



HAL
open science

Prévision court terme des temps de parcours. Synthèse bibliographique des différentes méthodes et expérimentations

Guillaume Costeseque

► To cite this version:

Guillaume Costeseque. Prévision court terme des temps de parcours. Synthèse bibliographique des différentes méthodes et expérimentations. [Rapport Technique] Cerema - Centre d'Etudes et d'Expertise sur les Risques, l'Environnement, la Mobilité et l'Aménagement. 2019. hal-03288122

HAL Id: hal-03288122

<https://hal.science/hal-03288122v1>

Submitted on 16 Jul 2021

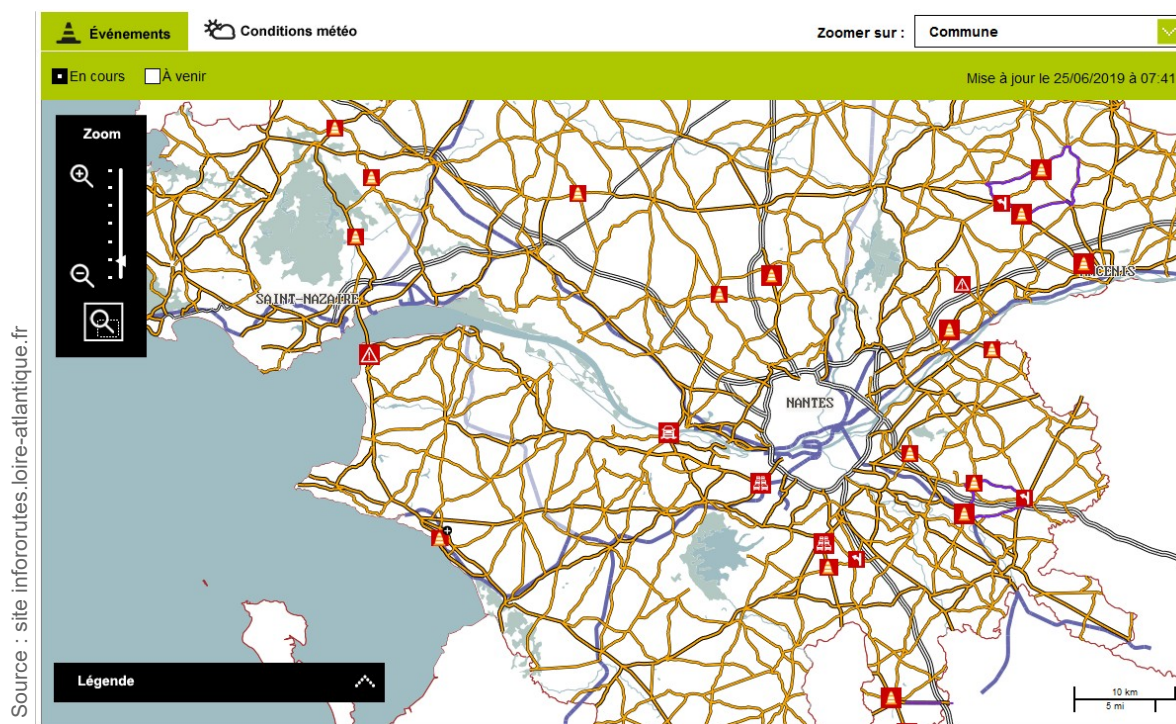
HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

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.

Prévision court terme des temps de parcours

Synthèse bibliographique des différentes méthodes et expérimentations

Juillet 2019



Partenaire de l'étude : Conseil Départemental de Loire Atlantique



Prévision court terme des temps de parcours

Synthèse bibliographique des différentes méthodes et expérimentations

Historique des versions du document

Version	Date	Commentaire
V1	18/07/19	Version avant commentaires des partenaires CD44

Affaire suivie par

Guillaume COSTESEQUE - Département Mobilités et Infrastructures – Groupe Sécurité et Optimisation des Déplacements
Tél. : 02 40 12 83 25 / Fax : Xx xx xx xx xx
Courriel : guillaume.costeseque@cerema.fr
Site de Nantes : Cerema Ouest – MAN – 9 rue René Viviani – BP 46223 – 44262 NANTES cedex 02

Références

N° d'affaire : C19OI0077 action de la convention cadre signée en janvier entre le CD44 et le Cerema
Maître d'ouvrage : Département de Loire-Atlantique (M. Aumoitte)
Fiche action signée le 02/05/2019

Rapport	Nom	Date	Visa
Établi par	Guillaume COSTESEQUE	12/07/19	
Avec la participation de	Nicolas DITCHI, Wilhémine LECOINTRE		
Contrôlé par	Marie-Amélie HORVATH	17/07/19	
Validé par	Anne GREGOIRE	18/07/19	

Résumé de l'étude :

Ce rapport a pour objectif de réaliser un état de l'art synthétique des méthodes utilisées pour la prévision à court terme du trafic routier. Ainsi, les deux principales familles méthodologiques sont présentées : la première englobe les approches statistiques, c'est-à-dire basées sur de l'analyse de données ; la seconde regroupe les approches s'appuyant sur la modélisation dynamique de l'écoulement du trafic. Ce rapport recense également un certain nombre d'outils, notamment à destination des gestionnaires routiers et liste certaines expérimentations récentes ou en cours.

SOMMAIRE

1 PRÉLIMINAIRES.....	5
1.1 Contexte opérationnel du Conseil Départemental de Loire Atlantique (CD44).....	5
1.2 Quelques définitions.....	6
1.3 Généralités sur la prévision.....	7
1.4 Source des données.....	8
2 MÉTHODES DE PRÉVISION.....	9
2.1 Méthodes statistiques (<i>data driven</i>).....	10
Méthodes de prévision par analyse de séries temporelles.....	10
Méthodes de prévision par apprentissage automatique.....	11
Avantages et inconvénients des méthodes statistiques.....	14
2.2 Approches phénoménologiques (<i>model driven</i>).....	16
Modèles microscopiques du trafic.....	16
Modèles macroscopiques du trafic.....	17
Modèles mésoscopiques du trafic.....	17
Hybridation de modèles d'écoulement.....	18
Avantages et inconvénients des méthodes phénoménologiques.....	18
2.3 Hybridation.....	19
2.4 Vue synthétique des méthodes de prévision à court terme.....	19
3 OUTILS ET EXPÉRIMENTATIONS.....	20
3.1 Outils pour les gestionnaires de voiries.....	20
Outils développés par des industriels.....	20
3.1.1 PTV Optima.....	20
3.1.2 Aimsun Live.....	21
Outils développés par des laboratoires de recherche.....	22
3.2 Outils pour les usagers grand public.....	23
4 CONCLUSION.....	24
5 REMERCIEMENTS.....	25
6 BIBLIOGRAPHIE.....	25

1 Préliminaires

Cette synthèse bibliographique se propose de donner un aperçu des différentes méthodes de prévision à court terme des temps de parcours. Ce document présente également quelques expérimentations ou outils existants de prévision.

Ce travail s'appuie grandement sur des éléments issus de la note d'information éditée par le SETRA (désormais Cerema Direction Technique Infrastructures de Transport et Matériaux) et rédigée dans le cadre du Pôle de Compétence et d'Innovation Régulation Dynamique des Réseaux de Transport au CETE de Lyon (Centre d'Études Techniques, désormais Cerema Direction Territoriale Centre-Est) par Fabrice RECLUS, en mars 2012. Les informations issues du rapport de CETE ont été actualisées et complétées au moyen d'une recherche bibliographique des articles scientifiques publiés récemment sur le sujet. Ceux-ci sont référencés en dernière section de ce travail. Une revue des expérimentations ayant été réalisées ces dernières années en France et dans le monde, est également proposée.

1.1 Contexte opérationnel du Conseil Départemental de Loire Atlantique (CD44)

Le CD44 dispose de capteurs Bluetooth sur trois itinéraires départementaux qui leur permettent de disposer des temps de parcours expérimentés par les usagers qui viennent de sortir de la zone de détection. On parle de temps de parcours reconstitué sortant (TPRS). Dans des conditions de trafic stationnaires (fluide ou totalement congestionné), ce sont les temps de parcours que vont expérimenter les usagers entrant sur le secteur ; ils peuvent être diffusés sans ajustement. En revanche, pour des conditions non stationnaires (apparition ou résorption de la congestion), ces temps de parcours sortant ne reflètent pas les temps de parcours que vont connaître les usagers entrant. Pour une information fiable, l'enjeu est de proposer des temps de parcours reconstitués entrant (TPRE). Les temps de parcours sortant peuvent être stockés pour réaliser a posteriori (temps différé) des analyses sur la congestion (temps moyens, distribution des temps passés...), mais ils ne sont pas destinés à être communiqués sans traitement.

Pour l'information en temps réel à destination des usagers, les temps de parcours proviennent en général du réseau de boucles de détection (stations SIREDO) des gestionnaires de réseau de type VSA (Voirie structurante d'agglomération) qui fournissent des données de vitesse exploitées pour calculer des temps de parcours par tronçon selon la méthode dite des « vitesses ». Cette méthode nécessite un réseau de boucles suffisamment dense (typiquement une boucle tous les 500 m) pour détecter correctement l'évolution de la congestion dans l'espace. L'algorithme basique de traitement des données peine cependant à bien estimer le temps prévisible pour l'utilisateur entrant (Cerema Est, Retour d'expérience Rocade Est de Lyon). Il s'appuie en effet sur le temps de parcours instantané (à l'instant t) mesuré sur tous les tronçons constituant l'itinéraire choisi. Or la situation est susceptible d'avoir évolué au moment où l'utilisateur parcourt cet itinéraire.

L'exploitation des capteurs Bluetooth pour produire des données de temps de parcours est expérimentée par différents gestionnaires de réseau. Les capteurs sont assez peu coûteux, non intrusifs et permettent une production en régie de la donnée. Par rapport aux boucles, les capteurs Bluetooth présentent l'avantage de fournir directement des données

de temps de parcours et de pouvoir être positionnés relativement librement de manière à capter au mieux les phénomènes de congestion. Par rapport aux données mobiles ou FCD (voir Section 1.4 ci-après), l'intérêt des capteurs Bluetooth est de fournir directement une donnée de temps de parcours dont l'algorithme de traitement peut être totalement maîtrisé.

Différentes évaluations ont été menées ou sont en cours par le Cerema pour comparer les temps de parcours obtenus à différentes techniques : FCD, LAPI, Bluetooth, SIREDO (Rocade Est de Lyon par le Cerema Est – Bluetooth Karrus, Projet Syncro en Isère avec le CD38 par le Cerema Est, A6 par le Cerema Île-de-France – Bluetooth Neavia et Magsys). En première lecture, les résultats disponibles montrent une bonne capacité des Bluetooth à produire des temps de parcours fiables comme les LAPI (temps de parcours reconstitués sortants). Une tendance à sous-estimer les temps de parcours (en régime fluide et en régime dense) a été identifiée. L'origine en est attribuée aux algorithmes de filtrage et de traitement. En revanche, les écarts par rapport aux temps de parcours de référence LAPI ne sont pas constants sur tous les pas de temps : parfois sur-estimation, parfois sous-estimation. Ceci peut poser des difficultés pour des exploitations à des fins de prévision, si le comportement ne traduit pas l'évolution réelle de la congestion. Le nombre de détections disponibles pour calculer les temps de parcours est parfois faible, et une analyse plus fine des possibilités de disposer de données fiables sur un pas de temps faible (1 min, 3 min) serait également à mener.

Des évaluations ont également été menées entre temps de parcours affichés à l'utilisateur et temps de parcours réellement expérimenté. L'INRETS (désormais IFSTTAR) et la DD38 ont réalisé des comparaisons sur la liaison Grenoble – Le Bourg d'Oisans équipée dans les années 2000 de plusieurs LAPI pour permettre des affichages de temps de parcours sur PMV avec un algorithme de calcul mis au point par l'INRETS. La DIR Nord-ouest et la métropole de Rouen ont installé des balises Bluetooth sur leur réseau pour communiquer des temps de parcours en direction des usagers. Le Cerema Normandie-Centre a participé à l'évaluation des temps de parcours annoncés par comparaison à des mesures par LAPI. Les méthodes de prévision retenues et les résultats obtenus restent à analyser.

1.2 Quelques définitions

Avant d'entrer dans la revue bibliographique à proprement parler, il est important pour le lecteur de définir clairement l'objet sur lequel porte cette étude, à savoir la *prévision court terme des temps de parcours*. La prévision ou prédiction est ici entendue comme l'action de prévoir, c'est-à-dire de déterminer à partir de certaines données, passées et présentes, quel sera l'état futur d'un système physique (c'est aussi vrai pour un système social, politique ou économique) déterminé. Prévoir est souvent une étape importante pour les personnes qui veulent anticiper l'évolution du système en question pour mieux décider, agir ou contrôler le système par des actions appropriées. Comme l'écrivait Alexandre Dumas, fils : « voir c'est savoir, et savoir c'est prévoir »¹.

Le système physique d'intérêt dans le cadre de cette étude est le trafic routier sur un axe donné. Le système « trafic routier » est caractérisé par des variables quantitatives (la densité, le débit, la vitesse de circulation ou le temps de parcours entre différents repères spatiaux) ou qualitatives (état fluide ou congestionné, avec éventuellement des gradations d'états). Les caractéristiques de l'état futur du système s'apprécie pour un horizon temporel bien précis.

Bien qu'il n'existe pas de définition objective de ce qui relève du court, moyen ou du long

1 Alexandre Dumas, fils ; Une lettre sur les choses du jour (1871).

terme, voici la distinction qui a été faite dans le cadre de ce travail :

- La prévision à **très long terme** en trafic routier correspond à la volonté des gestionnaires et décideurs publics d'anticiper l'évolution de la demande de transport sur un réseau généralement étendu d'infrastructures afin d'en concevoir l'aménagement. Il est commun de parler de planification. L'horizon temporel est souvent supérieur à plusieurs années. Il s'agit par exemple de prévoir l'évolution des volumes de déplacements d'une zone géographique d'une agglomération vers une autre zone afin d'adapter les infrastructures ou de proposer des modes de transport alternatifs.
- Le **long terme** désigne la prévision réalisée sur un horizon annuel ou mensuel avec une granularité à l'échelle de la journée. Il s'agit pour un gestionnaire de connaître les volumes de trafic journalier sur son réseau lors de grands événements comme les départs ou les retours de vacances, en fonction d'éléments calendaires comme les vacances scolaires ou les jours fériés, afin de planifier son calendrier d'intervention et les mesures de gestion adéquates. Le calendrier de prévision de trafic produit par Bison Futé pour chaque année en est un exemple ². La prévision se base sur les relevés historiques de trafic moyen journalier.
- La prévision à **moyen terme** a pour horizon temporel un ou plusieurs jours, avec une finesse horaire. Les prévisions à moyen terme portent sur les volumes de trafic heure par heure, en tenant compte des éléments de prévision météorologique (conditions extrêmes comme chute de neige ou pluviométrie exceptionnelle) et l'affinage des prévisions long terme à la veille des grands départs (Bison Futé).
- Le terme **court terme** est associé à la prévision à un horizon temporel horaire ou sous-horaire. La précision est de l'ordre de grandeur de la minute. Cette échelle de prévision est tout particulièrement l'objet de cette étude bibliographique.

1.3 Généralités sur la prévision

Après avoir précisé l'objet de cette revue de l'état de l'art en termes de *prévision à court terme des temps de parcours*, il semble utile de rappeler quelques généralités sur l'action de *prévoir*.

Il est tout d'abord légitime de se demander s'il est raisonnable de vouloir prévoir un événement futur pour un système physique complexe comme le trafic routier et d'accorder à cette prévision un haut niveau de confiance. Dans bien des domaines, il est commun de constater que la prévision n'est pas une science parfaitement mature. Prenons pour illustration l'exemple de la prévision météorologique qui, malgré des méthodes, des moyens et des données qui ne cessent de se multiplier et de s'améliorer, produit des résultats non exempts d'erreurs. Cela est notamment dû à la complexité de représenter fidèlement les phénomènes physiques en œuvre et leurs interactions. Cela est également le cas avec le trafic routier qui est un système fortement non-linéaire, instationnaire et stochastique. Il est par nature, impossible de connaître avec une absolue certitude la réalisation d'événements aléatoires exogènes ou intrinsèques comme un accident ou une panne. La compréhension du phénomène physique peut en revanche permettre d'évaluer les conséquences directes comme la propagation d'une congestion.

Il est donc nécessaire de ne pas oublier que les prévisions peuvent être erronées. En corollaire, il devient important de s'attacher à qualifier chaque prévision par un intervalle de confiance, un degré de fiabilité ou une probabilité d'occurrence plus ou moins élevée.

Le second point de ces généralités concerne l'usage et les utilisateurs potentiels de ces prévisions de trafic à court terme. En effet, les attentes sont aussi diverses que le sont les

2 <https://www.bison-fute.gouv.fr/calendrier-bison-fute,10739.html>

potentiels destinataires de ces prévisions. Nous distinguons ainsi les usagers « grand public » des usagers professionnels. Pour la première catégorie des utilisateurs grand public que sont généralement les voyageurs empruntant l'infrastructure routière, l'objectif est de disposer d'informations fiables sur le temps de parcours qu'ils vont expérimenter lors de leur trajet et de connaître une estimation de leur heure d'arrivée à destination. En ayant cette estimation prévisionnelle, les voyageurs peuvent décider soit de reporter leur heure de départ, soit de favoriser un autre mode de transport ou encore de choisir un itinéraire différent.

Parmi les utilisateurs professionnels, nous distinguons d'une part les professionnels de la route comme les personnes travaillant pour le transport de marchandises (logistique, livraisons) et le transport de personnes (taxis, VTC) et d'autre part les gestionnaires de réseaux routiers. Pour les premiers, les attentes vis-à-vis de la prévision sont relativement proches de celles des usagers « grand public », à savoir pouvoir estimer les conditions futures de circulation pour optimiser leurs itinéraires, connaître leurs temps prévisionnels de trajet et en informer leurs éventuels clients ou passagers. Pour les seconds, un algorithme de prévision peut être intégré à un outil d'aide à la décision pour permettre au gestionnaire de prendre les mesures adéquates pour contrôler les flux de trafic sur le réseau en question et en diffuser l'information auprès des usagers.

Comme énoncé ci-dessus, la diffusion d'informations prévisionnelles sur les conditions de trafic peut entraîner un changement de comportement de l'utilisateur : modification de l'horaire de départ, modification de l'itinéraire emprunté, etc. Il a été observé que l'usage d'applications mobiles de navigation comme Waze, avait eu pour effet de rediriger des flux de trafic de voies congestionnées vers des voiries secondaires non adaptées³. Il est donc important d'être conscient des potentiels effets induits sur la demande de trafic par la diffusion de ces prévisions. On parle d'élasticité de la demande. Très peu d'études ont porté sur ces effets.

1.4 Source des données

La question des données est d'une importance fondamentale en trafic notamment pour de l'estimation des états de circulation en temps réel, mais elle l'est encore davantage lorsqu'il s'agit de prévisions. Il est en effet illusoire de vouloir anticiper l'évolution d'un système, sans connaître son état actuel voire ses états passés. Bien qu'historiquement, la connaissance des flux de trafic se soit surtout développée autour des capteurs de type boucles électromagnétiques, il y a désormais une multiplication des sources de données et de la quantité de données disponibles. Nous en donnons ici une vision synthétique en distinguant :

- Les données trafic dites *fixes*, auxquelles les gestionnaires de réseaux peuvent avoir facilement accès mais avec des coûts de pose et de maintenance parfois élevés :
 - au moyen de capteurs *intrusifs*, c'est-à-dire placés directement sur la chaussée : boucles électromagnétiques, tubes pneumatiques, piézomètres, magnétomètres ;
 - Ou obtenues par des capteurs placés en bord de route : capteurs radars, capteurs lidars, capteurs vidéos dont la Lecture Automatique de Plaques d'Immatriculation (LAPI), portiques de télépéage et capteurs Bluetooth qui nous intéressent plus particulièrement dans cette étude.

3 Voir par exemple : Thai, Jérôme, Nicolas Laurent-Brouty, and Alexandre M. Bayen. "Negative externalities of GPS-enabled routing applications: A game theoretical approach." 2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC). IEEE, 2016.

- Les données *flottantes* ou *mobiles* (dénotés plus couramment par FCD pour « floating car data » ou encore FMD pour « floating mobile data » en anglais) provenant de véhicules traceurs ou d'équipements (téléphones ou autre) mobiles embarqués. Ce type de données est en pleine expansion en raison de la démocratisation de l'usage des smartphones notamment. Cependant, elles présentent l'inconvénient d'être des données propriétaires auxquelles les exploitants n'ont pas directement accès et pour lesquelles le processus d'élaboration n'est pas divulgué par les industriels.

Les capteurs rappelés ci-dessus permettent de mesurer une ou plusieurs variables caractéristiques du trafic (les boucles électromagnétiques mesurent par exemple un taux d'occupation et un débit en un seul point d'espace, les données FCD permettent de connaître des vitesses moyennes par tronçon, et les capteurs Bluetooth ne mesurent que du temps de parcours, etc.). Ils ont leur propre domaine de pertinence et leur spectre de validité.

Aucun capteur n'étant parfait, il est important de garder en tête que les mesures brutes qui en sont extraites, sont elles aussi entachées d'erreurs et d'incertitudes qu'il est nécessaire de traiter, par exemple au moyen de méthodes de filtrage. Les prévisions de trafic sont ensuite construites à partir de ces données traitées.

2 Méthodes de prévision

Cette section présente plus précisément les grandes familles méthodologiques de prévision à court terme du trafic routier. Nous distinguons trois principales familles :

- les méthodes statistiques ou *data driven* en anglais,
- les approches phénoménologiques ou *model driven* en anglais
- et les solutions hybrides couplant les deux méthodes précédentes.

Afin d'en faire un tour aussi exhaustif que possible, nous nous appuyons sur les articles suivants [Van Lint et Van Hinsbergen, 2012], [Vlahogianni et al., 2014] et [Laña et al., 2018] ainsi que sur la section 1.3 de la thèse suivante [Laharotte, 2016], sur la thèse [Haworth, 2014] et sur le livrable du projet européen SETA [SETA project, 2016].

Le problème scientifique de la prévision peut se formaliser au moyen de l'équation mathématique suivante :

$$\hat{Y}_{t+h} = f(X_t, \theta)$$

où

- \hat{Y}_{t+h} désigne la variable expliquée ou variable de sortie, c'est-à-dire la variable descriptive (flux, vitesse, temps de parcours, etc.) prévue à l'horizon de temps h ;
- X_t est l'ensemble des variables explicatives ou variables d'entrée, qui peuvent être des données historiques et/ou temps réel de l'état du système mais également des données exogènes comme la météo par exemple ;
- f est la fonction correspondant au modèle prédictif choisi ;
- et θ est l'ensemble des éventuels paramètres de la fonction qui sont à calibrer sur des données historiques. Si le modèle de prédiction n'introduit pas de paramètres à prescrire en amont mais qui sont déduits de façon automatique à partir de données test, la méthode est dite *non-paramétrique*. Dans le cas contraire, on parle d'approche *paramétrique*.

Dans ce qui suit, nous essayons de donner les principaux avantages et inconvénients pour chacune des grandes familles présentées.

2.1 Méthodes statistiques (*data driven*)

L'utilisation de méthodes statistiques pour la prévision du trafic routier à court terme est un domaine relativement ancien puisque les premiers travaux datent de la fin des années 70. Ce sujet connaît un regain d'intérêt depuis l'avènement des techniques d'intelligence artificielle et plus particulièrement, avec le foisonnement actuel d'algorithmes d'apprentissage automatique (*machine learning*). C'est un domaine en perpétuelle expansion ces dernières années et qui s'enrichit également du *big data*, c'est-à-dire de la multiplication des données disponibles.

Comme évoqué, la prévision par méthodes statistiques remonte historiquement à l'analyse de séries temporelles, à partir des travaux par Box et Jenkins. Les techniques basées sur les filtres de Kalman sont nées dans les années 70 également. Aujourd'hui, de nombreuses possibilités sont offertes pour les techniques nouvelles comme l'apprentissage profond (*deep learning*) avec les réseaux de neurones. Une tentative de classification de ces méthodes est proposée sur la figure 1.

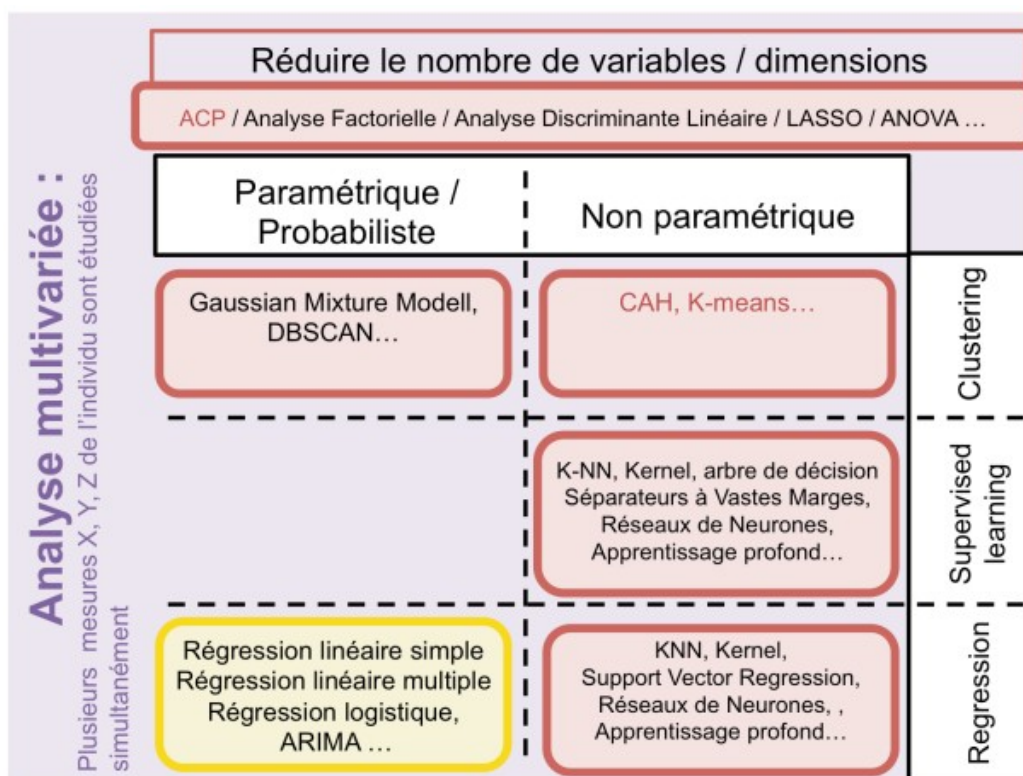


Figure 1: proposition de classification des méthodes statistiques (source : Pierre-Antoine LAHAROTTE – communication personnelle)

Méthodes de prévision par analyse de séries temporelles

On distingue tout d'abord les méthodes de prévision par analyse de séries (spatio-)temporelles. Parmi ces méthodes, nous pouvons citer :

- l'approche ARMA (*Auto-Regressive Moving-Average*) et ses variantes : ARIMA (*autoregressive integrated moving average*), STARIMA (*space-time autoregressive integrated moving average*) SARIMA (*seasonal autoregressive integrated moving average*) et ARMAX (*autoregressive-moving-average model with exogenous inputs*). Ces méthodes ont pour philosophie de considérer que toute série

temporelle se compose d'une partie auto-régressive, obtenue par la somme d'une moyenne fixe et d'une combinaison linéaire des états antérieurs avec un bruit blanc, et d'une partie représentée par une moyenne glissante. Pour un exemple d'application avec des données Bluetooth, voir [Khoei et al., 2013] ;

- la décomposition en série de Fourier, faisant l'hypothèse qu'une fonction dynamique peut toujours être approchée sous la forme d'une composition de fonctions sinusoïdales simples, variant simplement d'amplitude et de fréquence. Il existe également les méthodes de décomposition en ondelettes (*wavelet decomposition* en anglais) ;
- les méthodes qui s'appuient sur des inférences Bayésiennes, c'est-à-dire sur le calcul de la fonction de densité de probabilité du vecteur d'état :
 - le filtre de Kalman est une méthode incrémentale où la prédiction de l'état futur est basée sur l'état au pas de temps précédent et sur des mesures disponibles sur l'état actuel. Ce filtre ainsi que ses variantes (filtre non-linéaire, filtre étendu, filtre ensembliste) ont été très utilisés pour la prévision du trafic à court-terme : nous donnons dans la Section 3, les exemples du projet « Grenoble Traffic Lab » d'Inria Grenoble [Canudas De Wit et al., 2015], ainsi que du projet « Mobile Millenium Stockholm » porté notamment par UC Berkeley, voir également [Barceló et al., 2010] pour un exemple d'application de filtres de Kalman à partir de données Bluetooth.
 - les filtres particuliers qui, à la différence du filtre de Kalman, ne considèrent pas que la fonction de densité est une Gaussienne, mais un ensemble aléatoire de « particules ».
 - les méthodes de chaînes de Markov – Monte Carlo (MCMC) pour les cas de données multi-dimensionnelles difficiles à appréhender par les filtres particuliers.

Méthodes de prévision par apprentissage automatique

Les méthodes statistiques d'apprentissage automatique composent le second volet de cette classification. Ces méthodes appartiennent au champ de l'intelligence artificielle, qui est une branche de l'approche statistique visant à donner aux ordinateurs la capacité d'« apprendre » par eux-mêmes à partir de données. En reprenant l'expression de l'équation générique $\hat{Y}_{t+h} = f(X_t, \theta)$ introduite précédemment, les méthodes d'apprentissage automatique procèdent comme suit :

1. un critère de performance est défini : il s'écrit selon une fonction de coût basée sur l'écart entre la variable prévue \hat{Y} et la variable réellement observée Y ;
2. les paramètres (ou hyperparamètres) de la fonction f sont déterminés à partir d'un jeu de données (X, Y) dites d'entraînement ou d'apprentissage ; l'apprentissage s'opère en cherchant à minimiser le critère de performance pour chacun des éléments du jeu de données d'apprentissage ;
3. une fois que les paramètres sont « appris », la fonction de prédiction ou prédicteur f est appliquée à de nouvelles données X pour produire de nouvelles prévisions \hat{Y} . C'est ici que l'on teste la capacité de généralisation de la fonction.

Au sein de ces techniques, nous distinguons :

- Les algorithmes d'apprentissage supervisé ou d'analyse discriminante pour lesquels les données sont étiquetées, c'est-à-dire que les classes sont connues pour chaque élément des exemples d'apprentissage. Il s'agit de pouvoir attribuer une classe ou une valeur à un nouvel individu. Parmi ces méthodes, nous retrouvons :

- les méthodes de classification pour les données discrètes et/ou qualitatives :
 - la méthode des K plus proches voisins (*K-nearest neighbours* ou KNN en anglais) qui cherche dans les K voisins de la base de données historique une observation la plus proche de l'état actuel pour en déduire l'état futur par moyenne directe ou pondérée des états consécutifs historiques. La notion de proximité s'estime à partir d'une distance donnée comme la distance Euclidienne usuelle.
 - les méthodes à noyau, généralisant la méthode KNN, qui considèrent l'ensemble des individus de l'historique pondérés par une zone d'influence. La classe d'un nouvel individu dépend alors de la distance et de la position sur la zone d'influence relative à chacun des membres de l'historique.
 - classification par vecteurs de support (*Support Vector Classification* ou SVC en anglais),
 - les réseaux de neurones artificiels qui couvrent différentes architectures ou paradigmes mais qui gardent tous une même structure basique, à savoir un ensemble de couches d'éléments de traitement, appelés les « neurones ». Il y a une couche d'entrée, une couche de sortie et une ou plusieurs couches cachées. Les neurones se composent chacun d'une fonction de transfert interne et sont reliés les uns aux autres par des poids. Plus il y a de couches et de neurones, plus cela demande une grande quantité de données pour bien calibrer les poids reliant les neurones. Lorsque le nombre de neurones par couche et le nombre de couches cachées sont importants, on tend vers les réseaux de neurones profonds ou *deep learning* en anglais. Bien que ces méthodes se soient révélées efficaces dans de nombreux cas d'application, la communauté scientifique n'arrive pas encore à comprendre toutes les raisons de ce succès et ces méthodes restent souvent utilisées comme des boîtes noires.
 - les arbres de décision ainsi que leur généralisation aléatoire (*random forests* en anglais), dont l'efficacité a été prouvée pour des horizons supérieurs à une heure par rapport à des méthodes de régression linéaire mais qui peinent sur des horizons plus courts ;
 - la classification naïve bayésienne pour laquelle un individu est affecté à une classe selon un ensemble de caractéristiques qui sont statistiquement indépendantes. Cette méthode estime les paramètres (à savoir les probabilités des classes et les lois de probabilités associées aux différentes caractéristiques) par maximum de vraisemblance ;
- les méthodes de régression pour les données continues et/ou quantitatives :
 - la régression linéaire qui a l'intérêt d'être simple à être mise en œuvre et qui produit de bons résultats avec notamment la méthode de [Rice, Van Zwet, 2004] qui introduit des coefficients variant en fonction du temps,
 - d'autres formes de régression qui varient selon la forme de la fonction de perte comme la régression logistique,
 - l'algorithme LASSO (pour *Least Absolute Shrinkage and Selection Operator* en anglais) qui est une méthode de régression linéaire au moindre carré avec terme de régularisation en norme L1⁴, qui favorise les solutions avec un nombre restreint de caractéristiques,
 - la régression par vecteurs de support (*Support Vector Regression* ou SVR) est l'application des machines à vecteurs de support (*Support Vector Machine* ou SVM) à l'analyse de séries temporelles. Différentes variantes existent selon le choix de la fonction noyau : linéaire, non-linéaire,

4 La norme L1 considère simplement la somme des écarts en valeur absolue entre les valeurs modélisées et celles observées.

- polynomiale, Gaussienne (modèle RBF pour *Radial Basis Function*), etc.
 - les réseaux de neurones et les arbres de décision peuvent également être utilisés pour réaliser de la régression.
- Les algorithmes d'apprentissage non-supervisé pour lesquels les données ne sont pas étiquetées, c'est-à-dire que les classes et/ou le nombre de classes ne sont pas connus. Il s'agit de regrouper des individus en classes de caractéristiques communes ou d'identifier une structure au sein des données. Ces méthodes ne servent pas directement pour la prévision du trafic, mais permettent généralement de faire un travail de préparation des données. Cela couvre :
 - les algorithmes de regroupement (ou *clustering*) nécessitant la définition d'une distance et couvrant différentes méthodes comme :
 - la méthode des K-moyennes (*K-means* en anglais) et ses variantes : K-médoïdes, K-médians ;
 - l'allocation latente de Dirichlet (ou *latent Dirichlet allocation* (LDA) en anglais) modèle de catégorisation textuelle pour découvrir la structure latente d'un document à partir des mots qu'il contient ; cette méthode a été appliquée à d'autres domaines que la fouille de données textuelles avec notamment l'apprentissage de matrices origine-destination (OD) par [Laharotte, 2016].
 - les méthodes de regroupement hiérarchique comme la classification ascendante hiérarchique (CAH) par mesure de dissimilarité entre classes et qui se représente sous forme de dendrogramme, c'est-à-dire un diagramme sous forme d'« arbre » illustrant le regroupement des individus ;
 - les méthodes de réduction de dimension qui permettent de sélectionner ou réduire le nombre de variables d'entrée. La plus connue de ces méthodes est l'analyse en composantes principales (PCA en anglais) qui consiste en une transformation des coordonnées permettant de projeter les variables d'entrée sur de nouveaux axes représentant les variations maximales. Cette méthode a l'inconvénient d'être très sensible aux données extrêmes, qui peuvent être erronées.
- Les algorithmes d'apprentissage semi-supervisé qui utilisent un ensemble de données étiquetées et non-étiquetées, lorsque la taille des jeux de données à étiqueter est trop grande pour être réalisée de manière exhaustive par un opérateur humain. Évoquons aussi la méthode de co-apprentissage. Ces méthodes peuvent être utilisées par exemple pour la détection d'incidents.
- Les algorithmes d'apprentissage par renforcement qui sont des méthodes déductives à l'opposé des précédentes qui sont inductives. Ils proposent un apprentissage par processus incrémental avec une notion de récompense, positive ou négative, selon le résultat appris précédemment. La machine peut automatiquement déterminer le comportement à avoir dans un certain contexte pour maximiser ses performances, comme le degré de précision dans notre cas. L'algorithme de Q-learning ou encore celui de Temporal Difference (TD) learning sont des exemples d'algorithmes d'apprentissage par renforcement. Il existe des cas d'applications pour le contrôle de feux de trafic, avec une prévision de l'état futur de trafic. Pour illustration, [Li et al., 2016] propose un algorithme de renforcement pour déduire le plan de feux optimal, en considérant le retard et la longueur de la file d'attente comme des pénalités.

Il est intéressant de noter que ces différentes méthodes peuvent être combinées entre

elles. A titre d'exemple, le modèle ATHENA de [Danech-Pajouh et Aron, 1991] utilise des algorithmes de classification puis de la régression linéaire sur les classes ainsi trouvées, pour réaliser des prévisions. Il existe également les méthodes dites ensemblistes (*bootstrapping*) qui permettent de combiner différents réseaux de neurones.

Avantages et inconvénients des méthodes statistiques

Comme nous venons de le voir, il y a un grand foisonnement de méthodes statistiques. Parmi ces méthodes, les algorithmes d'apprentissage automatique représentent l'axe de recherche le plus actif.

Différentes approches statistiques ont été testées avec succès pour la prévision du trafic routier à court terme sur des cas particuliers, avec des méthodes distinctes selon le type de données disponibles (voir Section 1.4), le type de réseau considéré, la variable prédite et l'horizon temporel souhaité pour la prévision. Peu de ces travaux portent sur la prévision à court terme à partir de données de temps de parcours.

Nous reproduisons ci-après (voir figure 2) une aide au choix d'une méthode d'apprentissage statistique, en fonction de la quantité et du type de données à disposition (données qualitatives ou quantitatives ; données classées ou non) ainsi qu'en fonction de l'objectif recherché (prédire une catégorie ou une quantité). Dans le cas de données de temps de parcours obtenues au moyen de capteurs Bluetooth, comme les entrants sont des données numériques, il nous semble que les méthodes les plus pertinentes pour de la prévision à court terme sont des méthodes de régression (apprentissage supervisé). L'algorithme de prévision pourrait être affiné en définissant en amont un ensemble de journées-types, grâce à des méthodes de regroupement (apprentissage non-supervisé).

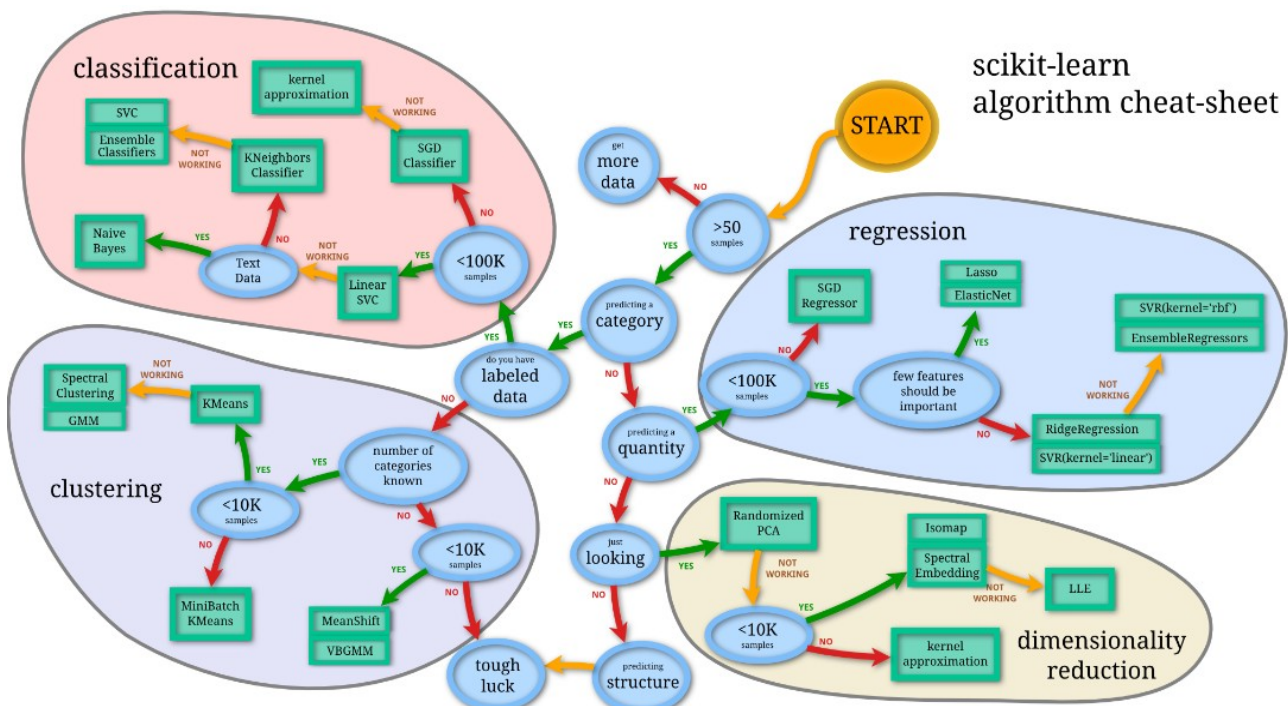


Figure 2: arbre de choix des méthodes de prédiction. Source : https://scikit-learn.org/dev/tutorial/machine_learning_map/index.html.

L'efficacité de ces méthodes axées sur l'analyse des données repose essentiellement sur la reproduction dans le temps de phénomènes comme les mouvements pendulaires sur

les axes péri-urbains. Les méthodes statistiques se montrent particulièrement performantes pour la prédiction d'évènements récurrents. Elles pèchent davantage pour les évènements non-récurrents pour lesquels il y a peu d'exemples dans l'historique de données.

Il faut également moduler certaines attentes sur les résultats potentiels de ces méthodes en matière de généralisation. Nous évoquons ici le théorème du « no free lunch » (NFL) énoncé par D. Wolpert⁵ et qui indique que deux algorithmes distincts d'optimisation (qui sont généralement à la base des méthodes d'apprentissage automatique) sont globalement équivalents. En d'autres termes, aucun algorithme d'apprentissage automatique n'est universellement meilleur que les autres.

D'autre part, les méthodes statistiques nécessitent une base de données historiques de bonne qualité et suffisamment représentative de tous les états de trafic et de la typologie des jours (saisonnalité, météorologie, variations hebdomadaires, calendrier scolaire, évènements sportifs et sociaux exceptionnels programmés) pour être capable de bien prédire les états de trafic futurs. Cela est d'autant plus vrai pour les algorithmes d'apprentissage automatique. Si la base de données n'est pas de bonne qualité, l'algorithme d'apprentissage ne permettra pas de corriger ce biais-là et les prévisions seront de mauvaise qualité (principe du « *garbage in, garbage out* » en anglais).

2.2 Approches phénoménologiques (*model driven*)

Cette seconde famille méthodologique de prévision s'appuie sur des simulations réalisées à partir de modèles physiques d'écoulement dynamique du trafic. L'idée de la prévision est de simuler l'évolution du trafic sur un horizon de temps donné, grâce à un modèle choisi et calé préalablement et à partir d'un ensemble d'informations sur :

- L'état « initial » du trafic au début de la simulation, en termes par exemple de densités, de vitesses ou encore de longueur de congestion. On parle aussi de *conditions initiales* ;
- Les demandes aux entrées de réseau qui se définissent :
 - soit par le débit de véhicules qui souhaitent entrer dans le réseau considéré et les coefficients de mouvements tournants à chaque intersection du réseau ;
 - soit par des matrices d'origine-destination (OD) auxquelles on ajoute un modèle de choix d'itinéraire pour déterminer l'affectation dynamique du trafic ;
- Les offres aux sorties du réseau, c'est-à-dire le débit de véhicules qui peuvent réellement sortir du réseau. Cela peut notamment traduire des réductions de capacité ou des remontées de congestion en aval de la sortie. Les demandes aux entrées et les offres aux sorties définissent les *conditions au bord*.

Les modèles de trafic qui nous intéressent ici sont les modèles dynamiques. Ces modèles sont dits *paramétriques* et peuvent être classifiés selon leur échelle de représentation et de détail (voir figure 3, page 18). Nous distinguons ainsi les modèles microscopiques, mésoscopiques et macroscopiques.

Modèles microscopiques du trafic

Les modèles microscopiques modélisent la trajectoire individuelle de chaque véhicule en tenant compte de trois facteurs :

5 Wolpert, David (1996), "The Lack of A *Priori* Distinctions between Learning Algorithms", *Neural Computation*, pp. 1341-1390. (voir en particulier la section 4). La phrase « No Free Lunch » est attribuée à D. Haussler.

1. des comportements (longitudinaux) de poursuite, c'est-à-dire la façon dont les véhicules adaptent leurs vitesses et distances par rapport aux véhicules les précédant ;
2. des comportements (latéraux) de changement de voie ;
3. et d'acceptation de créneaux pour l'insertion aux carrefours mais aussi pour l'exécution des manœuvres de changement de voie.

Les variables utilisées sont donc individuelles comme la position, la vitesse ou l'accélération de chaque véhicule. D'un point de vue mathématique, les modèles microscopiques de poursuite s'écrivent sous forme de systèmes d'équations différentielles ordinaires couplées. Des solutions exactes peuvent être trouvées pour des cas spécifiques.

Du fait de leur haut niveau de détail, les modèles microscopiques font intervenir différents paramètres comme la vitesse maximale désirée, l'inter-distance minimale ou le temps de réaction, qui doivent être calibrés avant les simulations. Ces modèles sont adaptés pour la simulation du trafic routier sur des aménagements locaux, comme des carrefours urbains gérés par des feux de circulation.

Le suivi individuel des véhicules entraîne un temps de calcul informatique proportionnel à leur nombre. D'autre part, les modèles microscopiques étant par nature stochastiques, il est généralement d'usage de réaliser plusieurs répliques pour avoir une bonne représentativité des comportements. Cela limite donc la prévision à de très courts horizons temporels, sauf à disposer d'une très grande puissance de calcul.

Modèles macroscopiques du trafic

Les modèles macroscopiques utilisent des quantités agrégées comme la densité, la vitesse moyenne du flux et le débit de véhicules, considérées continues malgré le fort aspect particulaire du trafic routier, en faisant l'analogie entre l'écoulement du trafic et l'écoulement d'un fluide continu. Les véhicules ne sont donc pas représentés individuellement.

Le modèle macroscopique le plus caractéristique est le modèle LWR proposé par Lighthill, Whitham et Richards séparément, au milieu des années 1950. Ce modèle s'intéresse principalement à la propagation des ondes cinématiques en trafic comme les ondes de congestion. D'autres modèles ont été proposés ensuite pour raffiner les propriétés du modèle LWR : citons par exemple les modèles multi-classes ou encore les modèles d'ordre supérieur.

Les modèles macroscopiques du trafic s'écrivent généralement sous la forme d'équations ou de systèmes d'équations aux dérivées partielles pour lesquels il n'existe pas de solutions exactes dans le cas général. Dans la majorité des cas, les simulations sont menées à partir de schémas numériques qui donnent une approximation de la solution en fonction d'une discrétisation de l'espace des coordonnées.

L'élément clé pour ce type de modèles est la définition d'une fonction reliant la densité au débit : on parle de *diagramme fondamental*. En dynamique des fluides, il est commun de considérer que le débit s'obtient comme le produit entre la densité et la vitesse moyenne du flux. Cette fonction débit-densité fait intervenir différents paramètres comme la vitesse de circulation en régime fluide, la densité maximale théorique de véhicules ou encore la densité critique à partir de laquelle le trafic passe d'un régime fluide à un régime congestionné. Ces paramètres doivent être calibrés à partir de données réelles historiques.

Les modèles macroscopiques sont davantage utilisés pour les réseaux interurbains et périurbains. Il est alors nécessaire de définir proprement des modèles simples pour les intersections du type convergent (bretelle d'entrée ou convergent autoroutier par exemple)

ou divergent (bretelle de sortie ou bifurcation par exemple).

Modèles mésoscopiques du trafic

Les modèles mésoscopiques utilisent une représentation intermédiaire du trafic : les véhicules sont toujours suivis individuellement mais le trafic est vu comme un continuum de particules. Deux approches existent avec :

- d'une part, les modèles cinétiques qui considèrent une distribution probabiliste des véhicules circulant à une certaine vitesse, en chaque point du domaine spatio-temporel considéré. Ils intègrent par construction une part de stochasticité et sont issus d'une analogie avec la dynamique de gaz de Boltzmann. En pratique, ce type de modèle est complexe à utiliser pour la simulation (et la prévision par conséquent) du trafic.
- d'autre part, les modèles venant d'une réécriture de modèles macroscopiques classiques, comme le modèle LWR, par un changement de coordonnées. Pour cette dernière catégorie de modèles, l'accent est mis sur une description événementielle du trafic en s'intéressant uniquement au temps de passage des véhicules à certains points du réseau, comme les intersections. Cela permet au modèle de s'affranchir de la taille du réseau en comparaison aux modèles microscopiques, tout en conservant une description individuelle des véhicules. Comme les modèles macroscopiques, la dynamique des véhicules reste simplifiée.

Pour l'une ou l'autre de ces deux approches, il n'existe pas non plus de solution exacte dans le cas général. La solution est donc approximée au moyen de schémas numériques.

Hybridation de modèles d'écoulement

Certains modèles hybrides permettent de simuler le trafic à différentes échelles sur différents segments, en combinant par exemple du macroscopique sur des grands axes dépourvus de bretelles d'accès ou de sortie et du microscopique au niveau de carrefours. Une attention particulière est mise sur les conditions de raccordement entre les différentes échelles de représentation.

La figure 3 suivante présente une classification des principaux outils de simulation dynamique présents sur le commerce, en fonction de leurs échelles d'agrégation (d'individuelle à agrégée) et de représentation (de particulière à continue).

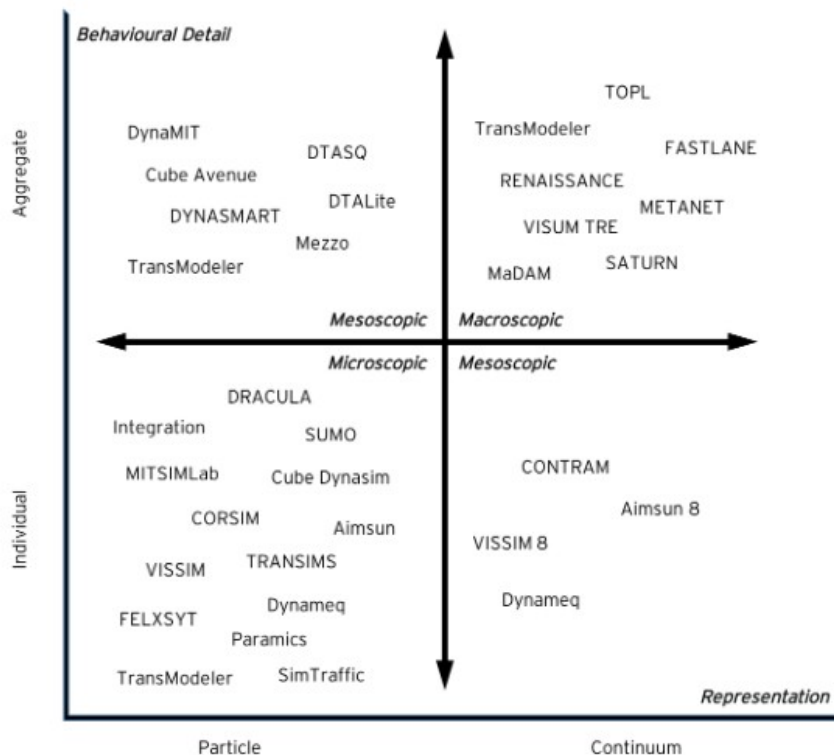


Figure 3: taxonomie des modèles de trafic avec quelques exemples de simulateurs du marché. Source : [SETA project, 2016]

Avantages et inconvénients des méthodes phénoménologiques

Bien qu'il soit impossible de prévoir l'occurrence d'un évènement aléatoire perturbateur (accident, ralentissement brutal, panne...), les modèles de trafic sont capables de reproduire les effets produits par cet évènement sur l'écoulement du trafic. Ces modèles bénéficient de développements théoriques depuis plus de 50 ans qui permettent d'améliorer leur capacité de reproduire les phénomènes les plus complexes avec fidélité. En cela, l'approche phénoménologique permet de meilleures prévisions dans le cas d'évènements non-récurrents que les méthodes statistiques. La principale incertitude réside sur la durée de l'évènement et à la capacité du modèle de reproduire le niveau d'offre dégradé associé.

Les principaux inconvénients des modèles d'écoulement du trafic sont :

- la nécessité de calibrer correctement les paramètres du modèle, ce qui peut s'avérer fastidieux pour un modèle microscopique ;
- la nécessité d'avoir une connaissance fine :
 - des conditions initiales,
 - des conditions au bord, c'est-à-dire les demandes en entrée et les offres en sortie de réseau considéré,
 - des matrices dynamiques origine-destination (OD) ou à défaut, les mouvements tournants à chaque intersection du réseau – qui seraient à adapter dynamiquement en cas de reroutage par exemple.
- la nécessité de coder correctement le réseau étant donné que la connectivité du réseau a un impact sur l'écoulement du trafic et la propagation de la congestion. D'un point de vue informatique, la difficulté est proportionnelle à la taille du réseau

et du nombre de liens.

2.3 Hybridation

L'hybridation consiste à coupler une méthode de chaque approche méthodologique (une méthode statistique et une méthode phénoménologique basée sur un modèle physique) ensemble et de les utiliser chacune spécifiquement dans son domaine de pertinence. Ainsi, les méthodes statistiques se révèlent être performantes pour les prévisions d'évènements récurrents tandis que les méthodes phénoménologiques le sont davantage en présence d'évènements non récurrents.

Bien que cette piste d'hybridation est régulièrement mentionnée dans la littérature comme étant la plus prometteuse pour améliorer les prévisions de trafic à court terme en toute circonstance, il existe peu d'exemples de travaux dans cette direction. La tendance principale consiste à utiliser les méthodes statistiques en amont pour le calibrage des paramètres des modèles physiques d'écoulement de trafic ou pour le calage des matrices OD dynamiques. Dans ces cas-là, la prévision reste toujours réalisée par une approche purement phénoménologique, c'est-à-dire au moyen d'un modèle de physique du trafic. Citons toutefois [Hofleitner et al., 2012] qui propose un algorithme s'appuyant sur un modèle physique de trafic et une méthode statistique pour prévoir les temps de parcours sur un axe urbain régulé par des feux. Nous détaillerons également dans la section suivante, le cas particulier de l'outil commercial « Aimsun Live » qui s'appuie sur l'hybridation de méthodes d'apprentissage automatique et de simulation du trafic par modèle pour de la prévision.

2.4 Vue synthétique des méthodes de prévision à court terme

En conclusion à cette section sur les méthodes de prévision du trafic à court terme, il nous semble important d'insister sur les points suivants :

- les méthodes statistiques tout comme celles basées sur des modèles physiques du trafic requièrent un historique conséquent de données (une année complète de données semble être un minimum pour couvrir la plus grande variabilité de cas possibles) ;
- toutes ces méthodes doivent être alimentées par des données temps réel, avec une fréquence inférieure ou égale au pas prévu pour la prévision ;
- les données doivent être de bonne qualité (sans biais) et doivent permettre de caractériser clairement l'état du trafic ;
- les méthodes paramétriques dont notamment les modèles physiques d'écoulement du trafic nécessitent d'avoir été calibrées et validées au préalable.

3 Outils et expérimentations

Cette partie se propose de lister un ensemble d'outils et de projets récents ou en cours, pour lesquels une méthode de prévision court-terme du trafic a été utilisée. Nous distinguons les outils selon leurs utilisateurs, à savoir gestionnaires routiers et usagers grand public.

Nous faisons un focus particulier sur deux outils commerciaux qui ont été spécifiquement développés à destination des gestionnaires routiers.

3.1 Outils pour les gestionnaires de voiries

Nous faisons volontairement une distinction ici entre les outils qui ont été développés par des industriels, avec une visée commerciale, et les outils issus du monde de la recherche pour des objectifs essentiellement académiques.

Outils développés par des industriels

En France, le projet phare ayant permis de tester la prévision du trafic à court terme est le projet « OPTIMOD Lyon ». Ce projet s'est déroulé sur 3 ans à partir de 2012, sous le pilotage de la métropole du Grand Lyon et il a été financé en partie par l'Ademe. Dans le cadre de ce projet, deux sociétés, **IBM** et **Phoenix ISI**, ont pu tester leurs technologies de prévision afin d'anticiper les actions de régulation au niveau des carrefours à feux de la métropole. La prévision avait un horizon temporel d'une heure. La prévision s'appuyait sur des données de débit et taux d'occupation provenant de capteurs magnétiques ainsi que des données FCD. Cependant, ces données FCD n'étaient à l'époque pas de qualité suffisante pour permettre de bonnes prévisions. Peu d'informations sont disponibles sur le taux de fiabilité des prévisions à l'issue de cette phase de test.

IBM s'est appuyé notamment sur les travaux de [Min & Wynter, 2011] utilisant une approche statistique et a pu commercialiser une solution de prévision qui est désormais intégrée dans leur boîte à outils « Intelligent Operations for Transportation » à destination des gestionnaires et des collectivités.

Phoenix ISI a poursuivi le déploiement d'un outil d'aide à la décision incorporant de la prévision à 1h pour le compte du Grand Lyon, à l'issue du projet OPTIMOD Lyon. Désormais, Phoenix ISI s'intéresse à une application relativement similaire à l'échelle de l'Île-de-France, dans le cadre du projet « Mob2i ». Leur méthode de prévision s'appuie exclusivement sur une approche statistique.

Outre le projet OPTIMOD Lyon évoqué ci-dessus, nous nous intéressons tout particulièrement à deux solutions logicielles qui représentent aujourd'hui les principaux outils commercialisés internationalement à destination des exploitants routiers : il s'agit de **PTV Optima** et **Aimsun Live**.

3.1.1 PTV Optima

Le logiciel PTV Optima est proposé par la société allemande PTV, groupe spécialisé dans la commercialisation de logiciels de simulation routière. Le groupe PTV fête ses 40 ans en 2019, et affiche disposer de plus de 40 000 licences actives, tous logiciels confondus, autour du monde. Le groupe PTV commercialise divers logiciels d'études hors-ligne dont PTV VISUM qui propose un modèle macroscopique statique et PTV VISSIM et VISWALK, qui sont des simulateurs microscopiques et mésoscopiques du trafic routier et piéton.

Le logiciel PTV Optima est une plateforme logicielle qui permet le traitement temps réel d'informations trafic pour réaliser de l'estimation (incluant le filtrage et la fusion des données, leur complétion et de la détection automatique d'incidents), de la prédiction jusqu'à 1 heure, de l'aide à la décision et qui offre aussi la possibilité de « rejeu » des données historiques par gestion de la base des données passées.

Il se compose également de deux sous-outils que sont PTV BALANCE pour de la simulation à l'échelle d'un quartier ou d'un axe et PTV EPICS qui est spécialement dédié au contrôle de feux à l'échelle d'un carrefour.

PTV Optima peut prendre, en entrants, différentes sources de données comme les données boucles (débit, taux d'occupation et éventuellement vitesses) ou les données flottantes FCD.

L'outil PTV Optima a été déployé dans différents pays et dans différentes villes du monde : parmi les projets récents, nous pouvons citer Turin dans le Piémont italien (2011-2013), Vienne en Autriche (2013-2016), Strasbourg où un démonstrateur a été testé (2016-2019) avec l'Eurométropole pour optimiser le système de feux et améliorer la qualité de l'air ou encore le projet « Talking Traffic » aux Pays-Bas. Cette liste de déploiements n'est pas exhaustive.

Nous détaillons le cas du **projet « Talking Traffic »** qui concerne l'ensemble du réseau autoroutier néerlandais et qui a été initié en 2017 et est toujours fonctionnel en 2019. L'outil PTV Optima est utilisé pour réaliser de l'estimation de l'état de trafic en temps réel, sur l'ensemble du réseau, y compris en dehors des sections équipées de capteurs, ainsi que de la prévision de trafic à court terme à 3, 6 et 9 minutes. La prévision s'appuie exclusivement sur l'outil logiciel PTV VISUM qui est historiquement un outil macroscopique d'affectation statique qui permet de déterminer les matrices OD initiales sur la base d'un modèle à 4 étapes : génération, distribution, choix modal et affectation à l'équilibre. Le modèle VISUM doit être préalablement calé hors ligne. Il est complété par un algorithme d'affectation dynamique en temps réel permettant d'estimer les demandes en temps réel. L'affectation est réalisée sur un horizon de 24 heures par tranches de 30 minutes. À partir des matrices OD et des demandes estimées, l'outil simule l'écoulement du trafic dans une approche phénoménologique avec la possibilité de simuler à l'échelle mésoscopique ou macroscopique. Il n'y a pas de méthode statistique implémentée pour apprendre automatiquement à partir des données. À noter que le réseau est discrétisé en cellules de longueur maximale de 500 mètres. La fiabilité de la prévision à 6 minutes a été estimée à 85 % sur un échantillon de 4 heures.

3.1.2 Aimsun Live

Le logiciel Aimsun Live (anciennement Aimsun Online) est quant à lui proposé par la société espagnole Aimsun et faisant désormais partie du groupe Siemens. Cette société édite principalement deux types de logiciels : Aimsun Next pour les études hors ligne et Aimsun Live pour le temps réel. Aimsun Next englobe des algorithmes d'affectation (statique et dynamique) et de la simulation microscopique et mésoscopique.

Dans le même esprit que PTV Optima, Aimsun Live propose ainsi de l'estimation d'état temps réel, de la prévision à horizon d'1 heure maximum et de l'aide à la décision pour les gestionnaires. Le flux de données est illustré sur la figure 4 ci-après.

Il est notable qu'Aimsun Live à la différence de PTV Optima utilise une approche hybride pour la prévision avec de l'analyse de séries temporelles et de la simulation. En effet, l'analyse statistique est utilisée pour définir des profils-types de situations de trafic, détecter les situations non-récurrentes ainsi que pour l'ajustement dynamique des matrices OD. La simulation tourne en continu mais n'est considérée que lorsque des événements non récurrents sont détectés. Un apprentissage continu est réalisé 1 heure après la première prévision pour améliorer la qualité de la prévision, par le biais d'un module de gestion de la qualité.

Bien que cela soit variable selon les projets, les matrices OD sont généralement disponibles par tranches de 15 minutes et la prévision est réalisée toutes les 5 à 15 minutes avec un horizon d'une heure.

L'outil Aimsun Live a été déployé et testé dans divers contextes : pour de la gestion sur un grand axe autoroutier avec l'Interstate I-15 à San Diego, Californie, depuis 2012 ou avec la M4 à Sydney, en Australie depuis 2017 ; pour de la gestion de plans de feux à Lyon

dans le cadre du projet OPTICITIES (faisant suite au projet OPTIMOD évoqué précédemment) avec un démonstrateur testé entre 2013 et 2016 ; pour de la prévision à l'échelle d'une zone métropolitaine comme à Gold Coast, Australie en lien avec le département des transports du Queensland. D'autres projets sont actuellement en cours de déploiement, par exemple à Wiesbaden en Allemagne et à Orlando, Floride, aux Etats-Unis.

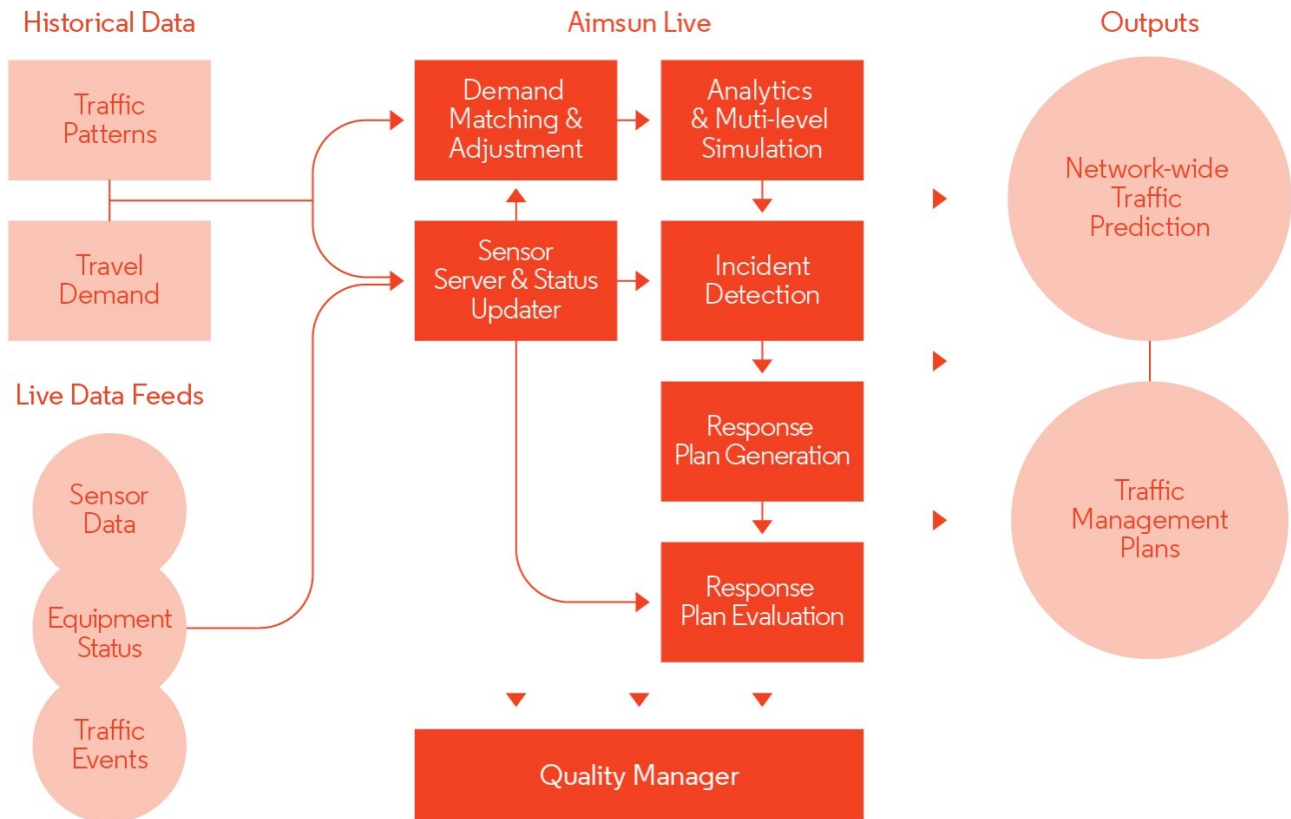


Figure 4: schéma de fonctionnement de l'outil Aimsun Live (source : <https://www.aimsun.com/aimsun-live/>)

Outils développés par des laboratoires de recherche

Le milieu académique a également développé et testé différentes solutions de prévision en partenariat avec des opérateurs routiers.

En voici quelques exemples en France :

- le laboratoire du LICIT commun à l'IFSTTAR et à l'ENTPE a notamment abrité :
 - le travail de thèse de Romain BILLOT (voir [Billot, 2017]) avec de la prévision météo-sensible, basée sur une approche statistique, sur les données de péage à Chambéry ;
 - le travail de thèse de Pierre-Antoine LAHAROTTE [Laharotte, 2016] qui a utilisé notamment les données Bluetooth à Brisbane en Australie et des données FCD sur le périphérique de Nantes pour réaliser des prévisions essentiellement à partir de méthodes statistiques ;
 - un projet de prévision sur le périphérique parisien en collaboration avec la DiRIF (voir [Duret et al., 2016]).
- le laboratoire du GRETTIA de l'IFSTTAR a accueilli le travail de thèse de Rémi SAINT (voir en particulier le chapitre 6 de [Saint, 2016]) qui a en partie porté sur de la prévision court terme pour l'ensemble du réseau périphérique de Toulouse.

Ce travail s'appuyait sur une approche phénoménologique et profitait de la plateforme CLAIRE-SITI qui est un hyperviseur développé par l'IFSTTAR en partenariat avec Thalès ;

- du côté Inria, nous pouvons souligner :
 - les projets ANR TRAVESTI (TRAffic Volume Estimation by Spatio-Temporal Inference) et FUI PUMAS (Plateforme Urbaine de Mobilité Avancée et Soutenable – 2009-2012) avec une expérimentation sur l'agglomération de Rouen avec des prévisions de trafic probabilistes à partir de données FCD ;
 - le démonstrateur « Grenoble Traffic Lab » [Canudas De Wit et al., 2015] sur la rocade Sud de la métropole grenobloise où une approche statistique est proposée pour réaliser des prévisions toutes les 3 minutes avec un horizon de 10 minutes.

À l'étranger, mentionnons, sans exhaustivité, les travaux menés par TU Delft et sa spin-off fileradar.nl qui propose la plateforme Future:traffic pour des prévisions issues d'une approche statistique. Également, citons les projets « Mobile Millennium » menés à San Francisco, Californie (2018-2010) et à Stockholm, en Suède (depuis 2010) par l'Université de Californie à Berkeley et ses partenaires.

Globalement, il n'y a pas ou peu d'éléments d'évaluation objective de tous ces projets académiques. Chacun se targue de résultats jugés satisfaisants sur leurs cas d'application. Il est donc difficile d'avoir un avis comparatif sur ces outils. Par ailleurs, s'agissant principalement de démonstrateurs avec des visées de recherche, ce ne sont pas, a priori, des outils destinés à être dupliqués sur d'autres sites.


3.2 Outils pour les usagers grand public

Nous avons souhaité ajouter cette section afin d'alerter le lecteur sur la multiplication d'outils à destination du grand public depuis l'essor des smartphones. Ces outils interrogent le rôle des gestionnaires routiers en termes de diffusion d'informations routières. Ainsi, de nombreuses applications mobiles de navigation routière proposent désormais à la fois un système de guidage mais également un modèle de prévision des temps de parcours. Parmi ces applications, nous pouvons citer : Google Maps, Waze, Apple Plans, TomTom, HERE (anciennement Navteq et Nokia), Inrix (spin-off de Microsoft), V-Trafic (Mediamobile).

De grands groupes du numérique s'y intéressent également comme IBM et Microsoft.

Malheureusement, peu de données sont librement accessibles concernant ces outils et les méthodes utilisées, pour cause de secret industriel. A titre d'information, la Figure 5 ci-après illustre la répartition statistique des brevets déposés ces dernières années sur le thème de la prévision à court terme des temps de parcours. La prédominance notable de grands groupes comme Inrix, IBM ou encore Microsoft, mais aussi des constructeurs automobiles comme GM ou BMW.

Il semble toutefois que l'essentiel des méthodes repose sur des approches statistiques. Ce manque d'informations rend impossible un avis critique sur ces outils. Il est simplement commun de constater l'usage très populaire des applications de navigation routière pour lesquelles les estimations de temps d'arrivée (et donc de temps de parcours) sont pertinentes dans une majorité des cas.



Assignees	Inventors	CPCs
Intelligent Technologies International, Inc. G08G1/161 G08G1/16 G01S7/497 G01S2007/4975		4%
Inrix, Inc. G08G1/0104 G08G1/01 G08G1/0133 G08G1/0125		3.7%
通用汽车环球科技运作公司 G01S2013/9325 G01S13/931 G01S13/723 G01S13/66		2%
GM Global Technology Operations LLC G01S13/723 G01S13/66 G01S13/87 G02B27/0101		1.7%
Makor Issues And Rights Ltd. G08G1/096811 G08G1/096816 G08G1/096872 G08G1/096805		1.7%
International Business Machines Corporation G08G1/0104 G08G1/01 G08G1 G08G1/00		1.7%
Microsoft Corporation G01C21/26 G01C21/00 G01C G08G1/01		1.7%
Automotive Technologies International, Inc. B60R2021/0002 B60R21 B60R21/00 G01S17/936		1.3%
Global Alert Network, Inc. H04W4/02 H04W4/00 H04W4 H04L67/18		1%
株式会社日立製作所 G08G1 G08G1/00 G08G H04H20/53		1%
Bayerische Motoren Werke Aktiengesellschaft B60R2300/50 B60R1 B60R1/12 B60R2300/106		1%
Ол2, Инк. A63F13/358 A63F13/335 A63F2300/50 H04N7/106		1%
Nokia Corporation G01C21 G01C21/00 G01C G01C21/20		1%

Figure 5: répartition des cessionnaires de brevets contenant les mots clés « prévision des temps de parcours à court terme ». Le pourcentage donne le nombre de brevets détenus par chaque entité sur le nombre total de brevets dans cette catégorie. Source : Google Patents (<https://tinyurl.com/y6mzggrx>).

4 Conclusion

La prévision du trafic n'est pas un sujet nouveau : les premiers essais en conditions réelles remontent à plus de 20 ans. Cependant, les méthodes ont évolué, de nouvelles sources de données sont apparues et le développement récent des techniques d'intelligence artificielle favorisent de nouvelles attentes, notamment pour les gestionnaires de réseaux routiers.

La plupart des méthodes actuelles sont basées sur des approches statistiques mais les outils les plus déployés, notamment pour les solutions grand public (comme les applications de guidage routier disponibles gratuitement pour smartphones), ne font l'objet de peu voire d'aucune publication, hors brevets, pour des raisons évidentes d'intérêt économique. A contrario, les outils à destination des opérateurs routiers (les deux principaux étant PTV Optima et Aimsun Live) sont principalement basés sur des modèles d'écoulement du trafic permettant des simulations de scénarios de gestion du trafic. Ces outils pour les gestionnaires routiers utilisent presque exclusivement la prévision pour de l'aide à la décision et non pour de l'information aux usagers.

Il est communément admis qu'il n'existe pas de méthode universellement meilleure que les autres, en toute situation. Il est nécessaire de choisir la méthode en fonction de critères (comme l'horizon temporel et la latence acceptée pour le temps de calcul).

Par ailleurs, les expérimentations de prévision se concentrent quasi-exclusivement sur les voies périurbaines et interurbaines ainsi que sur les grandes artères urbaines.

Il y a peu de travaux sur la prévision des temps de parcours à partir de données Bluetooth. Il semblerait que la variable « temps de parcours » seule ne permette pas une caractérisation suffisamment détaillée de l'état de trafic. Il est par exemple impossible de connaître précisément la position de la queue de bouchon avec simplement des données temps de parcours. La littérature porte surtout sur la prévision à partir de données de débit issues de capteurs fixes ou de vitesses à partir de données mobiles.

Quel que soit le type de méthode (statistique ou phénoménologique) choisi, la mise en place d'un outil de prévision à court terme du trafic demande certains pré-requis et certaines ressources, qui peuvent être particulièrement contraignants pour un exploitant routier. Aussi, il convient de bien estimer la pertinence de la mise en place d'un tel projet au regard des bénéfices attendus. Une manière de procéder consisterait à estimer la fiabilité de l'information routière en comparant par exemple les temps de parcours affichés aux usagers en entrée de section (les temps de parcours reconstitués sortants dans le cas de capteurs Bluetooth) et les temps de parcours réellement expérimentés.

5 Remerciements

Pour les informations fournies, les auteurs remercient :

- M. Philippe GOUDAL, Mediamobile, directeur de l'innovation et du développement ;
- M. Jean-Baptiste MOLINS, PTV France, ingénieur commercial et ingénieur projet ;
- M. Jean-Baptiste DERDOY, PTV France, chef de projet ;
- Prof. Hans VAN LINT, TU Delft (Pays-Bas), professeur-chercheur en simulation du trafic ;
- M. Emmanuel BERT, Aimsun, chef de produit Aimsun Live ;
- M. David MENEGAUX, Phoenix ISI, directeur scientifique ;
- M. Jean-Christophe COSSO, Conseil Départemental de Charente-Maritime, directeur adjoint de l'Environnement et de la Mobilité ;
- M. Pierre-Antoine LAHAROTTE, Cerema Centre-Est, chargé d'études trafic et déplacements.

6 Bibliographie

- Allain, G. (2008). *Prévision et analyse du trafic routier par des méthodes statistiques*. Thèse de doctorat, Université de Toulouse, Université Toulouse III-Paul Sabatier.
- Baudel, T., Wynter, L. & Coldefy, J. (2013). Prédiction du trafic et optimisation des déplacements professionnels planifiés : travaux d'IBM dans le projet Optimod'Lyon, congrès ATEXPO 2013
<http://thomas.baudel.name/UrbanInformatics/ATEXPO2013-final.pdf>
- Barceló, J., Montero, L., Marqués, L., & Carmona, C. (2010). Travel time forecasting and dynamic origin-destination estimation for freeways based on bluetooth traffic monitoring. *Transportation research record*, 2175(1), 19-27.
- Billot, R. (2017). Fouille de données, Modélisation et Optimisation. Applications à la mobilité intelligente et la santé connectée. Mémoire d'Habilitation à Diriger des Recherches, Université Claude Bernard Lyon 1, 224 pages.
- Canudas De Wit, C., Morbidi, F., Ojeda, L. L., Kibangou, A. Y., Bellicot, I., & Bellemain, P. (2015). Grenoble traffic lab: An experimental platform for advanced traffic monitoring and forecasting [applications of control]. *IEEE Control Systems Magazine*, 35(3), 23-39.
- Danech-Pajouh, M., & Aron, M. (1991). ATHENA: a method for short-term inter-urban motorway traffic forecasting. *Recherche Transports Sécurité*, (6).
- Dochy, T., Danech-Pajouh, M., & Lechevallier, Y. (1994). Short-Term Traffic Forecasting Using Neuronal Network. *IFAC Proceedings Volumes*, 27(12), 633-638.
- Duret, A., & Esposito, M.-C., & Remesy, R. (2016). Mise en œuvre d'un outil de simulation de trafic en temps réel à la DiRIF. Communication Congrès ATEC ITS France.
- Haworth, J. (2014). *Spatio-temporal forecasting of network data*, Doctoral dissertation, UCL (University College London).
- Hofleitner, A., Herring, R., & Bayen, A. (2012). Arterial travel time forecast with streaming data: A hybrid approach of flow modeling and machine learning. *Transportation Research Part B: Methodological*, 46(9), 1097-1122.
- Khoei, A. M., Bhaskar, A., & Chung, E. (2013). Travel time prediction on signalised urban arterials by applying SARIMA modelling on Bluetooth data. In *36th Australasian transport research forum (ATRF) 2013*.
- Laharotte, P. A. (2016). *Contributions à la prévision court-terme, multi-échelle et multi-variée, par apprentissage statistique du trafic routier*. Thèse de doctorat, Université de Lyon, 269 pages.
- Laña, I., Del Ser, J., Velez, M., & Vlahogianni, E. I. (2018). Road Traffic Forecasting: Recent Advances and New Challenges. *IEEE Intelligent Transportation Systems Magazine*, 10(2), 93-109.
- Li, L., Lv, Y., & Wang, F. Y. (2016). Traffic signal timing via deep reinforcement learning.

IEEE/CAA Journal of Automatica Sinica, 3(3), 247-254.

Min, W., & Wynter, L. (2011). Real-time road traffic prediction with spatio-temporal correlations. *Transportation Research Part C: Emerging Technologies*, 19(4), 606-616.

Qiao, W., Haghani, A., & Hamedi, M. (2012). Short-term travel time prediction considering the effects of weather. *Transportation research record*, 2308(1), 61-72.

Qiao, W., Haghani, A., & Hamedi, M. (2013). A nonparametric model for short-term travel time prediction using bluetooth data. *Journal of Intelligent Transportation Systems*, 17(2), 165-175.

Reclus, F. (2012). Prévisions de trafic court et moyen termes. Méthodes, modèles et outils. *Rapports du CETE de Lyon*, 58 pages.

Rice, J., & Van Zwet, E. (2004). A simple and effective method for predicting travel times on freeways. *IEEE Transactions on Intelligent Transportation Systems*, 5(3), 200-207.

Saint, R. (2016). *Étude des instabilités dans les modèles de trafic* (Doctoral dissertation, Université Paris-Est).

SETA project (2016). Deliverable 4.1. Exploring prediction perspectives. 57 pages. Accessible en ligne : http://staffwww.dcs.shef.ac.uk/people/L.Moffatt/Seta_Deliverables/D4.1_Final.pdf

Van Lint, H., & Van Hinsbergen, C. (2012). Short-term traffic and travel time prediction models. *Artificial Intelligence Applications to Critical Transportation Issues*, 22(1), 22-41.

Vlahogianni, E. I., Karlaftis, M. G., & Golias, J. C. (2014). Short-term traffic forecasting: Where we are and where we're going. *Transportation Research Part C: Emerging Technologies*, 43, 3-19.

Webographie

Page internet d'IBM consultée le 28/01/2019

https://researcher.watson.ibm.com/researcher/view_group_subpage.php?id=1248

et (consultée le 19/06/2019)

https://www.ibm.com/support/knowledgecenter/en/SS9HHZ/transport/ov_tp.html

Page internet de Thalès consultée le 10/06/2019

<https://www.thalesgroup.com/en/global/presence/europe/united-kingdom/transportation/roads>

et

<https://www.thalesgroup.com/en/united-kingdom/news/rail-road-big-data-and-transport>

Page internet du Ministère de la Transition Ecologique et Solidaire, consultée le 28/01/2019

<http://www.equipementsdelaroute.developpement-durable.gouv.fr/technologies-r105.html>

Page internet Inria Grenoble, consultée le 08/07/2019

<http://gtl.inrialpes.fr/predictions>

Page internet d'Aimsun, consultée le 14/06/2019

<https://www.aimsun.com/integrated-corridor-management-project-in-san-diego/>
et

<https://www.aimsun.com/aimsun-live/>

Page internet de PTV, consultée le 14/06/2019

<http://vision-traffic.ptvgroup.com/en-us/products/ptv-optima/>

et

<https://www.ptvgroup.com/en/solutions/products/ptv-optima/references/>

Page internet du projet Mob2i, consultée le 08/07/2019

<http://www.mob2i.fr/>

*



Cerema Ouest

MAN – 9 rue René Viviani – BP 46223 NANTES Cedex 02

Tel : 02 40 12 83 01 – mel : DTerOuest@cerema.fr

www.cerema.fr