes zones d'accès ont des flux de piétons bien différenciés, ce processus pourrait être difficile à caractériser dans d'autres situations. Ainsi, une approche plus dynamique du découpage des zones en utilisant la densité observée pourrait être intéressante à observer. Une approche reposant sur le clustering dynamique spatial (par exemple en utilisant DBSCAN) en se basant sur la densité observée des piétons pourrait permettre de dynamiquement ajuster les différentes zones et modèles associés. Ce couplage dynamique nécessiterait cependant d'introduire des mécanismes d'agrégation et de désagrégation des agents entre les modèles pour permettre leur transfert dynamique d'un modèle vers l'autre. Une seconde limitation porte sur la généricité de l'approche qui n'est appliquée ici qu'à la simulation de foule. Cependant, il serait possible de généraliser les notions de zones, de fonction de transition et de fonction d'agrégation/désagrégation dans un formalisme qui faciliterait son utilisation par les modélisateurs. Des travaux en ce sens ont déjà été réalisés [Huynh et al., 2017] et il serait intéressant de poursuivre dans cette direction.

Perspectives pour TTC-SLSTM : TTC-SLSTM propose l'introduction d'un nouveau terme de collision dans la fonction de perte. L'analyse de sensibilité a permis de mettre en évidence l'influence du paramètre de pondération λ sur la précision du modèle. En effet, une valeur faible de λ est pertinente dans les modèles à faible densité, alors qu'une valeur plus élevée est pertinente pour les modèles à forte densité. Nous avons évalué l'impact de ce terme sur l'architecture Social-LSTM. Ainsi, une première perspective serait d'étudier l'impact de ce terme sur d'autres architectures de réseaux de neurones pour voir si on retrouve le même point d'équilibre entre qualité de la trajectoire et réduction du nombre de collisions. Notre contribution s'est principalement concentrée sur l'amélioration de l'apprentissage au travers d'une meilleure fonction de perte. Une seconde perspective de recherche pour améliorer la qualité des modèles de prédiction à base de réseaux de neurones est d'intégrer davantage de caractéristiques qui regroupent des informations contextuelles dans leurs entrées. Les LSTM actuels n'utilisent généralement que les trajectoires des piétons comme données d'entrée. L'ajout de nouvelles caractéristiques aux données d'entrée, telles que le temps avant collision [Dang et al., 2024d] ou des informations sur la structure spatiale de l'environnement pourrait améliorer les performances. Enfin, l'intégration de modèles de prédiction de trajectoire piétons au sein de simulation à base d'agents pourrait représenter une piste intéresante pour réduire la complexité de calcul des modèles. Ainsi, on pourrait intégrer au sein du contrôleur d'un agent un modèle pré-entraîné pour générer des trajectoires réalistes. On peut voir ici un lien entre HyPedSim et TTC-LSTM qu'il reste à explorer.

Perspectives pour la calibration et l'analyse de sensibilité des systèmes : l'approche dirigée par la donnée et l'approche dirigée par les modèles peuvent sembler deux processus distincts où la donnée terrain n'intervient pas à la même étape. Cependant, on a vu dans les deux contributions que les deux approches reposent sur des outils similaires pour

permettre la calibration et l'analyse de sensibilité de ces systèmes. La calibration d'un modèle à base d'agents et l'analyse de sensibilité d'un modèle de machine learning partagent un objectif commun : affiner et comprendre le comportement du modèle en explorant l'impact de ses paramètres. Dans le cas de la calibration d'un modèle à base d'agents, il s'agit d'ajuster les valeurs des paramètres afin que les comportements simulés par les agents reflètent au mieux les observations du monde réel ou atteignent des objectifs préétablis. En parallèle, l'analyse de sensibilité dans un modèle de machine learning vise à évaluer l'influence de chaque paramètre ou caractéristique d'entrée sur les prédictions du modèle, permettant ainsi d'identifier les éléments critiques pour le résultat final. Ces deux processus jouent un rôle dans l'amélioration de la robustesse, de l'interprétabilité et de la fiabilité des modèles, qu'il s'agisse de simulations complexes ou de systèmes d'apprentissage automatique, tout en fournissant des informations précieuses pour la prise de décisions et les ajustements futurs. Il m'apparaît intéressant alors de voir comment les outils de l'apprentissage artificiel peuvent être utilisés pour la simulation à base d'agents et, réciproquement, comment les outils d'analyse de sensibilité des simulations peuvent aider à comprendre les modèles d'apprentissage artificiel. Cela ouvre de nouvelles perspectives d'usage de l'apprentissage machine pour la simulation à base d'agents que je détaille dans mon projet de recherche. Notamment, par l'usage de modèles de substitution (*surrogate models*) [Angione et al., 2022] pour approximer le comportement d'un modèle à base d'agents à des fins de calibration.

Dans ce chapitre, mes travaux de recherche appartenant au contexte de la simulation multi-agent. Au travers de deux contributions, HyPedSim et TTC-SLSTM, j'ai montré l'existence de liens entre la collecte de données présentée dans le chapitre 2, la construction de modèles du chapitre 3 et la simulation à base d'agents. C'est donc sur ces expériences que je propose dans le chapitre suivant, un projet de recherche original qui fait le lien entre ces trois problématiques.

Chapitre 5

Conclusion générale et perspectives

Contents

5.1 Conclusion générale 128
5.2 Projets de recherche et perspectives 130
5.2.1 Explorer la simulation dirigée par la donnée 130
5.2.2 Modéliser l'impact de la ville sur les usages : explorer le rôle des affordances urbaines 131
5.2.3 Développer l'explicabilité locale des comportements des agents . . . 132
5.2.4 Etudier les apports de l'apprentissage machine à la simulation à base d'agents 134

5.1 Conclusion générale

Ce mémoire présente une synthèse structurée de mes travaux de recherche selon trois axes : la collecte de données (Chapitre 2), la construction de modèles par apprentissage machine (Chapitre 3) et la simulation à base d'agents (Chapitre 4). Au travers d'applications liées à la ville et à ses mobilités, j'aborde des problématiques et verrous liés aux systèmes complexes : observabilité partielle des systèmes, non-linéarité et passage à l'échelle.

Dans le Chapitre 2, je positionne des travaux dans le domaine de la ville intelligente et de l'IoT. Une expérimentation in situ dans le cadre du projet "Liverpool Smart Pedestrian" (Section 2.2.1) a permis d'aborder la problématique de l'observation de l'impact de la mobilité sur la qualité de l'air. Un dispositif d'analyse de flux vidéos pour le comptage de trafic (Section 2.3) ainsi qu'un dispositif d'analyse de la qualité d'air (PM2.5) (Section 2.4) ont été conçus et expérimentés. Ces travaux me permettent de dégager de nouvelle perspectives de recherche autour de la question "Comment des données observant un phénomène à l'échelle locale peuvent-elles nous informer sur des phénomènes macroscopiques ?" (Section 2.5).

Dans le Chapitre 3, je présente mes travaux liés au domaine de la construction de modèles par apprentissage artificiel. Dans le cadre de l'apprentissage ensembliste (Section 3.2.1), j'ai proposé et évalué un modèle d'apprentissage ensembliste coopératif (Section 3.2.2). Les résultats de l'étude de ce modèle (Section 3.2.3) montre l'émergence de frontières de décision complexes entre les agents. J'ai proposé de nouvelles métriques d'explicabilité permettant d'étudier le comportement des fonctions sous-jacentes. Dans un second temps (Section 3.3), j'ai proposé et évalué un pipeline de traitement pour la classification des modes de transport. La prise en compte de features caractérisant les écarts temporels entre les données permet une amélioration de la performance de classification par rapport à l'état de l'art. L'apport de ces nouvelles features est évalué par une analyse comparative des performances avec et sans ces features, et par une analyse d'importance en utilisant l'importance de GINI sur des classifieurs Random Forest. Ces travaux ont permis la production d'un jeu de données open source de traces de mobilité. La Section 3.4 présente des perspectives à ces travaux, notamment par la poursuite des travaux sur l'explicabilité du comportement des agents contextes et la construction automatique de modèles à partir de traces d'utilisateurs.

Enfin, le Chapitre 4 présente des contributions à la simulation à base d'agents. La Section 4.2 positionne les travaux dans le domaine de la simulation de foule. Deux contributions à l'amélioration de la simulation des foules denses sont présentées. Ces deux contributions ont pour cas d'étude la Fête des Lumières à Lyon (Section 4.3.1). La première, HyPedSim (Section 4.3.2), aborde la problématique du couplage de modèles pour permettre la simulation de foules à différentes densités. Cette simulation est calibrée sur la Fête des Lumières et son passage à l'échelle est étudié pour montrer l'existence d'un équilibre nécessaire entre qualité du modèle et temps de calcul. La seconde contribution, TTC-SLSTM (Section 4.3.3), propose une approche d'apprentissage profond pour améliorer la qualité de la prédiction des trajectoires de piétons en foules denses. La nouveauté repose sur l'intégration d'un terme de collision dans la fonction de perte du réseau. L'analyse de sensibilité des performances de l'algorithme montre qu'il est possible de trouver, en fonction de la densité, une valeur d'équilibre entre réalisme de

la trajectoire et minimisation des collisions. La Section 4.4 conclut en dégageant de nouvelles perspectives. Je m'intéresse notamment à l'usage des outils de l'apprentissage artificiel pour la simulation à base d'agents et, réciproquement, comment les outils d'analyse de sensibilité des simulations peuvent nous aider à comprendre les modèles d'apprentissage artificiel, ouvrant de nouvelles perspectives d'usage de l'apprentissage machine pour la simulation agent.

Ce mémoire d'Habilitation à Diriger des Recherches a présenté une synthèse structurée de mes travaux de recherche articulés autour de trois axes fondamentaux pour l'étude des systèmes socio-techniques complexes, en particulier dans le contexte de la ville intelligente et de la mobilité : l'observation des phénomènes urbains, la construction de modèles par apprentissage artificiel et la simulation à base d'agents.

Plusieurs verrous scientifiques ont été adressés à travers ces travaux. Premièrement, la question de l'observabilité partielle des systèmes urbains a été explorée, cherchant à comprendre comment des données collectées localement peuvent informer sur des phénomènes macroscopiques. Deuxièmement, face à la complexité des interactions dans ces systèmes, l'accent a été mis sur l'utilisation de l'apprentissage artificiel pour construire des modèles sans spécification *a priori* exhaustive. Troisièmement, la modélisation et la simulation de phénomènes urbains complexes, notamment les foules denses, ont soulevé des défis liés au passage à l'échelle et au couplage de modèles de granularités différentes. Quatrièmement, l'amélioration du réalisme des prédictions de trajectoires de piétons en environnements denses, en particulier la prise en compte des collisions, a constitué un verrou important. Enfin, la nécessité d'établir un lien cohérent entre la collecte de données, la construction de modèles et la simulation pour une meilleure compréhension et prédiction des systèmes urbains a été un fil conducteur majeur.

En réponse à ces verrous, ce mémoire présente plusieurs contributions scientifiques :

— Dans le domaine de l'**observation des phénomènes urbains**, des dispositifs basés sur l'Internet des Objets (IoT) ont été conçus et déployés. Le projet "Liverpool Smart Pedestrian" a permis de développer un dispositif d'analyse de flux vidéo pour le comptage de trafic et un capteur pour l'analyse de la qualité de l'air (PM2.5). Ces travaux ont souligné l'importance du contexte des données et la nécessité de données ouvertes pour l'analyse des dynamiques urbaines.

— Concernant la **construction de modèles par apprentissage artificiel**, deux contributions majeures ont été apportées. Premièrement, un modèle d'apprentissage ensembliste coopératif basé sur l'auto-organisation d'agents contextes a été développé et évalué, proposant de nouvelles métriques d'explicabilité. Deuxièmement, un pipeline de traitement pour la classification automatique des modes de transport à partir de traces GNSS et d'accéléromètre a été mis en œuvre, en mettant en évidence l'apport des écarts temporels comme features et en produisant un nouveau jeu de données en accès libre (OCC-TMD).

— Dans le domaine de la **simulation à base d'agents**, des contributions à la simulation de foules denses ont été réalisées. Le modèle HyPedSim a été proposé pour coupler des modèles de granularités différentes en fonction de la densité, appliqué et calibré

sur le cas d'étude de la Fête des Lumières à Lyon. De plus, le modèle TTC-SLSTM a amélioré la prédiction de trajectoires de piétons en intégrant un terme de collision dans la fonction de perte d'un réseau de neurones profond.

— De manière transversale, ce mémoire a mis en lumière l'importance d'une **approche intégrée** qui combine la collecte de données in situ, l'utilisation de l'apprentissage artificiel pour l'analyse et la construction de modèles, et la simulation pour la compréhension et la prédiction des dynamiques urbaines. L'analyse de sensibilité et l'explicabilité ont été présentées comme des outils pour qualifier la qualité des modèles et faciliter la prise de décision.

Ainsi, les travaux présentés dans cette HDR ont contribué à l'avancement des connaissances et des méthodes pour l'étude des systèmes socio-techniques complexes, en proposant une nouvelle approche pour l'observation, la modélisation et la simulation des phénomènes urbains. La prochaine section détaille mes nouveaux axes de recherche.

5.2 Projets de recherche et perspectives

Les travaux présentés dans cette habilitation permettent de proposer un projet de recherche autour de l'étude des systèmes socio-techniques complexes. La démarche que je vais adopter part de l'observation locale de phénomènes au travers de données de capteurs ou de traces d'utilisateurs et intègre ces données au sein de modèles, qu'il s'agisse de modèles prédictifs ou de simulation. L'analyse de sensibilité et l'explicabilité permettent d'étudier l'influence des données sur les modèles produits. Ainsi, je peux utiliser ces approches pour qualifier la qualité du modèle et aider à la prise de décision. Je propose un projet de recherche qui s'appuie sur cette démarche et l'expérience acquise au travers de quatre axes de recherche :

— Explorer la simulation dirigée par la donnée - Section 5.2.1
— Modéliser l'impact de la ville sur les usages : explorer le rôle des affordances urbaines - Section 5.2.2
— Développer l'explicabilité locale des comportement des agents - Section 5.2.3
— Etudier les apports de l'apprentissage machine à la simulation à base d'agents - Section 5.2.4

5.2.1 Explorer la simulation dirigée par la donnée

Les différents travaux que j'ai présentés ont pour domaine d'application la ville et ses mobilités. La collecte de données locales, que ce soit par le biais de capteurs, de traces utilisateurs, ou par le biais de véhicules connectés permet de compléter les informations statistiques des enquêtes ménage déplacement. La disponibilité de ces données rend possible une approche dirigée par la donnée pour la simulation de mobilité [Chen et al., 2024]. Les modèles de simulation à base d'agents utilisant des chaînes d'activité se sont développés comme un outil intéressant pour modéliser les activités humaines [Bastarianto et al., 2023]. Cependant, les approches de modélisation nécessitent l'usage de données statistiques pour produire des

populations synthétiques [Prédhumeau and Manley, 2023]. La disponibilité de ces nouvelles sources de données ouvre la voie vers une méthode où les simulations sont directement alimentées et calibrées par des données empiriques. Pour ce faire, je vois deux axes de recherche à poursuivre : l'amélioration des techniques d'assimilation de données, pour intégrer en temps réel des données hétérogènes et calibrer les modèles de manière dynamique et faciliter le passage à l'échelle des simulations en s'appuyant sur l'utilisation d'émulateurs.

En effet l'assimilation de données dans le cadre des simulations à base d'agents en temps réel peut être interprétée comme un processus d'optimisation dynamique en continu [Tang and Malleson, 2022]. Contrairement à la calibration, qui est une étape réalisée offline et qui ajuste les paramètres d'un modèle en se basant sur des données préexistantes, l'assimilation de données opère dans un contexte où les informations sont intégrées et traitées au fil de leur acquisition. Cela implique une mise à jour instantanée des états du modèle afin de capturer au mieux les dynamiques en temps réel. Ce processus nécessite de concevoir de nouveaux algorithmes capables de gérer efficacement l'afflux constant de données, tout en réduisant les coûts computationnels pour maintenir une réactivité opérationnelle. Par conséquent, l'approche diffère non seulement par sa temporalité, mais aussi par les exigences qu'elle impose en termes d'architecture algorithmique et de robustesse aux incertitudes inhérentes aux flux de données en temps réel.

Le passage à l'échelle dans les simulations à base d'agents repose sur la capacité à modéliser et simuler un grand nombre d'individus, chacun suivant des dynamiques et comportements spécifiques, ce qui engendre une explosion des besoins en ressources computationnelles. Cette complexité devient particulièrement problématique lorsque l'on tente de représenter des systèmes à grande échelle, comme les mobilités dans des métropoles entières ou des populations vastes et hétérogènes. Les émulateurs, ou surrogate models, offrent une solution prometteuse en réduisant ces exigences computationnelles [Kieu et al., 2024]. Ces modèles agissent comme des approximations rapides des simulations à base d'agents complexes, capturant leurs principales dynamiques tout en diminuant significativement les temps de calcul. Je souhaite donc explorer l'usage des émulateurs dans la simulation à base d'agents. Il est possible d'utiliser des approches d'apprentissage artificiel pour entraîner des systèmes à imiter des comportements observés, réduisant par ce biais le besoin de construction et de calibration des modèles. Cet aspect est discuté dans la section 5.2.4.

5.2.2 Modéliser l'impact de la ville sur les usages : explorer le rôle des affordances urbaines

En m'intéressant à la ville et ses mobilités, j'ai été amené à étudier la relation qui existe entre la ville et ses usagers. Dans les perspectives qui découlent de la thèse de Thibault Fourez (Section 3.4), nous avions commencé à étudier la relation entre le motif du déplacement et les lieux d'origine et de destination et à proposer les bases d'un modèle d'apprentissage artificiel pour l'inférence de motifs. De même, dans le cadre de l'ANR-Switch, j'ai étudié les modèles agents à base de chaînes d'activités construits sur des populations synthétiques. Les discussions avec les géographes et urbanistes impliqués dans ce projet m'ont amené à questionner la

manière dont la configuration de l'espace urbain influence les choix, et les potentialités de déplacements des individus.

En effet, les espaces urbains sont traditionnellement perçus, dans de nombreuses approches de simulation, comme des supports neutres où les activités humaines se déploient. Cette conception repose sur l'idée que les individus projettent librement leurs actions sur un espace préexistant. Cependant, cette perspective peut occulter une dimension essentielle : la configuration urbaine influence profondément les choix, comportements et pratiques. Le concept d'affordance urbaine [Lanng and Jensen, 2022] propose que les objets urbains portent des potentialités d'actions, et que cette la perception de cette potentialité d'action diffère selon l'expérience et la culture de chaque individu. Ce concept émane de celui d'affordance proposé par [Gibson, 1977] sous la forme : "Les affordances de l'environnement sont ce qu'il offre à l'animal, ce qu'il lui fournit ou lui procure, que ce soit en bien ou en mal".

Les simulations de mobilité à base d'agents, centrées sur une modélisation des activités, négligent parfois le rôle actif de l'espace comme acteur structurant. Comment les caractéristiques de la ville, en tant qu'agencement matériel et symbolique, génèrent-elles des opportunités ou des contraintes pour les usagers ? En quoi les affordances proposées par l'environnement influencent-elles les comportements collectifs et individuels ?

Je propose d'explorer et de réévaluer les approches de simulation urbaine pour y intégrer une prise en compte des affordances offertes par l'espace urbain. L'objectif est de permettre le développement de simulations intégrant les affordances pour tester leur influence sur les comportements des usagers, et ainsi permettre le développement de scénario de type "what-if". Ce projet est celui de la thèse de E. Ceuille, que je co-dirige actuellement avec B. Gaudou et M. Predhumeau. Cet axe de recherche vise à proposer un cadre théorique enrichi pour les simulations urbaines, en proposant des outils et méthodes pour intégrer les affordances lors de la description de l'environnement et dans la prise de décision des agents. Ces outils pourraient alors servir à émettre des recommandations pour concevoir des environnements urbains inclusifs et flexibles, favorisant la diversité des usages. Des résultats initiaux de cette approche ont été proposés dans [Doussin et al., 2022].

5.2.3 Développer l'explicabilité locale des comportements des agents

Les récentes années ont vu l'émergence de nouveaux travaux et outils pour aborder la question de l'explicabilité dans l'apprentissage artificiel [Molnar et al., 2020]. Cela reflète un besoin croissant de comprendre et de justifier les prédictions produites par des modèles souvent perçus comme des "boîtes noires". Parmi les approches notables, SHapley Additive exPlanations (SHAP) [Lundberg and Lee, 2017] offre une perspective globale en attribuant à chaque *feature* une contribution précise à la prédiction, selon une approche basée sur la théorie des jeux. En testant successivement différentes variations sur les paramètres d'entrée du modèle, on peut estimer l'influence moyenne de chaque valeur sur les sorties. SHAP fournit une vue d'ensemble des contributions des variables d'entrée sur toutes les prédictions du modèle. Il attribue à chaque caractéristique une "valeur de Shapley", qui représente son impact moyen sur les prédictions, en tenant compte de toutes les combinaisons possibles de variables. Cette

analyse exhaustive permet de comprendre le rôle global de chaque caractéristique, indépendamment d'un exemple spécifique. C'est pourquoi SHAP est souvent utilisé pour des analyses à grande échelle ou pour identifier les tendances générales dans les modèles.

En revanche, Local Interpretable Model-agnostic Explanations (LIME) [Ribeiro et al., 2016] met l'accent sur une explicabilité locale, en se concentrant sur les décisions d'une prédiction individuelle du modèle grâce à des approximations simples. Un aspect particulièrement intéressant de LIME réside dans son utilisation de modèles (white-box models) dits surrogates (ou modèles de substitution) pour capturer le comportement local du modèle complexe. Cela permet d'expliquer pourquoi le modèle a pris une décision spécifique pour un cas donné, sans nécessairement généraliser ces explications à l'ensemble des données.

Il est intéressant d'établir un parallèle entre LIME et le système d'apprentissage par agent contextes (Section 3.2). En effet, les agents contexte reposent sur l'utilisation de modèles locaux qui approximent localement le comportement de la fonction cible. En utilisant des modèles boîte blanche (régression linéaire, arbre de décision, etc.), un agent contexte peut nativement fournir une explicabilité locale de sa prédiction. De même, par les mécanismes d'activation mis en place pour sélectionner les agents contexte voisins, il est possible d'observer les différents modèles locaux et d'étudier si les modèles proposent une explicabilité locale similaire ou non. Les travaux initiaux que j'ai présentés dans cette HDR ([Blanco-Volle et al., 2024a]) ont permis de dégager de nouvelles métriques d'explicabilité liées au comportement auto-organisateur des agents contextes. Mais il serait intéressant d'explorer l'usage des agents contextes comme mécanisme d'explicabilité, et d'inclure dans notre approche des éléments issus de la théorie des jeux en s'insiprant de LIME et SHAP.

Au-delà de l'explicabilité des systèmes, je vois dans l'étude du comportement des algorithmes d'apprentissage un moyen d'extraire de l'information sur la nature du système cible. Pourquoi un algorithme parvient-il ou non à apprendre une fonction cible, et qu'est-ce que les performances du comportement de l'algorithme peuvent nous dire sur la nature de cette fonction cible ? Ces questions font l'objet de deux thèses industrielles en cours.

La première est celle de C. Blanco-Volle au sein de l'entreprise Continentale (Thèse CIFRE), que je co-encadre avec S. Combette et M-P. Gleizes, et qui s'intéresse à la recommandation de vitesse dans les véhicules connectés. La recommandation de vitesse peut être abordée comme un processus de contrôle où l'on souhaite optimiser un ensemble de critères (vitesse, sécurité, confort, énergie...). Le Model Predictive Control (MPC) [Schwenzer et al., 2021], ou commande prédictive, est une méthode avancée de contrôle utilisée pour gérer des systèmes dynamiques complexes. Son principe repose sur l'utilisation d'un modèle mathématique du système pour prédire son comportement futur sur un horizon temporel donné. À chaque étape, le MPC optimise une fonction de coût (par exemple, minimiser l'écart par rapport à une trajectoire cible ou réduire la consommation d'énergie) tout en respectant les contraintes du système, comme les limites des actionneurs ou les conditions de sécurité. Une fois les commandes optimales calculées, seule la première action est appliquée, et le processus est répété à l'étape suivante, ce qui est connu sous le nom d'horizon glissant. Dans cette thèse, on souhaite étudier si le modèle mathématique peut être remplacé par un modèle prédictif à base

d'agents contextes et si des métriques d'explicabilité peuvent être utilisées pour à la fois garantir le comportement prédictif du modèle, mais aussi améliorer le processus d'optimisation en fournissant une quantification de l'erreur dans la prédiction des modèles.

La seconde thèse est celle de J. Levy au sein de l'entreprise Soben (Thèse CIFRE) qui s'intéresse à la détection d'anomalies explicables au sein de robots mobiles. La détection d'anomalies en robotique est un domaine qui s'intéresse à l'étude et à la modélisation des comportements d'un système pour détecter ou prédire des comportements déviants. Elle consiste à identifier les comportements ou les situations inhabituelles pouvant indiquer des pannes potentielles, des erreurs dans les capteurs ou des perturbations dans l'environnement. Cependant, les modèles utilisés pour détecter ces anomalies sont souvent complexes, en particulier lorsque l'apprentissage artificiel est impliqué. L'explicabilité des modèles présente un intérêt en permettant non seulement aux ingénieurs de comprendre pourquoi une anomalie a été signalée, mais également d'identifier les éléments caractéristiques qui peuvent facilité la reprise de contrôle. L'explicabilité agit comme un pont entre la performance des modèles d'apprentissage machine et leur adoption pratique. Dans cette thèse, nous souhaitons explorer l'usage des modèles de substitution (surrogate-model) comme mécanisme d'explicabilité de modèle de détection d'anomalies. Une des originalités de l'application de l'explicabilité au domaine de la robotique est la prise en compte de séries temporelles. En effet, peu d'approches d'explicabilité traitent de séries temporelles. On peut citer [Bento et al., 2021] qui proposent une généralisation de SHAP appliquée aux séries temporelles.

L'objectif de cet axe de recherche est donc dual. D'un côté, il s'agit de poursuivre les travaux d'apprentissage par agent contexte en les étendant à de nouveaux domaines d'application. Une emphase particulière est mise sur la capacité à expliquer et étudier le comportement organisateur des agents pour en extraire de l'information utilisable sur la fonction cible. De l'autre côté, il s'agit de contribuer à la thématique plus large de l'explicabilité des modèles d'apprentissage artificiel. Cela nécessite notamment de poursuivre l'approche de benchmarking des différents modèles pour définir les limites et perspectives de leurs usages, mais aussi de développer de nouveaux outils adaptés aux domaines d'application.

5.2.4 Etudier les apports de l'apprentissage machine à la simulation à base d'agents

Un dernier axe de recherche découle des trois précédents axes, et propose de s'intéresser dans une approche plus globale aux apports de l'apprentissage machine pour la simulation à base d'agents, notamment en abordant le défi du passage à l'échelle. Les contributions de cette HDR et les axes de recherches précédents ont déjà décrit des usages et perspectives de l'utilisation de l'apprentissage machine pour la simulation. Notamment, dans la Section 4.4 je dégage des perspectives à l'usage de modèles de substitution pour approximer le comportement de simulations à base d'agents ou de modèles de décision, dans un objectif de réduire le coût computationnel.

L'usage des modèles de substitution en simulation à base d'agents se démocratise en apportant principalement une contribution à la réduction de la complexité computation-

nelle des simulations en remplaçant certains calculs coûteux par des approximations rapides [Angione et al., 2022]. Toutefois, leur intégration exige une qualification rigoureuse et une évaluation méthodique des méthodes pour garantir leur fiabilité et leur fidélité aux dynamiques du système initial. Ainsi, l'explicabilité des modèles peut permettre cette qualification en identifiant par exemple les paramètres clés influençant les résultats. En ce sens, l'explicabilité rejoint la problématique de l'analyse de sensibilité des modèles. Il peut être intéressant d'étudier si l'explicabilité d'un modèle de substitution rejoint l'analyse de sensibilité d'une simulation à base d'agents. D'un côté, cela permettrait de qualifier la pertinence du modèle de substitution et de l'autre, il y a dans cette approche un moyen de fournir une analyse de sensibilité plus riche car reposant sur une évaluation rapide du modèle. Je vois dans cette approche un moyen d'aborder de manière originale la calibration des simulations à base d'agents, où les données d'explicabilité fournies par les modèles de substitution pourraient être utilisées comme heuristique d'exploration des paramètres lors du processus de calibration.

Enfin, l'étude du comportent des agents contextes a permis de dégager de nouvelles métriques d'explicabilité. Ces métriques permettent d'extraire dans l'espace des paramètres les espaces où le modèle est consistant, et ceux où le modèle est moins robuste. Cette métrique porte un intérêt pour mettre en place une stratégie d'apprentissage actif. L'apprentissage actif (active learning) est une stratégie d'apprentissage automatique dans laquelle un modèle interagit avec un "oracle" pour choisir de manière sélective les données les plus informatives à étiqueter. Contrairement à l'approche traditionnelle, où l'ensemble des données est étiqueté à l'avance, l'apprentissage actif vise à optimiser le processus en réduisant le nombre de données étiquetées nécessaires tout en maintenant une haute performance du modèle. On peut voir un cycle apprentissage par agent contexte comme une étape d'évaluation d'une donnée. À partir des métriques que nous avons proposés, on peut qualifier les sous-parties de l'espace des paramètres à explorer pour renforcer l'expertise du modèle. Ainsi, il peut être intéressant de concevoir et d'étudier des procédures d'apprentissage actif basées intégrant les métriques d'explicabilité dans son heuristique d'évaluation.

Ce croisement entre simulation et apprentissage machine offre des perspectives prometteuses pour doter la simulation à base d'agents de nouveaux outils et méthodes. C'est l'objet principal de l'ANR-JCJC MIMICO (https://www.irit.fr/mimico/), projet dont je suis porteur et qui a démarré en janvier 2025.

Bibliographie

[Acharya et al., 2017] Acharya, D., Khoshelham, K., and Winter, S. (2017). Real-time detection and tracking of pedestrians in cctv images using a deep convolutional neural network. In *Proceedings of the 4th Annual Conference of Research@ Locate, Sydney, Australia*, pages 3–6.

[Alahi et al., 2016] Alahi, A., Goel, K., Ramanathan, V., Robicquet, A., Fei-Fei, L., and Savarese, S. (2016). Social lstm : Human trajectory prediction in crowded spaces. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 961–971.

[Alaya et al., 2015] Alaya, M. B., Medjiah, S., Monteil, T., and Drira, K. (2015). Toward semantic interoperability in onem2m architecture. *IEEE Communications Magazine*, 53(12) :35–41.

[Angione et al., 2022] Angione, C., Silverman, E., and Yaneske, E. (2022). Using machine learning as a surrogate model for agent-based simulations. *Plos one*, 17(2) :e0263150.

[Antoniou et al., 2011] Antoniou, C., Balakrishna, R., and Koutsopoulos, H. N. (2011). A synthesis of emerging data collection technologies and their impact on traffic management applications. *European Transport Research Review*, 3 :139–148.

[Arshad et al., 2019] Arshad, B., Ogie, R., Barthelemy, J., Pradhan, B., Verstaevel, N., and Perez, P. (2019). Computer vision and iot-based sensors in flood monitoring and mapping : A systematic review. *Sensors*, 19(22) :5012.

[Bachir et al., 2019] Bachir, D., Khodabandelou, G., Gauthier, V., El Yacoubi, M., and Puchinger, J. (2019). Inferring dynamic origin-destination flows by transport mode using mobile phone data. *Transportation Research Part C : Emerging Technologies*, 101 :254–275.

[Bandini et al., 2009] Bandini, S., Manzoni, S., and Vizzari, G. (2009). Agent based modeling and simulation : an informatics perspective. *Journal of Artificial Societies and Social Simulation*, 12(4) :4.

[Barthélemy et al., 2020a] Barthélemy, J., Arshad, B., Verstaevel, N., Guastella, D., and Perez, P. (2020a). Smart building additional data.

[Barthélemy et al., 2020b] Barthélemy, J., Arshad, B., Verstaevel, N., and Perez, P. (2020b). Smart infrastructure facility building data.

[Barthélemy and Verstaevel, 2020] Barthélemy, J. and Verstaevel, N. (2020). Low-cost, long-range air quality sensor using lorawan. https://doi.org/10.5281/zenodo.3627394.

[Barthélemy et al., 2019] Barthélemy, J., Verstaevel, N., Forehead, H., and Perez, P. (2019). Edge-computing video analytics for real-time traffic monitoring in a smart city. *Sensors*, 19(9) :2048.

[Bastarianto et al., 2023] Bastarianto, F. F., Hancock, T. O., Choudhury, C. F., and Manley, E. (2023). Agent-based models in urban transportation : review, challenges, and opportunities. *European Transport Research Review*, 15(1) :19.

[Batty, 2013] Batty, M. (2013). *The new science of cities*. MIT press.

[Bellini et al., 2024] Bellini, P., Bilotta, S., Collini, E., Fanfani, M., and Nesi, P. (2024). Data sources and models for integrated mobility and transport solutions. *Sensors*, 24(2) :441.

[Beniger, 1992] Beniger, J. R. (1992). Communication and the control revolution. *OAH Magazine of History*, 6(4) :10–13.

[Bentéjac et al., 2021] Bentéjac, C., Csörgő, A., and Martínez-Muñoz, G. (2021). A comparative analysis of gradient boosting algorithms. *Artificial Intelligence Review*, 54 :1937–1967.

[Bento et al., 2021] Bento, J. a., Saleiro, P., Cruz, A. F., Figueiredo, M. A., and Bizarro, P. (2021). Timeshap : Explaining recurrent models through sequence perturbations. In *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery Data Mining*, KDD '21, page 2565–2573, New York, NY, USA. Association for Computing Machinery.

[Bewley et al., 2016] Bewley, A., Ge, Z., Ott, L., Ramos, F., and Upcroft, B. (2016). Simple online and realtime tracking. In *2016 IEEE international conference on image processing (ICIP)*, pages 3464–3468. IEEE.

[Bianchi and Schmidt, 2023] Bianchi, I. and Schmidt, L. (2023). The smart city revolution : design principles and best practices for urban transformation. *Eigenpub Review of Science and Technology*, 7(1) :55–70.

[Bibri and Krogstie, 2017a] Bibri, S. E. and Krogstie, J. (2017a). On the social shaping dimensions of smart sustainable cities : A study in science, technology, and society. *Sustainable Cities and Society*, 29 :219–246.

[Bibri and Krogstie, 2017b] Bibri, S. E. and Krogstie, J. (2017b). Smart sustainable cities of the future : An extensive interdisciplinary literature review. *Sustainable cities and society*, 31 :183–212.

[Biljecki et al., 2013] Biljecki, F., Ledoux, H., and Van Oosterom, P. (2013). Transportation mode-based segmentation and classification of movement trajectories. *International Journal of Geographical Information Science*, 27(2) :385–407.

[Bishop and Nasrabadi, 2006] Bishop, C. M. and Nasrabadi, N. M. (2006). *Pattern recognition and machine learning*, volume 4. Springer.

[Blanco-Volle et al., 2024a] Blanco-Volle, C., Verstaevel, N., Combettes, S., Gleizes, M.-P., and Povlovitsch Seixas, M. (2024a). Explainability and interpretability of an ensemble

multi-agent system for supervised learning. In *International Conference on Principles and Practice of Multi-Agent Systems*, pages 335–350. Springer.

[Blanco-Volle et al., 2024b] Blanco-Volle, C., Verstaevel, N., Combettes, S., Seixas, M. P., and Gleizes, M.-P. (2024b). Explicabilité et interprétabilité d'un système multi-agent ensembliste pour l'apprentissage supervisé. In *Les 32èmes Journées Francophones sur les Systèmes Multi-Agents (JFSMA 2024)*.

[Boes and Migeon, 2017] Boes, J. and Migeon, F. (2017). Self-organizing multi-agent systems for the control of complex systems. *Journal of Systems and Software*, 134 :12–28.

[Boes et al., 2015] Boes, J., Nigon, J., et al. (2015). The Self-Adaptive Context Learning Pattern : Overview and Proposal. In *Modeling and Using Context : 9th International and Interdisciplinary Conference*, pages 91–104. Springer, Cham, Switzerland.

[Breiman, 1996] Breiman, L. (1996). Bagging predictors. *Machine learning*, 24 :123–140.

[Breiman, 2001] Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1) :5–32.

[Breiman and Friedman, 2017] Breiman, L. and Friedman, J. (2017). *Classification and Regression Trees*. Routledge, Andover, England.

[Breuer et al., 2014] Breuer, J., Walravens, N., and Ballon, P. (2014). Beyond defining the smart city. meeting top-down and bottom-up approaches in the middle. *TeMA-Journal of Land Use, Mobility and Environment*.

[Carpineti et al., 2018] Carpineti, C., Lomonaco, V., Bedogni, L., Di Felice, M., and Bononi, L. (2018). Custom dual transportation mode detection by smartphone devices exploiting sensor diversity. In *2018 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*, pages 367–372. IEEE.

[Chang and Lin, 2011] Chang, C.-C. and Lin, C.-J. (2011). LIBSVM : A Library for Support Vector Machines. *ACM TIST*, 2(3) :1–27.

[Charypar et al., 2007] Charypar, D., Axhausen, K. W., and Nagel, K. (2007). Event-driven queue-based traffic flow microsimulation. *Transportation Research Record*, 2003(1) :35–40.

[Chen et al., 2024] Chen, D., Zhu, M., Yang, H., Wang, X., and Wang, Y. (2024). Data-driven traffic simulation : A comprehensive review. *IEEE Transactions on Intelligent Vehicles*.

[Chen et al., 2022] Chen, J., Xiong, C., Cai, M., et al. (2022). A travel mode identification framework based on cellular signaling data. *Mobile Information Systems*, 2022.

[Chen and Guestrin, 2016] Chen, T. and Guestrin, C. (2016). XGBoost : A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD*.

[Chen et al., 2018] Chen, X., Treiber, M., Kanagaraj, V., and Li, H. (2018). Social force models for pedestrian traffic–state of the art. *Transport reviews*, 38(5) :625–653.

[Chraibi et al., 2023] Chraibi, M., Cordes, J., Dang, H.-T., Dufour, O., Gaudou, B., Korbmacher, R., Nicolas, A., Rodney, D., Tordeux, A., and Verstaevel, N. (2023). Multi-Agent modelling of Dense cRowd dynAmicS (MADRAS) : Application to the Festival of Lights (Lyon). In *11th International Conference on Pedestrian and Evacuation Dynamics (PED2023)*, Eindhoven, Netherlands. Eindhoven University of Technology.

[Collins et al., 2024] Collins, A., Koehler, M., and Lynch, C. (2024). Methods that support the validation of agent-based models : An overview and discussion. *Journal of Artificial Societies and Social Simulation*, 27(1).

[Commenges, 2013] Commenges, H. (2013). *L'invention de la mobilité quotidienne. Aspects performatifs des instruments de la socio-économie des transports*. PhD thesis, Université Paris-Diderot-Paris VII.

[Cui et al., 2019] Cui, C., Wang, Z., He, P., Yuan, S., Niu, B., Kang, P., and Kang, C. (2019). Escaping from pollution : the effect of air quality on inter-city population mobility in china. *Environmental Research Letters*, 14(12) :124025.

[Dameri and Cocchia, 2013] Dameri, R. P. and Cocchia, A. (2013). Smart city and digital city : twenty years of terminology evolution. In *X Conference of the Italian Chapter of AIS, ITAIS*.

[Dang, 2025] Dang, H.-T. (2025). *Simulation and prediction of dense crowd dynamics*. Theses, Université Toulouse Capitole.

[Dang et al., 2022a] Dang, H.-T., Gaudou, B., and Verstaevel, N. (2022a). A modular framework for multi-behavior and multi-scale simulation of pedestrians. In *2nd conference GAMA Days 2022*, Online, France.

[Dang et al., 2022b] Dang, H.-T., Gaudou, B., and Verstaevel, N. (2022b). Gampy : a fast plugin for integration of Python-based deep-learning models to the GAMA platform. In *2nd conference GAMA Days 2022*, Online, France.

[Dang et al., 2022c] Dang, H.-T., Gaudou, B., and Verstaevel, N. (2022c). A modular framework for multi-behavior and multi-scale simulation of pedestrians. In *2nd conference GAMA Days 2022*.

[Dang et al., 2023a] Dang, H.-T., Gaudou, B., and Verstaevel, N. (2023a). Empirical analysis on external factors affecting pedestrian dynamics in high-density situations. 11th International Conference on Pedestrian and Evacuation Dynamics (PED 2023). Poster.

[Dang et al., 2023b] Dang, H.-T., Gaudou, B., and Verstaevel, N. (2023b). A multi-level density-based crowd simulation architecture. In *International Conference on Practical Applications of Agents and Multi-Agent Systems*, pages 64–75. Springer Nature Switzerland Cham.

[Dang et al., 2024a] Dang, H.-T., Gaudou, B., and Verstaevel, N. (2024a). A literature review of dense crowd simulation. *Simulation Modelling Practice and Theory*, 134 :102955.

[Dang et al., 2024b] Dang, H.-T., Gaudou, B., and Verstaevel, N. (2024b). HyPedSim : Un framework pour la simulation multi-niveau de foules denses. In *Les 32èmes Journées Francophones sur les Systèmes Multi-Agents (JFSMA 2024)*, Cargèse (Corse du Sud), France.

[Dang et al., 2024c] Dang, H.-T., Gaudou, B., and Verstaevel, N. (2024c). HyPedSim : A Multi-Level Crowd-Simulation Framework-Methodology, Calibration, and Validation. *Sensors*, 24(5 : Special Issue Advances in Agents and Multiagent Systems for Sensor Applications) :1639.

[Dang et al., 2024d] Dang, H.-T., Gaudou, B., and Verstaevel, N. (2024d). Improving pedestrian dynamics predictions using neighboring factors. *Collective Dynamics*, 9 :1–8.

[Dang et al., 2024e] Dang, H.-T., Gaudou, B., and Verstaevel, N. (2024e). A literature review of dense crowd simulation. *Simulation Modelling Practice and Theory*, page 102955.

[Dang et al., 2023c] Dang, H.-T., Korbmacher, R., Tordeux, A., Gaudou, B., and Verstaevel, N. (2023c). TTC-SLSTM : Human trajectory prediction using time-to-collision interaction energy. In *15th IEEE International Conference on Knowledge and Systems Engineering (KSE 2023)*, pages 1–6, Hanoi, Vietnam. Academy of Cryptography Techniques (ACT) and VNU University of Engineering and Technology (VNU-UET) and IEEE, IEEE.

[Dato, 2021] Dato, B. (2021). *Lifelong learning by endogenous feedback, application to a robotic system*. PhD thesis, Université Paul Sabatier-Toulouse III.

[Daudé et al., 2019] Daudé, E., Chapuis, K., Taillandier, P., Tranouez, P., Caron, C., Drogoul, A., Gaudou, B., Rey-Coyrehourq, S., Saval, A., and Zucker, J.-D. (2019). Escape : exploring by simulation cities awareness on population evacuation. In *ISCRAM*.

[Davis, 2017] Davis, L. W. (2017). Saturday driving restrictions fail to improve air quality in mexico city. *Scientific reports*, 7(1) :41652.

[Dimou et al., 2016] Dimou, A., Medentzidou, P., Garcia, F. A., and Daras, P. (2016). Multi-target detection in cctv footage for tracking applications using deep learning techniques. In *2016 IEEE international conference on image processing (ICIP)*, pages 928–932. IEEE.

[Dinaharison, 2023] Dinaharison, J. B. (2023). *Conception d'une approche spatialisée à base d'agent pour coupler les modèles mathématiques et informatiques : application à la modélisation du processus écosystémique du sol*. PhD thesis, Sorbonne Université ; Université de Fianarantsoa (Madagascar).

[Divasson-J et al., 2025] Divasson-J, A., Macarulla, A. M., Garcia, J. I., and Borges, C. E. (2025). Agent-based modeling in urban human mobility : A systematic review. *Cities*, 158 :105697.

[Dong et al., 2020] Dong, X., Yu, Z., Cao, W., Shi, Y., and Ma, Q. (2020). A survey on ensemble learning. *Frontiers of Computer Science*, 14 :241–258.

[Dou et al., 2023] Dou, X., Chen, W., Zhu, L., Bai, Y., Li, Y., and Wu, X. (2023). Machine learning for smart cities : A comprehensive review of applications and opportunities. *International Journal of Advanced Computer Science and Applications*, 14(9).

[Doussin et al., 2022] Doussin, B., Verstaevel, N., Gaudou, B., Kaddoum, E., and Amblard, F. (2022). Une simulation multi-agent basée sur l'affordance pour contraindre l'emergence. In *Rencontres des Jeunes Chercheurs en Intelligence Artificielle (RJCIA 2022)*, pages 77–83. AFIA. Issue : Session" IA distribuée".

[Duc et al., 2020] Duc, P. M., Chapuis, K., Drogoul, A., Gaudou, B., Grignard, A., Marilleau, N., and Tri, N.-H. (2020). Hoankiemair : simulating impacts of urban management practices on traffic and air pollution using a tangible agent-based model. In *2020 RIVF International Conference on Computing and Communication Technologies (RIVF)*, pages 1–7. IEEE.

[Dufour et al., 2024] Dufour, O., Dang, H.-T., Cordes, J., Korbmacher, R., Benoit, G., Chraibi, M., Nicolas, A., and Tordeux, A. (2024). Dense Crowd Dynamics and Pedestrian Trajectories : A Multiscale Field Study at the Fête des Lumières in Lyon. working paper or preprint.

[Dupuy, 1975] Dupuy, G. (1975). *Une technique de planification au service de l'automobile, les modèles de trafic urbain*. Ministère de l'équipement.

[D'Elia et al., 2024] D'Elia, G., Ferro, M., Sommella, P., Ferlito, S., De Vito, S., and Di Francia, G. (2024). Concept drift mitigation in low-cost air quality monitoring networks. *Sensors*, 24(9) :2786.

[Erdelyi et al., 2021a] Erdelyi, J.-F., Adam, C., Gaudou, B., Taillandier, F., and Verstaevel, N. (2021a). Simulating the transition of mobility toward smart and sustainable cities. In *6th International Workshop on Agent-Based Modelling of Urban Systems (ABMUS@ AAMAS 2021)*, pages 41–45.

[Erdelyi et al., 2021b] Erdelyi, J.-F., Amblard, F., Gaudou, B., Kaddoum, E., and Verstaevel, N. (2021b). Exploration of model coupling strategies in a hybrid agent-based traffic simulation. In *International Workshop on Multi-Agent Systems and Agent-Based Simulation*, pages 153–167. Springer International Publishing Cham.

[Farhadi and Redmon, 2018] Farhadi, A. and Redmon, J. (2018). Yolov3 : An incremental improvement. In *Computer vision and pattern recognition*, volume 1804, pages 1–6. Springer Berlin/Heidelberg, Germany.

[Forehead et al., 2020] Forehead, H., Barthelemy, J., Arshad, B., Verstaevel, N., Price, O., and Perez, P. (2020). Traffic exhaust to wildfires : PM2.5 measurements with fixed and portable, low-cost LoRaWAN-connected sensors. *PLOS ONE*, 15(4) :e0231778.

[Fourez, 2022] Fourez, T. (2022). Occitania-transportation mode. https://doi.org/10.5281/zenodo.7386788.

[Fourez, 2024] Fourez, T. (2024). *Analyzing Human Mobility with an Ensemblist Multi-Agent Context Learning System*. Theses, Université Toulouse Capitole.

[Fourez et al., 2022a] Fourez, T., Verstaevel, N., Migeon, F., Schettini, F., and Amblard, F. (2022a). An ensemble Multi-Agent System for non-linear classification. In *14th ITS European Congress (ITS EU 2022)*, pages 1–12, Toulouse, France. Congrès annuel européen des Systèmes de Transport Intelligents (ITS).

[Fourez et al., 2022b] Fourez, T., Verstaevel, N., Migeon, F., Schettini, F., and Amblard, F. (2022b). How to solve a classification problem using a cooperative tiling multi-agent system ? In *International Conference on Practical Applications of Agents and Multi-Agent Systems*, pages 166–178. Springer International Publishing Cham.

[Fourez et al., 2025] Fourez, T., Verstaevel, N., Migeon, F., Schettini, F., and Amblard, F. (2025). Transport mode detection on gnss and accelerometer data : a temporality based workflow. *Transportation Research Procedia*, 82 :3454–3471. World Conference on Transport Research - WCTR 2023 Montreal 17-21 July 2023.

[Freeman et al., 2004] Freeman, E., Robson, E., Bates, B., and Sierra, K. (2004). *Head First Design Patterns : A Brain-Friendly Guide*. " O'Reilly Media, Inc.".

[Friedman, 2001] Friedman, J. H. (2001). Greedy Function Approximation : A Gradient Boosting Machine. *Annals of Statistics*, 29(5) :1189–1232.

[Frisk, 2016] Frisk, R. (2016). Citizens of the smarter city. Available at : https://www.arkilab.dk/wp-content/uploads/2016/06/3.pdf [Accessed : 13/11/2024].

[Gaudou et al., 2014] Gaudou, B., Sibertin-Blanc, C., Therond, O., Amblard, F., Auda, Y., Arcangeli, J.-P., Balestrat, M., Charron-Moirez, M.-H., Gondet, E., Hong, Y., et al. (2014). The maelia multi-agent platform for integrated analysis of interactions between agricultural land-use and low-water management strategies. In *Multi-Agent-Based Simulation XIV : International Workshop, MABS 2013, Saint Paul, MN, USA, May 6-7, 2013, Revised Selected Papers*, pages 85–100. Springer.

[Gibson et al., 1992] Gibson, D. V., Kozmetsky, G., and Smilor, R. W. (1992). *The technopolis phenomenon : Smart cities, fast systems, global networks*. Rowman & Littlefield.

[Gibson, 1977] Gibson, J. (1977). J.(1977). the theory of affordances. *Perceiving, acting, and knowing : Toward an ecological psychology*, pages 67–82.

[Gilpin et al., 2018] Gilpin, L. H., Bau, D., and Yuan, B. Z. (2018). Explaining explanations : An overview of interpretability of machine learning. In *2018 IEEE 5th International Conference on data science and advanced analytics (DSAA)*, pages 80–89. IEEE.

[Giri et al., 2022] Giri, S., Brondeel, R., El Aarbaoui, T., and Chaix, B. (2022). Application of machine learning to predict transport modes from gps, accelerometer, and heart rate data. *International Journal of Health Geographics*, 21(1) :19.

[Gong et al., 2012] Gong, H., Chen, C., Bialostozky, E., and Lawson, C. T. (2012). A gps/gis method for travel mode detection in new york city. *Computers, Environment and Urban Systems*, 36(2) :131–139.

[Goodfellow et al., 2016] Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep Learning*. MIT Press. http://www.deeplearningbook.org.

[Google, 2023] Google (2023). General transit feed specification reference. https://developers.google.com/transit/gtfs/reference?hl=fr.

[Gracias et al., 2023] Gracias, J. S., Parnell, G. S., Specking, E., Pohl, E. A., and Buchanan, R. (2023). Smart cities—a structured literature review. *Smart Cities*, 6(4) :1719–1743.

[Guastella et al., 2021] Guastella, D. A., Verstaevel, N., Valenti, C., Arshad, B., and Barthélemy, J. (2021). Evaluating correlations in IoT sensors for smart buildings. In *ICAART (1)*, pages 224–231.

[Gubbi et al., 2013] Gubbi, J., Buyya, R., Marusic, S., and Palaniswami, M. (2013). Internet of things (iot) : A vision, architectural elements, and future directions. *Future Generation Computer Systems*, 29(7) :1645–1660. Including Special sections : Cyber-enabled Distributed Computing for Ubiquitous Cloud and Network Services Cloud Computing and Scientific Applications — Big Data, Scalable Analytics, and Beyond.

[Guivarch et al., 2012] Guivarch, V., Camps, V., and Péninou, A. (2012). Amadeus : an adaptive multi-agent system to learn a user's recurring actions in ambient systems. *ADCAIJ : Advances in Distributed Computing and Artificial Intelligence Journal*, 1(3) :1.

[Guvensan et al., 2017] Guvensan, M. A., Dusun, B., Can, B., and Turkmen, H. I. (2017). A novel segment-based approach for improving classification performance of transport mode detection. *Sensors*, 18(1) :87.

[Hall et al., 2000] Hall, R. E., Bowerman, B., Braverman, J., Taylor, J., Todosow, H., and Von Wimmersperg, U. (2000). The vision of a smart city. Technical report, Brookhaven National Lab.(BNL), Upton, NY (United States).

[Helbing et al., 2000] Helbing, D., Farkas, I., and Vicsek, T. (2000). Simulating dynamic features of escape panic. *Nature*, 407 :487–490.

[HERE, 2024] HERE (2024). Here map content - schema. https://www.here.com/docs/bundle/map-content-schema-data-specification/page/topics/overview.html.

[Hoogendoorn and Bovy, 2004] Hoogendoorn, S. P. and Bovy, P. H. (2004). Pedestrian route-choice and activity scheduling theory and models. *Transportation Research Part B : Methodological*, 38(2) :169–190.

[Huang et al., 2022] Huang, J., Cui, Y., Zhang, L., Tong, W., Shi, Y., and Liu, Z. (2022). An overview of agent-based models for transport simulation and analysis. *Journal of Advanced Transportation*, 2022(1) :1252534.

[Huynh et al., 2017] Huynh, N. Q., ud Grignard, A., Huynh, H. X., et al. (2017). Coupling equation based models and agent-based models : example of a multi-strains and switch sir toy model. *EAI Endorsed Transactions on Context-aware Systems and Applications*, 4(11).

[Insee, 2016] Insee (2016). Définition - iris. https://www.insee.fr/fr/metadonnees/definition/c1523. Consulté le 12 février 2024.

[IRIT, 2019] IRIT (2019). Action « territoire d'innovation » du pia3 : le projet vilagil retenu ! https://www.irit.fr/action-territoire-dinnovation-du-pia3-le-projet-vilagil-retenu/. Consulté le 26 février 2024.

[Iskanderov and Guvensan, 2020] Iskanderov, J. and Guvensan, M. A. (2020). Breaking the limits of transportation mode detection : Applying deep learning approach with knowledge-based features. *IEEE Sensors Journal*, 20(21) :12871–12884.

[Jamil and Yang, 2013] Jamil, M. and Yang, X.-S. (2013). A Literature Survey of Benchmark Functions for Global Optimisation Problems. *IJMMNO*, 4 :150–194.

[Johansson et al., 2007] Johansson, A., Helbing, D., and Shukla, P. K. (2007). Specification of the social force pedestrian model by evolutionary adjustment to video tracking data. *Advances in complex systems*, 10(supp02) :271–288.

[José and Rodrigues, 2024] José, R. and Rodrigues, H. (2024). A review on key innovation challenges for smart city initiatives. *Smart Cities*, 7(1) :141–162.

[Kalman, 1960] Kalman, R. (1960). On the general theory of control systems. *IFAC Proceedings Volumes*, 1(1) :491–502. 1st International IFAC Congress on Automatic and Remote Control, Moscow, USSR, 1960.

[Karale, 2021] Karale, A. (2021). The challenges of iot addressing security, ethics, privacy, and laws. *Internet of Things*, 15 :100420.

[Karamouzas et al., 2014] Karamouzas, I., Skinner, B., and Guy, S. J. (2014). Universal power law governing pedestrian interactions. *Physical review letters*, 113(23) :238701.

[Ke et al., 2017] Ke, G., Meng, Q., et al. (2017). LightGBM : A Highly Efficient Gradient Boosting Decision Tree. *NIPS*, 30.

[Khalid, 2024] Khalid, M. (2024). Smart grids and renewable energy systems : Perspectives and grid integration challenges. *Energy Strategy Reviews*, 51 :101299.

[Khan et al., 2022] Khan, A., Aslam, S., Aurangzeb, K., Alhussein, M., and Javaid, N. (2022). Multiscale modeling in smart cities : A survey on applications, current trends, and challenges. *Sustainable Cities and Society*, 78 :103517.

[Kieu et al., 2024] Kieu, M., Nguyen, H., Ward, J. A., and Malleson, N. (2024). Towards real-time predictions using emulators of agent-based models. *Journal of Simulation*, 18(1) :29–46.

[Korbmacher et al., 2023] Korbmacher, R., Dang, H.-T., and Tordeux, A. (2023). Using time-to-collision in the loss function of deep learning algorithm to improve pedestrian trajectory predictions. 11th International Conference on Pedestrian and Evacuation Dynamics (PED 2023). Poster.

[Korbmacher et al., 2024] Korbmacher, R., Dang, H.-T., and Tordeux, A. (2024). Predicting pedestrian trajectories at different densities : A multi-criteria empirical analysis. *Physica A : Statistical Mechanics and its Applications*, 634 :129440.

[Korbmacher et al., 2022a] Korbmacher, R., Dang, H.-T., Tordeux, A., Gaudou, B., and Verstaevel, N. (2022a). Differences in pedestrian trajectory predictions for high- and low-density situations. In *14th International Conference on Traffic and Granular Flow (TGF 2022)*, Dehli, India. Springer.

[Korbmacher et al., 2022b] Korbmacher, R., Dang, H.-T., Tordeux, A., Gaudou, B., and Verstaevel, N. (2022b). Empirical Comparison of Different Pedestrian Trajectory Prediction Methods at High Densities. In *Traffic and Granular Flow '22*, volume 443 of *Lecture Notes in Civil Engineering*, pages 231–238, Delhi (India), India. Springer Nature Singapore.

[Korbmacher et al., 2022c] Korbmacher, R., Dang, H.-T., Tordeux, A., Gaudou, B., and Verstaevel, N. (2022c). Empirical comparison of different pedestrian trajectory prediction methods at high densities. In *International Conference on Traffic and Granular Flow*, pages 231–238. Springer Nature Singapore Singapore.

[Korbmacher et al., 2022d] Korbmacher, R., Dang, H.-T., Tordeux, A., Gaudou, B., and Verstaevel, N. (2022d). Using synthetic data to improve performance of data-driven algorithms in high density pedestrian situations. In *2nd conference GAMA Days 2022*, Online, France.

[Korbmacher and Tordeux, 2022] Korbmacher, R. and Tordeux, A. (2022). Review of pedestrian trajectory prediction methods : Comparing deep learning and knowledge-based approaches. *IEEE Transactions on Intelligent Transportation Systems*, 23(12) :24126–24144.

[Kothari et al., 2021] Kothari, P., Kreiss, S., and Alahi, A. (2021). Human trajectory forecasting in crowds : A deep learning perspective. *IEEE Transactions on Intelligent Transportation Systems*, 23(7) :7386–7400.

[Kuhn, 1955] Kuhn, H. W. (1955). The hungarian method for the assignment problem. *Naval research logistics quarterly*, 2(1-2) :83–97.

[Lanng and Jensen, 2022] Lanng, D. B. and Jensen, O. B. (2022). A walk in the park : Affordance as urban design tool for creating inhabitable cities. In *Affordances in everyday life : A multidisciplinary collection of essays*, pages 41–49. Springer.

[Lawson et al., 2023] Lawson, C. T., Krans, E., Rentz, E. G., and Lynch, J. (2023). Emerging trends in household travel survey programs. *Social Sciences & Humanities Open*, 7(1) :100466.

[Lerner et al., 2007] Lerner, A., Chrysanthou, Y., and Lischinski, D. (2007). Crowds by example. In *Computer graphics forum*, pages 655–664. Wiley Online Library.

[Li et al., 2022] Li, Y., Yuan, Z., Chen, L.-W. A., Pillarisetti, A., Yadav, V., Wu, M., Cui, H., and Zhao, C. (2022). From air quality sensors to sensor networks : Things we need to learn. *Sensors and Actuators B : Chemical*, 351 :130958.

[Lin et al., 2014] Lin, T.-Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., and Zitnick, C. L. (2014). Microsoft coco : Common objects in context. In *Computer Vision–ECCV 2014 : 13th European Conference, Zurich, Switzerland, September 6-12, 2014, Proceedings, Part V 13*, pages 740–755. Springer.

[Liu et al., 2013] Liu, Y.-Y., Slotine, J.-J., and Barabási, A.-L. (2013). Observability of complex systems. *Proceedings of the National Academy of Sciences*, 110(7) :2460–2465.

[Lopez et al., 2018] Lopez, P. A., Behrisch, M., Bieker-Walz, L., Erdmann, J., Flötteröd, Y.-P., Hilbrich, R., Lücken, L., Rummel, J., Wagner, P., and Wießner, E. (2018). Microscopic traffic simulation using sumo. In *The 21st IEEE International Conference on Intelligent Transportation Systems*. IEEE.

[Lundberg and Lee, 2017] Lundberg, S. M. and Lee, S.-I. (2017). A unified approach to interpreting model predictions. In Guyon, I., Luxburg, U. V., Bengio, S., Wallach, H., Fergus, R., Vishwanathan, S., and Garnett, R., editors, *Advances in Neural Information Processing Systems 30*, pages 4765–4774. Curran Associates, Inc.

[Mao et al., 2019] Mao, Q.-C., Sun, H.-M., Liu, Y.-B., and Jia, R.-S. (2019). Mini-yolov3 : real-time object detector for embedded applications. *Ieee Access*, 7 :133529–133538.

[Marilleau et al., 2018] Marilleau, N., Lang, C., and Giraudoux, P. (2018). Coupling agent-based with equation-based models to study spatially explicit megapopulation dynamics. *Ecological Modelling*, 384 :34–42.

[Mehdizadeh et al., 2022] Mehdizadeh, M., Nordfjaern, T., and Klöckner, C. A. (2022). A systematic review of the agent-based modelling/simulation paradigm in mobility transition. *Technological Forecasting and Social Change*, 184 :122011.

[Mitchell, 1997] Mitchell, T. (1997). *Machine Learning*. McGraw-Hill international editions - computer science series. McGraw-Hill Education.

[Molnar et al., 2020] Molnar, C., Casalicchio, G., and Bischl, B. (2020). Interpretable machine learning–a brief history, state-of-the-art and challenges. In *Joint European conference on machine learning and knowledge discovery in databases*, pages 417–431. Springer.

[Montes, 2020] Montes, J. (2020). A historical view of smart cities : Definitions, features and tipping points. *SSRN Electronic Journal*.

[Moussaïd et al., 2009] Moussaïd, M., Helbing, D., Garnier, S., Johansson, A., Combe, M., and Theraulaz, G. (2009). Experimental study of the behavioural mechanisms underlying self-organization in human crowds. *Proceedings of the Royal Society B : Biological Sciences*, 276(1668) :2755–2762.

[Moussaïd et al., 2011] Moussaïd, M., Helbing, D., and Theraulaz, G. (2011). How simple rules determine pedestrian behavior and crowd disasters. *Proceedings of the National Academy of Sciences*, 108(17) :6884–6888.

[Navarro et al., 2013] Navarro, L., Corruble, V., Flacher, F., and Zucker, J.-D. (2013). A flexible approach to multi-level agent-based simulation with the mesoscopic representation. In *Proceedings of the 2013 international conference on Autonomous agents and multi-agent systems*, pages 159–166.

[Nawaz et al., 2020a] Nawaz, A., Zhiqiu, H., Senzhang, W., Hussain, Y., Khan, I., and Khan, Z. (2020a). Convolutional lstm based transportation mode learning from raw gps trajectories. *IET Intelligent Transport Systems*, 14(6) :570–577.

[Nawaz et al., 2020b] Nawaz, A., Zhiqiu, H., Senzhang, W., Hussain, Y., Naseer, A., Izhar, M., and Khan, Z. (2020b). Mode inference using enhanced segmentation and pre-processing on raw global positioning system data. *Measurement and Control*, 53(7-8) :1144–1158.

[Neirotti et al., 2014] Neirotti, P., De Marco, A., Cagliano, A. C., Mangano, G., and Scorrano, F. (2014). Current trends in smart city initiatives : Some stylised facts. *Cities*, 38 :25–36.

[Nigon et al., 2016] Nigon, J., Glize, E., Dupas, D., Crasnier, F., and Boes, J. (2016). Use cases of pervasive artificial intelligence for smart cities challenges. In *2016 Intl IEEE conferences on ubiquitous intelligence & computing, advanced and trusted computing, scalable computing and communications, cloud and big data computing, internet of people, and smart world congress (UIC/ATC/ScalCom/CBDCom/IoP/SmartWorld)*, pages 1021–1027. IEEE.

[Nigon et al., 2017] Nigon, J., Verstaevel, N., Boes, J., Migeon, F., and Gleizes, M.-P. (2017). Smart is a matter of context. In *Modeling and Using Context : 10th International and Interdisciplinary Conference, CONTEXT 2017, Paris, France, June 20-23, 2017, Proceedings 10*, pages 189–202. Springer.

[Ogie and Verstaevel, 2020] Ogie, R. and Verstaevel, N. (2020). Disaster informatics : An overview. *Progress in Disaster Science*, 7.

[OpenStreetMap contributors, 2017] OpenStreetMap contributors (2017). Planet dump retrieved from https ://planet.osm.org .

[Palmisano, 2009] Palmisano, S. J. (2009). A smarter planet : The next leadership agenda. *Connect-World*.

[Pedregosa et al., 2012] Pedregosa, F., Varoquaux, G., et al. (2012). Scikit-learn : Machine Learning in Python. *ArXiv e-prints*.

[Peirce et al., 2013] Peirce, N., Freed, A., and Townsend, A. (2013). Urban futures : An atlantic perspective. *German Marshall Fund of the United States : Washington DC*.

[Pellegrini et al., 2009] Pellegrini, S., Ess, A., Schindler, K., and Van Gool, L. (2009). You'll never walk alone : Modeling social behavior for multi-target tracking. In *2009 IEEE 12th international conference on computer vision*, pages 261–268. IEEE.

[Peppa et al., 2018] Peppa, M., Bell, D., Komar, T., and Xiao, W. (2018). Urban traffic flow analysis based on deep learning car detection from cctv image series. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42 :499–506.

[Pisani and (France), 2015] Pisani, F. and (France), N. O. (2015). *A Journey through smart cities : between datapolis and participolis*. UNESCO Publishing.

[Pliatsios et al., 2023] Pliatsios, A., Kotis, K., and Goumopoulos, C. (2023). A systematic review on semantic interoperability in the ioe-enabled smart cities. *Internet of Things*, 22 :100754.

[Polk et al., 1996] Polk, A., Kranig, J., and Minge, E. (1996). Field test of non-intrusive traffic detection technologies. In *Intelligent Transportation : Realizing the Benefits. Proceedings of the 1996 Annual Meeting of ITS America. ITS America*.

[Prédhumeau and Manley, 2023] Prédhumeau, M. and Manley, E. (2023). A synthetic population for agent-based modelling in canada. *Scientific Data*, 10(1) :148.

[Rahim et al., 2021] Rahim, M. A., Rahman, M., Rahman, M. A., Muzahid, A. J. M., and Kamarulzaman, S. F. (2021). A framework of iot-enabled vehicular noise intensity monitoring system for smart city. In *Advances in Robotics, Automation and Data Analytics : Selected Papers from ICITES 2020*, pages 194–205. Springer.

[Raiaan et al., 2024] Raiaan, M. A. K., Mukta, M. S. H., Fatema, K., Fahad, N. M., Sakib, S., Mim, M. M. J., Ahmad, J., Ali, M. E., and Azam, S. (2024). A review on large language models : Architectures, applications, taxonomies, open issues and challenges. *IEEE Access*.

[Railsback and Grimm, 2019] Railsback, S. F. and Grimm, V. (2019). *Agent-based and individual-based modeling : a practical introduction*. Princeton university press.

[Ribeiro et al., 2016] Ribeiro, M. T., Singh, S., and Guestrin, C. (2016). " Why should i trust you ?" Explaining the predictions of any classifier. In *Proceedings of the 22nd ACM SIGKDD*, pages 1135–1144.

[Rückerl et al., 2011] Rückerl, R., Schneider, A., Breitner, S., Cyrys, J., and Peters, A. (2011). Health effects of particulate air pollution : a review of epidemiological evidence. *Inhalation toxicology*, 23(10) :555–592.

[Russell and Norvig, 1995] Russell, S. and Norvig, P. (1995). A modern, agent-oriented approach to introductory artificial intelligence. *Acm Sigart Bulletin*, 6(2) :24–26.

[Russell and Norvig, 2016] Russell, S. J. and Norvig, P. (2016). *Artificial intelligence : a modern approach*. Pearson.

[Sadeghian et al., 2021] Sadeghian, P., Håkansson, J., and Zhao, X. (2021). Review and evaluation of methods in transport mode detection based on gps tracking data. *Journal of Traffic and Transportation Engineering (English Edition)*, 8(4) :467–482.

[Salih et al., 2025] Salih, A. M., Raisi-Estabragh, Z., Galazzo, I. B., Radeva, P., Petersen, S. E., Lekadir, K., and Menegaz, G. (2025). A perspective on explainable artificial intelligence methods : Shap and lime. *Advanced Intelligent Systems*, 7(1) :2400304.

[Satyanarayanan, 2017] Satyanarayanan, M. (2017). The emergence of edge computing. *Computer*, 50(1) :30–39.

[Sauerländer-Biebl et al., 2017] Sauerländer-Biebl, A., Brockfeld, E., Suske, D., and Melde, E. (2017). Evaluation of a transport mode detection using fuzzy rules. *Transportation research procedia*, 25 :591–602.

[Schwenzer et al., 2021] Schwenzer, M., Ay, M., Bergs, T., and Abel, D. (2021). Review on model predictive control : An engineering perspective. *The International Journal of Advanced Manufacturing Technology*, 117(5) :1327–1349.

[Setton et al., 2011] Setton, E., Marshall, J. D., Brauer, M., Lundquist, K. R., Hystad, P., Keller, P., and Cloutier-Fisher, D. (2011). The impact of daily mobility on exposure to traffic-related air pollution and health effect estimates. *Journal of exposure science & environmental epidemiology*, 21(1) :42–48.

[Sharma et al., 2024] Sharma, A., Kumar, V., and Longchamps, L. (2024). Comparative performance of yolov8, yolov9, yolov10, yolov11 and faster r-cnn models for detection of multiple weed species. *Smart Agricultural Technology*, page 100648.

[Shorten and Khoshgoftaar, 2019] Shorten, C. and Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of big data*, 6(1) :1–48.

[Shu et al., 2015] Shu, Y., Bo, C., Shen, G., Zhao, C., Li, L., and Zhao, F. (2015). Magicol : Indoor localization using pervasive magnetic field and opportunistic wifi sensing. *IEEE Journal on Selected Areas in Communications*, 33(7) :1443–1457.

[Štrumbelj and Kononenko, 2014] Štrumbelj, E. and Kononenko, I. (2014). Explaining prediction models and individual predictions with feature contributions. *Knowledge and information systems*, 41 :647–665.

[Taillandier et al., 2019] Taillandier, P., Gaudou, B., Grignard, A., Huynh, Q.-N., Marilleau, N., Caillou, P., Philippon, D., and Drogoul, A. (2019). Building, composing and experimenting complex spatial models with the gama platform. *GeoInformatica*, 23 :299–322.

[Tang and Malleson, 2022] Tang, D. and Malleson, N. (2022). Data assimilation with agent-based models using markov chain sampling. *arXiv preprint arXiv :2205.01616*.

[Taplin, 1999] Taplin, J. (1999). Simulation models of traffic flow. *The 34th Annual Conference of the Operational Research Society of New Zealand, New Zealand*, page 12.

[Tchappi Haman et al., 2017] Tchappi Haman, I., Kamla, V. C., Galland, S., and Kamgang, J. C. (2017). Towards an Multilevel Agent-based Model for Traffic Simulation. *Procedia Computer Science*, 109 :887–892.

[Treiber et al., 2000] Treiber, M., Hennecke, A., and Helbing, D. (2000). Congested traffic states in empirical observations and microscopic simulations. *Physical review E*, 62(2) :1805.

[Treuille et al., 2006] Treuille, A., Cooper, S., and Popovic, Z. (2006). Continuum crowds. *ACM Trans. Graph.*, 25 :1160–1168.

[Vakili et al., 2020] Vakili, M., Ghamsari, M., and Rezaei, M. (2020). Performance analysis and comparison of machine and deep learning algorithms for iot data classification. *arXiv preprint arXiv :2001.09636*.

[Van Dam and Verstaevel, 2022] Van Dam, K. H. and Verstaevel, N. (2022). *Multi-Agent-Based Simulation XXII : 22nd International Workshop, MABS 2021, Virtual Event, May 3-7, 2021, Revised Selected Papers*, volume 13128. Springer Nature.

[Vergnet et al., 2021] Vergnet, D., Amblard, F., Kaddoum, E., and Verstaevel, N. (2021). Auto-calibration adaptative de modèles de simulation de trafic par système multi-agent. In *3èmes Rencontres Francophones Transport Mobilité (RFTM 2021)*.

[Vergnet et al., 2022] Vergnet, D., Kaddoum, E., Verstaevel, N., and Amblard, F. (2022). Cooperation-based search of global optima. In *International Conference on Optimization and Learning*, pages 105–116. Springer.

[Verstaevel, 2016] Verstaevel, N. (2016). *Self-organization of robotic devices through demonstrations*. PhD thesis, Université de Toulouse, Université Toulouse III-Paul Sabatier.

[Verstaevel et al., 2020] Verstaevel, N., Barthélemy, J., Forehead, H., Arshad, B., and Perez, P. (2020). Assessing the effects of mobility on air quality : The liverpool smart pedestrian project. *Transportation Research Procedia*, 48 :2197–2206.

[Verstaevel et al., 2017a] Verstaevel, N., Boes, J., and Gleizes, M.-P. (2017a). From smart campus to smart cities issues of the smart revolution. In *2nd Workshop on Smart and Sustainable Cities*.

[Verstaevel et al., 2017b] Verstaevel, N., Boes, J., Nigon, J., d'Amico, D., and Gleizes, M.-P. (2017b). Lifelong machine learning with adaptive multi-agent systems. In *International Conference on Agents and Artificial Intelligence*, volume 2, pages 275–286. SciTePress.

[Verstaevel et al., 2018a] Verstaevel, N., Garzone, G., Monteil, T., Guermouche, N., Barthelemy, J., and Perez, P. (2018a). An ontology based context-aware architecture for smart campus applications. In *2018 IEEE Intl Conf on Parallel & Distributed Processing with Applications, Ubiquitous Computing & Communications, Big Data & Cloud*

Computing, Social Computing & Networking, Sustainable Computing & Communications (ISPA/IUCC/BDCloud/SocialCom/SustainCom), pages 1056–1063. IEEE.

[Verstaevel et al., 2018b] Verstaevel, N., Georgé, J.-P., Bernon, C., and Gleizes, M.-P. (2018b). A self-organized learning model for anomalies detection : application to elderly people. In *2018 IEEE 12th International Conference on Self-Adaptive and Self-Organizing Systems (SASO)*, pages 70–79. IEEE.

[Videau et al., 2011] Videau, S., Bernon, C., Glize, P., and Uribelarrea, J.-L. (2011). Controlling bioprocesses using cooperative self-organizing agents. In *Advances on Practical Applications of Agents and Multiagent Systems : 9th International Conference on Practical Applications of Agents and Multiagent Systems*, pages 141–150. Springer.

[W Axhausen et al., 2016] W Axhausen, K., Horni, A., and Nagel, K. (2016). *The multi-agent transport simulation MATSim*. Ubiquity Press.

[Wang et al., 2022] Wang, Y., Yu, X., Guo, J., Papamichail, I., Papageorgiou, M., Zhang, L., Hu, S., Li, Y., and Sun, J. (2022). Macroscopic traffic flow modelling of large-scale freeway networks with field data verification : State-of-the-art review, benchmarking framework, and case studies using metanet. *Transportation Research Part C : Emerging Technologies*, 145 :103904.

[Weisberg, 2005] Weisberg, S. (2005). *Applied Linear Regression*. John Wiley & Sons, Ltd., Chichester, England, UK.

[Yang et al., 2018] Yang, X., Stewart, K., Tang, L., Xie, Z., and Li, Q. (2018). A review of gps trajectories classification based on transportation mode. *Sensors*, 18(11) :3741.

[Yin et al., 2015] Yin, C., Xiong, Z., Chen, H., Wang, J., Cooper, D., and David, B. (2015). A literature survey on smart cities. *Science China. Information Sciences*, 58(10) :1–18.

[Yuan and Mills, 2019] Yuan, Y. and Mills, D. (2019). Exploring urban dynamics from bluetooth tracking data : A case study of austin, texas. In *Proceedings of the ICA*, volume 2, page 153. Copernicus Publications Göttingen, Germany.

[Zeng et al., 2017] Zeng, W., Chen, P., Yu, G., and Wang, Y. (2017). Specification and calibration of a microscopic model for pedestrian dynamic simulation at signalized intersections : A hybrid approach. *Transportation Research Part C : Emerging Technologies*, 80 :37–70.

[Zheng et al., 2009] Zheng, Y., Zhang, L., Xie, X., and Ma, W.-Y. (2009). Mining interesting locations and travel sequences from gps trajectories. In *Proceedings of the 18th international conference on World wide web*, pages 791–800.

[Zhong et al., 2022] Zhong, J., Li, D., Huang, Z., Lu, C., and Cai, W. (2022). Data-driven crowd modeling techniques : A survey. *ACM Transactions on Modeling and Computer Simulation (TOMACS)*, 32(1) :1–33.