



**HAL**  
open science

## **P-ADRIP : un système multi-agent auto-organisateur pour la prévision du trafic routier**

Ha-Nhi Ngo, Elsy Kaddoum, Marie-Pierre Gleizes, Jonathan Bonnet,  
Goursolle Anaïs

► **To cite this version:**

Ha-Nhi Ngo, Elsy Kaddoum, Marie-Pierre Gleizes, Jonathan Bonnet, Goursolle Anaïs. P-ADRIP : un système multi-agent auto-organisateur pour la prévision du trafic routier. 30èmes Journées Francophones sur les Systèmes Multi-Agents : SMA et Smart Cities (JFSMA 2022) @ PFIA, Jun 2022, Saint-Etienne, France. pp. article 977. hal-03764716

**HAL Id: hal-03764716**

**<https://hal.science/hal-03764716>**

Submitted on 30 Aug 2022

**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.

# P-ADRIP : un système multi-agent auto-organisateur pour la prévision du trafic routier

Ha-Nhi Ngo<sup>a,b</sup>    Elsy Kaddoum<sup>a</sup>    Marie-Pierre Gleizes<sup>a</sup>  
ha-nhi.ngo@irit.fr    elsy.kaddoum@irit.fr    marie-pierre.gleizes@irit.fr

Jonathan Bonnet<sup>b</sup>    Anaïs Goursolle<sup>b</sup>  
jonathan.bonnet@continental-corporation.com    anais.goursolle@continental-corporation.com

<sup>a</sup>IRIT- Université de Toulouse, CNRS, Toulouse INP, UT3, UT1, UT2

<sup>b</sup>Continental Digital Services France, Toulouse, France

## Résumé

*La prévision du trafic suscite de plus en plus d'intérêt dans les recherches académiques et industrielles. Récemment, de nombreuses méthodes de prévision du trafic basées sur des approches d'apprentissage automatique et d'apprentissage profond ont été proposées. Cependant, ces modèles coûteux en temps de calcul, nécessitent des volumes de données importants et leurs résultats soulèvent des questions de fiabilité et de faisabilité. En effet, la prévision du trafic est une tâche très difficile en raison des dépendances spatiales et temporelles complexes et de la difficulté de la prévision à long terme. Pour adresser les défis mentionnés, nous proposons le système P-ADRIP (Prevision subsystem - Adaptive multi-agent system for DRIVING behaviors Prevision) basé sur les systèmes multi-agents. P-ADRIP vise à fournir une prévision dynamique et temps réel du trafic. Les expériences menées montrent la performance remarquable de P-ADRIP par rapport aux méthodes de prévision connues dans l'état de l'art.*

**Mots-clés :** *Prédiction du trafic, Système multi-agent adaptatif, Coopération locale, Séries temporelles*

## Abstract

*Traffic forecasting has gained more and more interests in both academic and industrial research activities. Recently, many methods for traffic forecasting based on machine learning and deep learning approaches are proposed. However, these models always encounter the unsolved questions relating to the reliability and the feasibility. Indeed, traffic forecasting is a very challenging task due to the complex spatial correlations, the high-level time dependency and the difficulty of long-term prediction. To address the mentioned challenges, we propose a novel system based on multi-agent systems ap-*

*proach called P-ADRIP (Prediction subsystem - Adaptive multi-agent system for DRIVING behaviors Prediction) that aims to provide dynamic and real-time traffic prediction. The conducted experiments demonstrate the outstanding performance of P-ADRIP comparing to the state-of-the-art prediction methods.*

**Keywords:** *Traffic prediction; Adaptive Multi-agent system; Local Cooperation, Time series prediction methods*

## 1 Introduction

La prévision précise et en temps réel du trafic est aujourd'hui essentielle pour le contrôle du trafic urbain, la sécurité et les fonctions de guidage du Système de Transport Intelligents (STI). Elle est largement appliquée à divers services de transport afin de fournir de meilleures recommandations de voyage, d'atténuer les embouteillages et les collisions dangereuses en queue du bouchon, d'économiser l'énergie consommée et d'améliorer l'efficacité du trafic. Ainsi, la prévision précise devient indispensable pour de nombreux sous-systèmes de STI, notamment les systèmes avancés d'aide à la conduite (ADAS), les systèmes avancés d'information aux voyageurs (ATIS), etc.

Cette tâche est difficile en raison de la complexité des dépendances spatio-temporelles et de la difficulté de la prévision à long terme. D'une part, les données de trafic montrent qu'une forte dynamique temporelle entraîne une haute dépendance des valeurs prédites par rapport aux données historiques de trafic, i.e une dépendance temporelle. La dépendance temporelle est caractérisée par différentes propriétés des séries temporelles telles que : la non-stationnarité, la saisonnalité, la non-linéarité, etc. D'autre part, la dynamique du trafic présente également une

corrélation spatiale complexe.

Récemment, les Systèmes Multi-Agents (SMA) ont été appliqués avec succès à de nombreux problèmes dans divers domaines, notamment dans le transport intelligent [6] ou l'apprentissage par démonstrations pour des robots ambiants [17], grâce à leur capacité à modéliser des problèmes complexes. Comme le problème de la prévision du trafic peut être considéré comme un problème complexe en raison du nombre de facteurs qui interviennent, un système basé sur un SMA est une approche prometteuse à envisager.

Cet article présente un système basé sur un SMA [3] pour prédire la dynamique du trafic, appelé P-ADRIP (Prevision subsystem - Adaptive multi-agent system for DRIVING behaviors Prevision). P-ADRIP met en oeuvre une stratégie de prévision en temps réel et à long terme qui garantit que la prévision de la dynamique du trafic est fournie et mise à jour tout au long de la vie du système.

## 2 État de l'art

Les recherches actuelles portent principalement sur les paramètres fondamentaux du flux de trafic tels que : la vitesse moyenne, le volume ou la densité avec différents horizons de prévision. Ces travaux sont principalement classés en deux catégories : les modèles paramétriques et les modèles non-paramétriques. Pour chaque catégorie, nous présentons ci-dessous les méthodes les plus utilisées [11].

### 2.1 Modèles paramétriques

Les modèles paramétriques sont basés sur les modèles de séries temporelles. Les modèles ARMA (Auto-Regressive Moving Average) sont bien adaptés pour la prévision du trafic à court terme [14]. Certaines variantes d'ARMA sont développées pour résoudre des problèmes de non-stationnarité, saisonnalité ou de dépendance spatio-temporelle.

Les modèles ARMA supposent que les informations futures du trafic ne dépendent linéairement que des valeurs précédentes (Auto-Régressif - AR) et de bruits aléatoires (Moyenne Mobile - MA) [1]. ARIMA (Auto-Regressive Integrated Moving Average), qui est une extension du modèle ARMA peut traiter des non-stationnarités en considérant les différences entre les observations consécutives. ARIMA a été appliqué de

façon prometteuse dans [1] pour étudier la prévision du temps de trajet dans les artères d'une ville. Dans [9], les auteurs ont appliqué un sous-ensemble d'ARIMA pour la prévision à court terme du volume de trafic. Le problème de saisonnalité a été traité avec SARIMA (Seasonal Auto-Regressive Integrated Moving Average). Dans [19], la base théorique de la prévision de l'état du trafic à l'aide de processus SARIMA est présentée. Le modèle SARIMA est également appliqué pour prévoir le flux du trafic [18] combiné à un modèle de lissage exponentiel. Selon les résultats obtenus, l'intégration des composantes saisonnières améliore la performance du modèle. Le modèle VARMA (Vector AutoRegressive Moving Average) est un modèle multivarié qui a été appliqué dans [8] pour considérer l'impact des mesures des segments voisins sur le segment actuel. Les résultats ont montré une amélioration significative de la performance de prévision lors de l'utilisation d'un modèle de série temporelle multivariée dans les cas d'un grand réseau routier et d'un nombre élevé de détecteurs de boucles.

Malgré l'amélioration des modèles paramétriques pour traiter les propriétés spécifiques des données de trafic, leur principal inconvénient est qu'ils ne peuvent pas résoudre les problèmes non linéaires. Ils obtiennent de bonnes performances lorsque le trafic présente des variations régulières, mais l'erreur de prévision devient significative lorsque des changements de situations se produisent.

### 2.2 Modèles non paramétriques

Les modèles non paramétriques utilisent des données historiques pour entraîner des modèles et calibrer des coefficients qui expriment l'impact des variables sur les valeurs futures. Parmi les nombreux modèles non paramétriques développés, nous nous concentrons sur les modèles similaires à P-ADRIP, comme le modèle des  $K$ -plus proches voisins (KNN), et qui répondent aux défis importants de l'analyse des séries temporelles.

KNN cherche les  $k$  historiques états de trafic les plus proches de l'état actuel du trafic et prédit les états futurs en observant les états suivants des  $k$  voisins. Dans [20], KNN a été appliqué pour la première fois à la prévision du flux de trafic. Une version améliorée de KNN pour la prévision du trafic a été introduite dans [2]. La grande précision obtenue montre la faisabilité de la méthode proposée pour la prévision du

flux de trafic à court terme sans contraintes de données. Cependant, le choix de la valeur optimale des paramètres du modèle pose la question de la robustesse. Le type simple de réseau de neurones (NN) appelé **le réseau de neurones à propagation avant (FFNN)** est appliqué dans [15] pour estimer le flux de trafic. Les auteurs de [13] ont utilisé un NN avec plusieurs couches cachées pour prédire la vitesse du trafic. Les résultats obtenus montrent que l'erreur quadratique moyenne diminue de 14% par rapport à une seule couche cachée. Les réseaux neuronaux sont flexibles et permettent d'intégrer les variables environnementales et d'autres informations sur le trafic ou les paramètres du trafic de la route voisine ou du capteur. Cependant, la capture des dépendances complexes et à long terme des séries temporelles de données de trafic est un grand défi pour les NN en raison de la complexité croissante du modèle. Les réseaux neuronaux récurrents (RNN) et leurs variantes, telles que le réseau **Long short-term memory (LSTM)** et le réseau **Gated Recurrent Unit (GRU)**, constituent un autre type de réseau neuronal capable de traiter la dépendance à long terme des séries temporelles. Les expériences dans [4], [21] ont montré que la performance de LSTM et GRU surpasse la performance d'ARIMA, NN et RNN traditionnels.

### 2.3 Discussion

L'état de l'art ci-dessus souligne les points suivants : premièrement, la complexité de la prévision du trafic à long terme est affirmée par la grande dépendance temporelle et spatiale. Deuxièmement, la plupart des méthodes existantes ne font pas évoluer leur modèle tout au long de la vie pour s'adapter à de nouvelles perceptions. Troisièmement, le passage à l'échelle est difficile de par l'exigence élevée de calcul. Il est nécessaire d'associer à ces méthodes des mécanismes de stockage et de manipulation efficaces. Finalement, les recherches existantes se concentrent sur la prévision des paramètres fondamentaux du trafic tels que : la vitesse moyenne ou la densité moyenne du trafic dans une fenêtre temporelle (ex.5 minutes). Cependant, ces paramètres ne sont pas suffisants pour représenter finement la dynamique du trafic ou les comportements de conduite sur un segment de route. Par exemple, nous ne pouvons pas déduire la variation de la vitesse des véhicules sur un segment de route entier.

Les limitations des approches actuelles incitent à aborder la prévision du trafic par SMA. En effet,

les SMA ont montré leur efficacité dans la résolution de problèmes complexes dans des environnements dynamiques et non linéaires en se basant sur la distribution des tâches entre les agents autonomes et coopératifs. De plus, les agents peuvent adapter localement leurs décisions pour s'adapter à des situations spécifiques grâce aux capacités d'auto-organisation. D'ailleurs, la décentralisation des SMA permet de paralléliser le calcul au niveau local, entraînant la réduction du temps de traitement pour les applications à grande échelle. Grâce à ces propriétés, nous considérons que les SMA sont pertinents pour représenter la dynamique du trafic. Dans la suite, nous proposons P-ADRIP - un SMA pour la prévision du trafic.

## 3 Le système multi-agent ADRIP

### 3.1 Architecture d'ADRIP

ADRIP (Adaptive multi-agent system for DRIVING behaviors Prevision) vise à traiter le problème de la prévision dynamique du trafic qui peut être décrit comme :

- Un ensemble de véhicules  $V = v_1; v_2; \dots; v_m$ . Chaque véhicule suit un itinéraire  $I$  constitué d'une séquence de segments de route notés  $I = \{rds_1, \dots, rds_N\}$ .
- Un ensemble de segments de route déterminés selon le réseau routier dans Open Street Map (OSM) ou des scénarios routiers simulés. Chaque segment de route est caractérisé par une position de départ et une position d'arrivée qui peuvent être localisées par des dispositifs GPS.

ADRIP est décomposé en deux sous-systèmes (L-ADRIP et P-ADRIP) qui fonctionnent en parallèle et en temps réel :

- L-ADRIP [12] : le sous-système d'apprentissage qui permet de classer dynamiquement **les comportements de conduite** des véhicules sur chaque segment de route, il est basé sur le flux de données perçu à partir des véhicules.
- P-ADRIP : le sous-système de prévision qui est l'objet de cet article, prédit les comportements de conduite sur chaque segment de route pour un horizon de prévision donné en utilisant la base des comportements de conduite appris.

L'architecture globale d'ADRIP est présentée dans la figure 1. Tout au long de son activité, le sous-système L-ADRIP fournit et met à jour




FIGURE 1 – Illustration d'ADRIP

la base de données locale de chaque segment de route. Cette base de données contient différents comportements de conduite appelés **profils de mobilité (MP)**. Le MP est défini comme la distribution du temps de passage sur le segment par rapport à différentes plages de vitesse. Chaque MP a des intervalles de temps associés appelés **plages d'utilisation (RU)** pendant lesquels les véhicules se sont déplacés à une certaine vitesse. Chaque MP a une liste de RU indiquant les moments où les véhicules d'une flotte se sont déplacés sur ce segment de route avec ce MP. La base de données apprise de L-ADRIP est composée des différentes bases de données locales apprises pour chaque segment. Ce mécanisme d'apprentissage est réalisé par un SMA adaptatif décrit dans [12].

Le sous-système P-ADRIP perçoit la situation actuelle et utilise des bases de données apprises pour prédire les comportements de conduite futurs sur l'ensemble du réseau pour un horizon de temps donné. Les prévisions de P-ADRIP sont mises à jour à chaque fois que des changements se produisent dans la situation actuelle ou dans la base de données apprise. Dans P-ADRIP, la prévision du trafic sur un réseau routier est effectuée par un SMA composé d'agents segment (SA). Chaque agent SA est associé à un segment de route du réseau routier et prédit le trafic sur ce segment.

### 3.2 Formalisation du problème de prévision locale

Pour envisager la prévision du trafic sur un réseau routier, ADRIP distribue la tâche globale au niveau local. Le problème de prévision locale est défini comme la prévision du trafic sur chaque segment de route du réseau par un agent SA. Pour cela, deux aspects majeurs sont considérés : la *corrélation spatiale* et la *dépendance temporelle*.

Premièrement, la corrélation spatiale est prise

en compte puisque la dynamique du trafic d'un segment de route est influencée par celle des segments de route voisins, en particulier la dynamique du trafic des segments de route en amont et en aval. Dans ADRIP, les agents SA communiquent avec leurs voisins pour demander les informations nécessaires à leur prévision locale. Les informations des SA voisins constituent une partie de l'entrée de l'algorithme de prévision défini comme une **Configuration**.

**Definition 1** La configuration à l'instant  $T$  du point de vue de l'agent SA est l'ensemble des MP et de leurs RU correspondants à  $T$  des agents SA voisins.

Deuxièmement, la dépendance temporelle est intégrée en analysant la base de données obtenue par l'apprentissage de L-ADRIP. La figure 2 montre la description de la base de données d'un agent SA obtenue par L-ADRIP. Les  $SA_1, \dots, SA_i, \dots, SA_N$  représentent l'ensemble des agents SA associés à l'ensemble des segments de route. Après le processus d'apprentissage, chaque  $SA_i$  peut observer la liste des différents comportements de conduite représentés par la liste des MP :  $\{MP_{i,1}, \dots, MP_{i,j}, \dots, MP_{i,L_i}\}$  avec  $L_i$  étant le nombre de MP de  $SA_i$ . Chaque  $MP_{i,j}$  possède une liste de RU :  $\{RU_{i,j,1}, \dots, RU_{i,j,k}, \dots, RU_{i,j,K_{i,j}}\}$  avec  $K_{i,j}$  le nombre de RU de  $MP_{i,j}$ .

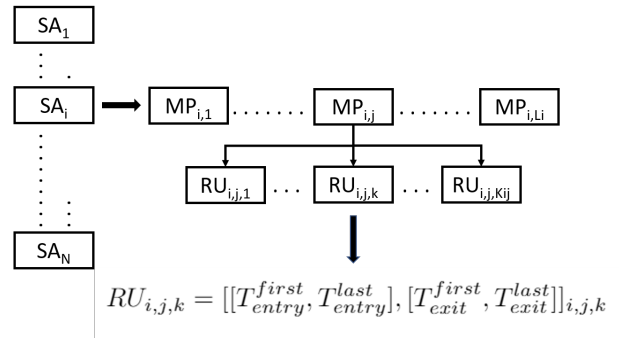


FIGURE 2 – Sortie de L-ADRIP

## 4 Les agents segment de P-ADRIP

Le comportement d'un agent SA est décomposé en deux parties : le comportement nominal et le comportement coopératif. Le comportement nominal consiste en l'ensemble des fonctions qui sont exécutées localement par les agents SA pour poursuivre leur but individuel. Le comportement coopératif définit l'ensemble des solutions proposées par les agents SA pour régler

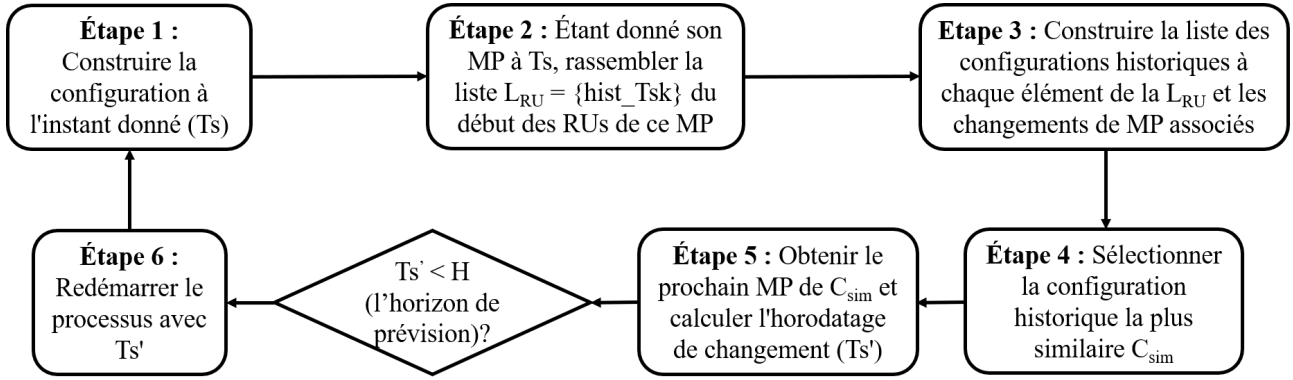


FIGURE 3 – Étapes principales du processus de prévision d'un agent SA

des situations spécifiques qui perturbent le comportement nominal appelées **des situations de non-coopération**.

#### 4.1 Comportement nominal

Le **comportement nominal** d'un agent SA dans P-ADRIP consiste à calculer l'enchaînement prédictif des différents changements de MP pour un horizon de prévision donné (20 minutes par exemple). À partir de l'instant courant ( $T_s$ ), l'agent SA lance l'algorithme de prévision dont les principales étapes sont illustrées à la figure 3 pour prédire le prochain MP et le timestamp auquel le changement de profil (MP) va se produire. Ce timestamp est également le début du prochain MP prédit. Si ce timestamp n'atteint pas l'horizon de prévision demandé, l'agent SA lance à nouveau l'algorithme de prévision en utilisant comme entrées le dernier MP calculé et son timestamp associé. Ce processus est répété jusqu'à ce que l'agent SA atteigne au moins l'horizon de prévision demandé.

À l'étape 4, l'agent SA compare la configuration à  $T_s$  et les configurations historiques pour sélectionner la plus similaire. Ainsi, pour chaque configuration historique calculée à l'étape 3, l'agent SA la compare à la configuration à  $T_s$  et calcule deux critères :

1. Le premier critère est le nombre d'agents SA voisins avec des MPs différents parmi les deux configurations.
2. Le deuxième critère se réfère à la comparaison de l'écart temporel entre le début du MP des SAs voisins et le début du MP du SA considéré. En effet, puisque le changement de dynamique du trafic sur un segment de route peut être entraîné par des changements de dynamique du trafic

sur ses voisins, ce critère vise à évaluer la différence du temps de propagation de la dynamique entre deux configurations. La figure 4 illustre le calcul de ce critère.




FIGURE 4 – Illustration du calcul de l'écart temporel du second critère

Pour chaque  $SA_i$  appartenant à l'ensemble des agents SA voisins,  $\Delta t_{T_s, SA_i}$  est la distance temporelle entre le début du MP sur SA ( $T_s$ ) et le début du MP de  $SA_i$  observé à  $T_s$ . De même,  $\Delta t_{hist\_Ts_k, SA_i}$  est la distance temporelle entre le début de MP de SA à un RU historique ( $hist\_Ts_k$ ) et le début du MP de  $SA_i$  observé à  $hist\_Ts_k$ . Ainsi, le deuxième critère s'exprime comme :

$$\begin{aligned}
 c_2(Conf_{T_s}, Conf_{hist}) &= \sum_{i=1}^M |\Delta t_{T_s, SA_i} - \Delta t_{Hist\_Ts_k, SA_i}| \\
 & \quad (1)
 \end{aligned}$$

où  $M$  est le nombre d'agents SA voisins.

La configuration historique la plus similaire avec la configuration à  $T_s$  est celle qui minimise les deux critères. À l'étape 5, le changement de MP associé à la configuration historique la plus similaire constitue le prochain MP prédictif de SA à  $T_s'$ .  $T_s'$  est calculé en décalant  $T_s$  vers l'avant pour un intervalle de temps égal à la taille du RU associé à la configuration choisie. Enfin, si

$Ts'$  atteint l'horizon de prévision, l'agent SA arrête l'algorithme, sinon, il relance le processus calculant la prévision à  $Ts'$  et stocke le prochain MP dans la chaîne des différents changements prédictifs de MP.

## 4.2 Comportement coopératif

Au cours de leur comportement nominal, les agents SA rencontrent des situations spécifiques qui perturbent leurs performances. Les comportements coopératifs sont définis pour faire face à ces situations spécifiques comme :

**Incompétence** : un agent SA ne peut pas construire la configuration complète requise à l'étape 1 car certains voisins n'ont pas encore estimé leur prévision à l'instant demandé, et ne peuvent donc pas l'envoyer à cet agent SA. **Solution proposée** : l'agent SA attend que les agents SA voisins qui ont un horizon de prévision plus court que le sien lancent leur processus de prévision avant. Lorsque les prévisions de ces agents SA sont mises à jour et que l'horizon de prévision du SA devient plus court que celui de ses agents SA voisins, il peut construire la configuration complète requise et commencer son processus de prévision. Ainsi, les agents SA réorganisent automatiquement et de manière adaptative leur exécution en fonction des différentes perceptions permettant une auto-organisation du système pour une prévision en continue.

**Improductivité** : un agent SA perçoit un nouveau MP et il ne peut pas trouver des successeurs de ce MP car il n'a jamais été perçu ou appris par L-ADRIP.

**Solution proposée** : P-ADRIP reste sur ce nouveau MP pour la prévision jusqu'à l'horizon de prévision. En parallèle, le processus d'apprentissage dynamique de l'agent SA (réalisé par L-ADRIP) intègre ce nouveau MP dans sa base de données locale et continue à apprendre des MP perçus. Si l'agent SA détecte que le MP prévu n'est pas celui appris par L-ADRIP, le mécanisme d'auto-correction de SA corrige la prévision. Ce mécanisme est réalisé par une fonction de contrôle de P-ADRIP qui sera étudiée dans la prochaine étape du projet.

**Ambiguïté** : un agent SA trouve plusieurs configurations historiques qui sont similaires avec la configuration à l'instant  $Ts$ . Il ne peut donc pas décider laquelle sera la prévision.

**Solution proposée** : dans ce cas, les configurations sont considérées comme équivalente,

l'agent SA va sélectionner la configuration la plus récente. En cas de mauvaise prévision, le mécanisme d'auto-correction sera sollicitée.

## 5 Expérimentations

Dans cette section, nous présentons les expérimentations pour valider le comportement de P-ADRIP et le comparer avec des modèles connus de prévision de trafic.

### 5.1 Génération de données




FIGURE 5 – Le scénario de l'OSM (à gauche) et sa projection dans GAMA

Les expériences sont réalisées sur la plateforme GAMA (GIS Agent-based Modelling Architecture) [5]. GAMA permet de charger des réseaux routiers à partir de fichiers de forme ou de fichiers d'OSM (Open Street Map) pour réaliser la simulation sur un réseau routier réel. Pour cette étude, le scénario se situe sur le campus de l'Université Toulouse III Paul Sabatier à Toulouse et comprend 63 segments de route (cf. figure 5). Les caractéristiques des agents SA sont extraites de l'OSM [7]. Le comportement des véhicules est défini selon le modèle proposé par [16] nommée Advanced Driving Skill. Le nombre de véhicules à chaque instant de la simulation est fixé à 200 ce qui permet de présenter une diversité de dynamiques de trafic. Dès qu'un véhicule termine sa trajectoire, il est remplacé par un nouveau afin que le nombre total de véhicules pendant la simulation soit toujours de 200. La position de démarrage de chaque véhicule et sa trajectoire sont choisies aléatoirement. Ainsi, bien que le nombre total d'agents soit fixe, le flux de trafic sur chaque segment de route varie dans le temps, entraînant des dynamiques de conduite différentes. Le trafic a été simulé sur ce scénario pendant 3 heures pour l'échantillon

d'apprentissage et ensuite pendant 1 heure pour l'échantillon de test, totalisant 9520 trajectoires de véhicules.

## 5.2 Prétraitement des données

À partir de la simulation, nous obtenons les données de la trajectoire du véhicule contenant la vitesse à chaque position GPS identifiée par la longitude et la latitude. Les méthodes présentées dans l'état de l'art sont testées en utilisant les données formant la série temporelle de la vitesse moyenne sur les segments de route à chaque  $f$  minutes ( $f$  est la fréquence de la série temporelle). Ainsi, nous faisons la moyenne des vitesses de tous les véhicules sur chaque segment de route toutes les 10 secondes pour obtenir des séries temporelles de vitesse moyenne à une fréquence de 10s. De plus, les données collectées doivent également être normalisées à l'aide de *MinMaxScaler* pour éviter de dégrader les performances des modèles d'apprentissage lors de l'optimisation du gradient pour FFNN, LSTM, GRU et pour assurer un poids égal à chaque variable dans la mesure de la distance pour KNN. En outre, la fonction de transformation *StandardScaler* est appliquée pour les modèles VARMA et ARIMA afin de garantir l'échelle cohérente des données dans différentes séries temporelles. Ces fonctions sont implémentées dans la bibliothèque *sklearn* de Python.

Pour ADRIP, les données de trajectoire des véhicules sont segmentées en fonction du réseau routier et ces données segmentées sont transformées en MP. Le MP est la distribution du temps de parcours sur 7 plages de vitesse qui sont [0%, 5%], [5%, 10%], [10%, 20%], [20%, 30%], [30%, 40%], [40%, 60%], [60%, 200%] de la limite de vitesse du segment de route. La dernière plage de vitesse est étendue arbitrairement à 200% de la vitesse limitée afin de couvrir certains dépassements de vitesse qui se produisent parfois. Nous observons la vitesse du véhicule au cours du temps et comptons le temps de déplacement correspondant à chaque plage de vitesse. Ces MP sont construits localement par le véhicule puis sont communiqués et traités par L-ADRIP pour apprendre les profils historiques du segment considéré.

## 5.3 Paramètres

Pour ARIMA, les paramètres sont (30, 0, 1) présentés dans l'article [10] sauf le nombre de valeurs précédentes utilisées que nous avons fixé

à 30 pour s'adapter à notre plan d'expérience. Le modèle est implémenté en utilisant la librairie Python *statsmodel*.

Pour VARMA, le modèle est appliqué avec un nombre de lags fixé à 30 et est mis en oeuvre à l'aide de la librairie Python *statsmodel*.

Pour KNN, la valeur optimale de  $k$  (nombre de voisins les plus proches) est fixée à 18 selon [20].

Pour FFNN, le réseau a 2 couches cachées, chaque couche contient 256 unités. Les paramètres du réseau sont issus de [10].

Pour les modèles LSTM, GRU<sup>1</sup>, les cellules du modèle sont implémentées en utilisant la librairie *keras.layers.recurrent*. Ces modèles ont 2 couches cachées avec 64 unités et 1 couche dense avec 30 unités.

## 5.4 Critères d'évaluation

Pour comparer la performance des méthodes considérées pour la prévision de la vitesse moyenne, 2 métriques sont adoptées : MAE et RMSE (Racine de l'erreur quadratique moyenne).

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| ; RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (2)$$

où  $y_i$  est la valeur réelle,  $\hat{y}_i$  est la valeur prédite et  $N$  est le nombre de points de données.

De plus, pour évaluer la performance de ADRIP pour la prévision des MP, nous définissons la métrique de la **différence de MP**.

$$MPDiff(MP^k, MP^l) = (|MP_i^k - MP_i^l|)_{i=1, \dots, N} \quad (3)$$

où  $N$  est le nombre de plages de vitesse,  $MP_i^k$  and  $MP_i^l$  sont les valeurs du temps de déplacement correspondant à la plage de la  $i$ ème vitesse.

## 5.5 Résultats et analyse

Nous comparons d'abord ADRIP avec les méthodes choisies pour la prévision de la vitesse moyenne pour les 5 prochaines minutes. Les méthodes comparées prennent en entrée la vitesse moyenne des 5 dernières minutes. Bien que l'horizon de prévision ne soit que de 5 minutes, notre expérience peut être considérée comme un test à

1. Le code Python se trouve à l'adresse suivante : <https://github.com/xiaochus/TrafficFlowPrediction>.



	Métrique	VARMA	ARIMA	KNN	FFNN	LSTM	GRU	<b>ADRIP</b>
Moyenne sur 4 segments	MAE	1.51	1.51	1.50	1.59	1.59	1.72	<b>1.31</b>
	RMSE	2.42	2.36	2.40	2.54	2.52	2.69	<b>1.77</b>
1er segment	MAE	1.05	1.09	0.96	1.02	0.95	0.96	<b>1.00</b>
	RMSE	1.80	1.68	1.62	1.72	1.59	1.72	<b>1.41</b>
2ème segment	MAE	1.10	1.16	1.08	1.13	1.03	1.05	<b>0.91</b>
	RMSE	2.15	2.10	2.09	2.11	2.05	2.05	<b>1.42</b>
3ème segment	MAE	2.44	2.41	2.58	2.80	2.95	3.49	<b>1.80</b>
	RMSE	3.82	3.77	4.05	4.42	4.57	5.28	<b>2.40</b>
4ème segment	MAE	1.43	1.40	1.38	1.41	1.42	1.38	<b>1.52</b>
	RMSE	1.91	1.90	1.82	1.89	1.88	1.82	<b>1.83</b>

TABLE 1 – Evaluation des méthodes de l’état de l’art et ADRIP sur les 4 segments de route

long terme en ce qui concerne la fenêtre de données à 10s puisque cet horizon correspond aux 30 prochains points de données. Contrairement aux tests réalisés dans d’autres articles, nous visons à obtenir toutes les valeurs prédictives entre le timestamp actuel et les 5 prochaines minutes. Ainsi, la variable de réponse est un vecteur de taille 30.

Nous sélectionnons 4 segments de route (montrés en rouge sur la figure 5) du scénario de test. Ces segments possèdent la plus grande diversité de dynamiques de trafic. En effet, ces segments de route sont intéressants pour l’évaluation des méthodes de prévision du trafic car ils montrent l’aptitude des méthodes à capturer l’évolution complexe des données de trafic. Le tableau 1 résume les résultats obtenus. Notez que la prévision obtenue par ADRIP est le MP, ainsi, les vitesses moyennes prédites à chaque 10s sont déduites en utilisant l’expression suivante :

$$\bar{v}_t = \frac{l}{\sum_{i=1}^N MP_t^i} \quad (4)$$


où  $\bar{v}_t$  est la vitesse moyenne à l’instant  $t$ ,  $l$  est la longueur du segment de route,  $N$  est le nombre de plages de vitesse dans le MP et  $MP_t^i$  est le temps de déplacement du véhicule dans la plage de la  $i$ ème vitesse du MP à l’instant  $t$ . La somme  $\sum_{i=1}^N MP_t^i$  donne le temps de déplacement total lorsque les véhicules se déplacent avec le  $MP_t$ .

Premièrement, les erreurs moyennes sur 4 segments de route montrent que P-ADRIP obtient la meilleure performance moyenne pour les deux paramètres d’évaluation, ce qui témoigne de l’efficacité de la modélisation de la dépendance spatio-temporelle. Deuxièmement, dans le cadre de cette étude n’utilisant que des données simulées, on note que KNN - un modèle non paramétrique simple - présente des résultats similaires aux modèles paramétriques (ARIMA


et VARMA). Troisièmement, FFNN et les modèles basés sur RNN (LSTM, GRU) donnent de moins bonnes performances que KNN et les modèles linéaires. Cela peut venir de la dégradation causée par la complexité du modèle ou à l’insuffisance de l’ensemble des données d’apprentissage. Cette remarque renforce l’avantage de P-ADRIP comme une solution efficace pour la dépendance spatio-temporelle complexe dans la prévision du trafic avec une taille raisonnable de l’ensemble de données.

Ensuite, en considérant le détail de la performance du modèle sur chaque segment de route, nous observons les remarques suivantes. Pour les 2ème et 3ème segments de route, P-ADRIP surpasse les méthodes de l’état de l’art pour les deux métriques d’évaluation, ce qui est cohérent avec l’interprétation des résultats moyens. Cependant, pour les 1er et 4ème segments de route, P-ADRIP donne parfois un RMSE plus faible mais un MAE plus élevé par rapport aux autres modèles. Puisque RMSE pénalise plus sévèrement les grandes erreurs que MAE, nous pouvons déduire de ce phénomène que P-ADRIP fait plus de petites erreurs mais moins de grandes erreurs que les autres méthodes.


Ensuite, nous évaluons la précision de prévision de P-ADRIP pour différents horizons. La figure 6 montre l’erreur de prévision moyenne pour chaque plage de vitesse sur les 4 segments de route choisis pour les horizons à 2 minutes, 3 minutes, 4 minutes et 5 minutes. Nous observons que P-ADRIP n’augmente pas fortement l’erreur de prévision lorsque l’on étend l’horizon de prévision. Ce résultat permet de confirmer la capacité d’ADRIP pour les prévisions de trafic à long terme. Cette figure 6 souligne également la capacité de P-ADRIP à prédire localement au niveau de chaque segment la dynamique du trafic se distinguant des méthodes classiques de prévision de la vitesse moyenne.




(a) 1er segment



(b) 2ème segment



(c) 3ème segment



(d) 4ème segment

FIGURE 6 – Erreur de prévision moyenne par plage de vitesse avec les différents horizons de prévision

## 6 Conclusions et perspectives

Dans cet article, nous proposons le SMA P-ADRIP qui fournit des prévisions de trafic sur tout un réseau routier à partir de profils de mobilité appris en temps réel sur ses segments. Avec L-ADRIP introduit dans [12], P-ADRIP complète la fonctionnalité globale d'ADRIP. P-ADRIP montre sa capacité à traiter les problèmes de dépendance spatio-temporelle de la prévision du trafic en se basant sur deux mécanismes principaux. Premièrement, la dépendance temporelle est étudiée en analysant la base de données historique locale apprise pour chaque segment de route. Deuxièmement, l'analyse de la dépendance spatiale est basée sur l'échange d'informations avec les segments routiers voisins.

P-ADRIP a été comparé aux méthodes les plus utilisées sur la plateforme GAMA. Le test de comparaison pour la prévision de la vitesse moyenne montre que P-ADRIP est meilleur dans le cas de fortes variations de trafic mais moins efficace dans le cas de variations de trafic réduites. L'erreur de prévision dépend du choix du

seuil de similarité, pour lequel nous effectuons une étude de sensibilité. De plus, ADRIP peut fournir la prévision des profils de mobilité qui est une représentation plus fine de la dynamique du trafic que la vitesse moyenne. Le test de prévision avec différents horizons montre la capacité d'ADRIP pour la prévision à long-terme.

Par rapport aux méthodes existantes, notre solution présente de multiples avantages : (1) intègre de nombreuses propriétés des données de trafic, telles que la non linéarité et la dépendance spatio-temporelle sans augmenter la complexité du modèle grâce à des décisions décentralisées, (2) inclut des modèles sans paramètres, (3) permet la prévision dynamique et en temps réel, (4) adapte la décision en fonction de l'évolution de l'environnement et (5) demande un temps de calcul et une capacité de calcul réduits grâce au mécanisme distribué.

Si les simulations ont permis de maîtriser les conditions d'évaluation des performances de plusieurs modèles, nous souhaitons dans l'immédiat appliquer P-ADRIP sur des ensembles

réels de données à grande échelle afin de renforcer son efficacité et sa fiabilité. Ensuite, nous intégrerons un mécanisme de contrôle pour P-ADRIP qui permet automatiquement de détecter, corriger l'erreur de prévision et la mettre à jour en temps réel. De plus, la base de données apprises peut contenir des informations du trafic obsolètes qui ne reflète plus le contexte actuel, par exemple en raison d'un changement des caractéristiques de la route (i.e. ajout d'un feu rouge). En filtrant ces données, la prévision sera plus précise. Finalement, un point intéressant que nous souhaitons étudier concerne l'influence de la réaction du véhicule sur la performance du système de prévision. En effet, avec des prévisions fiables, les véhicules pourront adapter leur comportement entraînant le changement de la dynamique du trafic.

## Références

- [1] Daniel Billings and Jiann-Shiou Yang. Application of the arima models to urban roadway travel time prediction-a case study. In *2006 IEEE International Conference on Systems, Man and Cybernetics*, volume 3, pages 2529–2534. IEEE, 2006.
- [2] Pinlong Cai, Yunpeng Wang, Guangquan Lu, Peng Chen, Chuan Ding, and Jianping Sun. A spatio-temporal correlative k-nearest neighbor model for short-term traffic multistep forecasting. *Transportation Research Part C : Emerging Technologies*, 62 :21–34, 2016.
- [3] Giovanna Di Marzo Serugendo, Marie-Pierre Gleizes, and Anthony Karageorgos. Self-organising software : From natural to artificial adaptation, 2011.
- [4] Rui Fu, Zuo Zhang, and Li Li. Using lstm and gru neural network methods for traffic flow prediction. In *2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC)*, pages 324–328. IEEE, 2016.
- [5] Arnaud Grignard, Patrick Taillandier, Benoit Gaudou, Duc An Vo, Nghi Quang Huynh, and Alexis Drogoul. Gama 1.6 : Advancing the art of complex agent-based modeling and simulation. In *International conference on principles and practice of multi-agent systems*, pages 117–131. Springer, 2013.
- [6] Maxime Guériau, Frédéric Armetta, Salima Hasas, Romain Billot, and Nour-Eddin El Faouzi. A constructivist approach for a self-adaptive decision-making system : application to road traffic control. In *2016 IEEE 28th International Conference on Tools with Artificial Intelligence (ICTAI)*, pages 670–677. IEEE, 2016.
- [7] Mordechai Haklay and Patrick Weber. Openstreetmap : User-generated street maps. *IEEE Pervasive computing*, 7(4) :12–18, 2008.
- [8] Yiannis Kamarianakis and Poulicos Prastacos. Forecasting traffic flow conditions in an urban network : Comparison of multivariate and univariate approaches. *Transportation Research Record*, 1857(1) :74–84, 2003.
- [9] Sangsoo Lee and Daniel B Fambro. Application of subset autoregressive integrated moving average model for short-term freeway traffic volume forecasting. *Transportation Research Record*, 1678(1) :179–188, 1999.
- [10] Yaguang Li, Rose Yu, Cyrus Shahabi, and Yan Liu. Diffusion convolutional recurrent neural network : Data-driven traffic forecasting. *arXiv preprint arXiv :1707.01926*, 2017.
- [11] Attila M Nagy and Vilmos Simon. Survey on traffic prediction in smart cities. *Pervasive and Mobile Computing*, 50 :148–163, 2018.
- [12] Ha-Nhi Ngo, Elsy Kaddoum, Marie-Pierre Gleizes, Jonathan Bonnet, and Goursolle Anaïs. Life-long learning system of driving behaviors from vehicle data streams. In *2021 IEEE International Intelligent Transportation Systems Conference (ITSC)*, pages 1132–1139. IEEE, 2021.
- [13] Nicholas G Polson and Vadim O Sokolov. Deep learning for short-term traffic flow prediction. *Transportation Research Part C : Emerging Technologies*, 79 :1–17, 2017.
- [14] Brian L Smith, Billy M Williams, and R Keith Oswald. Comparison of parametric and nonparametric models for traffic flow forecasting. *Transportation Research Part C : Emerging Technologies*, 10(4) :303–321, 2002.
- [15] Shiliang Sun, Rongqing Huang, and Ya Gao. Network-scale traffic modeling and forecasting with graphical lasso and neural networks. *Journal of Transportation Engineering*, 138(11) :1358–1367, 2012.
- [16] Patrick Taillandier. Traffic simulation with the gama platform. In *Eighth International Workshop on Agents in Traffic and Transportation*, pages 8–p, 2014.
- [17] Nicolas Verstaevael, Jérémy Boes, Julien Nigon, Dorian d'Amico, and Marie-Pierre Gleizes. Lifelong machine learning with adaptive multi-agent systems. In *9th International Conference on Agents and Artificial Intelligence (ICAART 2017)*, volume 2, pages pp–275, 2017.
- [18] Billy M Williams, Priya K Durvasula, and Donald E Brown. Urban freeway traffic flow prediction : application of seasonal autoregressive integrated moving average and exponential smoothing models. *Transportation Research Record*, 1644(1) :132–141, 1998.
- [19] Billy M Williams and Lester A Hoel. Modeling and forecasting vehicular traffic flow as a seasonal arima process : Theoretical basis and empirical results. *Journal of transportation engineering*, 129(6) :664–672, 2003.
- [20] Lun Zhang, Qiuchen Liu, Wenchen Yang, Nai Wei, and Decun Dong. An improved k-nearest neighbor model for short-term traffic flow prediction. *Procedia-Social and Behavioral Sciences*, 96 :653–662, 2013.
- [21] Zheng Zhao, Weihai Chen, Xingming Wu, Peter CY Chen, and Jingmeng Liu. Lstm network : a deep learning approach for short-term traffic forecast. *IET Intelligent Transport Systems*, 11(2) :68–75, 2017.