

Dimensionnement d'une flotte de véhicules électriques de service : développement d'une méthodologie combinant prévisions, simulation à événement discret et heuristiques

par

Simon JEZEQUEL

MÉMOIRE PRÉSENTÉ À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
COMME EXIGENCE PARTIELLE À L'OBTENTION DE
LA MAITRISE EN GENIE DE LA PRODUCTION AUTOMATISEE

MONTREAL, LE 19 DECEMBRE 2025

ECOLE DE TECHNOLOGIE SUPÉRIEURE
UNIVERSITÉ DU QUÉBEC

©Tous droits réservés, Simon JEZEQUEL, 2025

©Tous droits réservés

Cette licence signifie qu'il est interdit de reproduire, d'enregistrer ou de diffuser en tout ou en partie, le présent document. Le lecteur qui désire imprimer ou conserver sur un autre media une partie importante de ce document, doit obligatoirement en demander l'autorisation à l'auteur.

PRÉSENTATION DU JURY

CE MEMOIRE A ÉTÉ ÉVALUÉ

PAR UN JURY COMPOSÉ DE :

Mme Boukherroub Tasseda, directrice de mémoire
Département de Génie des systèmes à l'École de technologie supérieure

Mme Berraf-Belmokhtar, codirectrice de mémoire
Département de Génie industriel à l'Université Gustave Eiffel

M. Carter Alan, président du jury
Département de Génie de la construction à l'École de technologie supérieure

M. Ruiz Angel, examinateur externe
Département opérations et systèmes de décision à l'Université Laval

IL A FAIT L'OBJET D'UNE SOUTENANCE DEVANT JURY ET PUBLIC

LE 18 NOVEMBRE 2025

A L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE

AVANT-PROPOS

Ce mémoire permet de présenter mes travaux durant les deux dernières années pour l'obtention du diplôme de Maîtrise en Génie de la Production Automatisée, à l'École de technologie supérieure (ÉTS) de Montréal. Il est dédié au développement d'un outil d'aide à la décision pour le dimensionnement et la gestion d'une flotte de véhicules de service, ayant entre autres, pour mission de maintenir les bus en conditions opérationnelles de fonctionnement. Cette étude menée en partenariat avec la société de transport de Montréal (STM) a été motivée par une politique de mobilité électrique, visant à réduire l'impact écologique du transport. Comme les véhicules électriques sont coûteux, il est indispensable de se doter d'une méthodologie pour dimensionner la flotte d'une part et assurer la même qualité de service d'autres part. Par ailleurs, cette transition électrique amène de nouvelles contraintes liées à l'autonomie des véhicules qui doivent être intégrées.

Cette étude se veut être une contribution permettant d'offrir un cadre générique de modélisation d'une flotte de véhicules de service considérant la nature stochastique de la demande d'intervention, à savoir des incidents impactant le service des bus. Ainsi, un modèle de simulation est développé afin d'évaluer différentes stratégies d'affectation des véhicules aux demandes d'intervention (dispatching). De plus, des heuristiques ont été développées afin de dimensionner la flotte de véhicule dans un contexte déterministe.

Cette étude s'est basée sur un historique de données, regroupant l'ensemble des interventions de la STM correspondant aux cinq dernières années. Toutefois, les données disponibles n'étaient pas complètes ce qui nous a conduit à proposer un passage à l'échelle de ces dernières. De plus, le fort caractère stochastique de la demande selon les deux dimensions spatiale et temporelle, nous ont amené à définir et à considérer la distribution de cette dernière.

Une partie de ce travail a été présentée dans un article de conférence internationale (JEZEQUEL et al., 2025).

REMERCIEMENTS

Je tiens à remercier tout particulièrement Tasseda BOUKHERROUB et Sana BERRAF-BELMOKHTAR, en leurs qualités de directrice et co-directrice de recherche, pour leurs conseils avisés tout au long de mon projet de ma maîtrise. Leur confiance et leur sympathie m'ont permis d'effectuer cette étude dans les meilleures conditions possibles.

J'aimerais également remercier notre partenaire industriel, la STM, et en particulier les collaborateurs avec lesquels j'ai eu l'occasion de travailler. Je tiens à remercier Timothy AYOUB, instigateur de ce projet de recherche, mais également Étienne LE PIRONNEC et François ARSENAULT pour leur expertise, leur patience et leur suivi régulier du projet. La confiance et l'enthousiasme qu'ils ont manifestés à l'égard de mon travail ont été particulièrement valorisant. De même j'aimerais remercier MITACS et IVADO, et en particulier Jean-François Bruneau, pour leur soutien à ce projet.

Enfin, j'aimerais remercier l'ensemble des personnes que j'ai eu l'occasion de rencontrer à Montréal et en particulier mes amis. Leur soutien indéfectible et leurs encouragements ont été une grande source de motivation tout au long de mon projet de recherche. Pour finir, je tiens à remercier tout particulièrement ma famille, sans qui rien de cela n'aurait été possible.

Dimensionnement d'une flotte de véhicules électriques de service : Développement d'une méthodologie combinant prévisions, simulation à évènement discret et heuristiques

Simon JEZEQUEL

RÉSUMÉ

Le dimensionnement d'une flotte de véhicules de service demeure un défi majeur pour de nombreuses entreprises, même avec l'utilisation répandue des systèmes ERP qui permettent d'obtenir de nombreuses données. Cela s'explique notamment par la nature stochastique de ce type de problème, les véhicules de service se déplaçant sur demande pour prendre en charge des incidents difficiles à prévoir. Ainsi, contrairement à des interventions pouvant être planifiées à l'avance (en construisant des tournées de véhicules au préalable), lors du départ d'un véhicule, pour lequel on souhaite minimiser les temps de déplacement, les moments d'apparition et les localisations des interventions devant être prises en charge ne sont pas connues avec précision.

Les approches de dimensionnement traditionnelles trouvées dans la littérature ont souvent du mal à capturer efficacement le caractère stochastique de ce problème, ainsi qu'à faire un lien entre la composante temporelle et la composante spatiale des demandes d'intervention. Enfin, le passage à l'électrique est un enjeu majeur dans l'industrie, qui n'a que peu été étudié dans ce cadre-ci.

Dans cette optique, ce mémoire de maîtrise propose une approche basée sur les données pour le dimensionnement d'une flotte de véhicules électriques de service pour laquelle la demande est stochastique. Cette méthodologie est séparée en trois parties majeures : 1) la prévision des interventions futures, 2) la mise en place d'un modèle de simulation afin de tester de nouvelles stratégies d'affectation des véhicules de service aux interventions et 3) le développement d'heuristiques nous permettant de construire des tournées de véhicules dans le cas où les prévisions des interventions seraient suffisamment fiables. Notre attention s'est également portée sur la rectification des données collectées. Pour ce faire, à partir du modèle de simulation une méthodologie a été construite afin de mettre à l'échelle le nombre d'interventions.

Ce qui distingue cette approche de l'existant est l'application de méthodes utilisées dans des domaines connexes à un domaine encore peu traité, celui des véhicules électriques de service, répondant à des interventions (difficiles à prévoir) impactant l'offre de service de transports en commun. Son originalité réside dans le traitement des données permettant de mimer l'apparition spatiotemporelle des demandes d'interventions combiné dans un premier temps, à la simulation et ensuite à des heuristiques qui ont servi au dimensionnement de la flotte des véhicules de service.

Nos résultats montrent que le passage à l'électrique peut être une opportunité menant à la réduction de la taille de la flotte chez la STM, en fonction des hypothèses choisies, allant jusqu'à 68% de véhicules en moins par rapport au nombre actuel de véhicules. Certaines stratégies testées pouvaient se traduire par des temps d'intervention moyen diminués. Enfin, la centralisation des véhicules au sein d'un même dépôt ne ferait pas augmenter substantiellement le temps d'intervention ce qui entrainerait des économies sur les infrastructures de recharge, avec leur mutualisation pour l'ensemble de la flotte.

Mots-clés :

Véhicules électriques, Transport, Prévisions, Simulation à évènement discret, Affectation, Dimensionnement de flotte, Heuristiques.

Electric Service Vehicle Fleet Sizing: A Methodological Approach Combining Forecasting, Discrete-Event Simulation and Heuristics

Simon JEZEQUEL

ABSTRACT

Sizing a fleet of service vehicles remains a major challenge for many companies, even with the widespread use of ERP systems that provide access to large amounts of data. This difficulty is largely explained by the stochastic nature of the problem: service vehicles are dispatched on demand to handle incidents that are difficult to predict. Thus, unlike interventions that can be planned in advance (by constructing vehicle routes beforehand), when a vehicle is dispatched—where the objective is to minimize travel times—the times of occurrence and the locations of the interventions to be handled are not known precisely.

Traditional sizing approaches found in the literature often struggle to effectively capture the stochastic nature of this problem, as well as to establish a link between the temporal and spatial components of intervention demand. Finally, the transition to electric vehicles presents a major challenge for the industry that has been little studied in this specific context.

In this perspective, this master's thesis proposes a data-driven approach to sizing a fleet of electric service vehicles facing stochastic demand. This methodology is divided into three main parts: 1) forecasting future interventions, 2) developing a simulation model to test new strategies for assigning service vehicles to interventions, and 3) developing heuristics to construct vehicle routes in cases where intervention forecasts are sufficiently reliable. Particular attention was also given to the correction of collected data. To this end, a methodology was developed, based on the simulation model, to scale the number of interventions.

What distinguishes this approach from existing work is the application of methods used in related fields to a domain that has been little explored: electric service vehicles responding to (hard-to-predict) interventions that affect the level of public transportation service. Its

originality lies in the processing of data to mimic the spatiotemporal occurrence of intervention requests, combined first with simulation and subsequently with heuristics used for sizing the service vehicle fleet.

Our results show that the transition to electric vehicles can represent an opportunity to reduce fleet size at the STM, depending on the assumptions considered, with reductions of up to 68% in the number of vehicles compared to the current fleet. Some of the tested strategies also resulted in lower average intervention times. Finally, centralizing vehicles within a single depot would not substantially increase intervention times, which would lead to savings in charging infrastructure through its shared use across the entire fleet.

Key-words:

Electric vehicles, Transportation, Forecast, Discrete event simulation, Assignment, Fleet sizing, Heuristics.

TABLE DES MATIÈRES

	Page
INTRODUCTION	1
CHAPITRE 1 DESCRIPTION DU CAS D'ETUDE	5
1.1 Exploitation des bus.....	5
1.2 Maintenance des bus	6
1.2.1 Maintenance en CT	6
1.2.2 Tâches des chefs d'opération (CO).....	6
CHAPITRE 2 REVUE DE LA LITTERATURE	11
2.1 Les travaux de la littérature portant sur les prévisions de la demande	11
2.1.1 Quelques concepts importants	11
2.1.2 Méthodologie de recherche bibliographique	13
2.1.3 Catégorisation des profils de demande	14
2.1.4 Données d'entrée et méthodes de prévisions	17
2.1.4.1 Données d'entrée	17
2.1.4.2 Les travaux sur les méthodes de prévisions pour les incidents..	19
2.1.4.3 Evaluation des méthodes de prévision	24
2.2 Les travaux sur les stratégies d'affectation et le dimensionnement de flotte de véhicules	26
2.2.1 Stratégie de recherche bibliographique.....	26
2.2.2 Stratégies d'affectation et méthodes de dimensionnement de flotte.....	27
2.3 Conclusion	32
CHAPITRE 3 METHODOLOGIE	33
3.1 Collecte des données.....	33
3.1.1 Source des données	33
3.1.2 Structure des données	35
3.1.3 Localisation des demandes d'interventions	37
3.1.4 Sectorisation des interventions	37
3.2 Développement des modèles de prévisions des demandes d'interventions.....	40
3.2.1 Analyse des données	40
3.2.2 Les modèles de prévision des demandes d'interventions	42
3.3 Un cadre générique de modélisation basé sur la simulation à évènement discret	46
3.3.1 Hypothèses et indicateurs de performance	46
3.3.1.1 Hypothèses.....	46
3.3.1.2 Indicateurs de performance.....	48
3.3.2 Le modèle de simulation.....	49
3.3.3 Génération de plusieurs niveaux de densité de la demande pour une mise à l'échelle du nombre d'interventions	53
3.3.4 Évaluation des différentes stratégies de dispatching	53
3.4 Heuristiques pour la variante déterministe	55

3.4.1	Heuristique du plus proche voisin.....	57
3.4.2	Heuristique de <i>Clark & Wright</i>	58
3.4.3	Heuristique basée sur l'aléatoire.....	61
CHAPITRE 4 RESULTATS		63
4.1	Evaluation des modèles de prévision des demandes d'interventions	63
4.2	Validation du modèle de simulation à évènement discret	65
4.2.1	Mise à l'échelle de la demande d'interventions.....	65
4.2.2	Comparaison des stratégies d'affectation	65
4.2.3	Analyse de sensibilité	69
4.3	Evaluation des heuristiques.....	71
4.4	Conclusion	72
CONCLUSION.....		73
LISTE DE RÉFÉRENCES BIBLIOGRAPHIQUES		75

LISTE DES TABLEAUX

	Page
Tableau 2.1	Concepts et mots clés relatifs aux prévisions de la demande d'interventions utilisés pour notre revue de littérature13
Tableau 2.2	Concepts et mots clés relatifs aux stratégies d'affectation et au dimensionnement utilisés pour notre revue de littérature26
Tableau 3.1	Tableau décrivant les indicateurs et leurs cibles49
Tableau 3.2	Tableau récapitulatif des règles de dispatching54
Tableau 4.1	Tableau récapitulatif des résultats des méthodes de prévisions63
Tableau 4.2	Tableau récapitulatif des résultats pour chaque règle d'affectation pour différents scénarios70
Tableau 4.3	Tableau récapitulatif des résultats pour chaque heuristique71

LISTE DES FIGURES

	Page
Figure 1.1	Carte de la sectorisation de l'île de Montréal de la STM et des CT obtenue sur QGIS7
Figure 1.2	Cartographie du processus d'affectation des véhicules des CO aux demandes d'interventions8
Figure 2.1	Représentation graphique des profils de demande dans la catégorisation ADI / CV2 (Adam et al., 2024).....16
Figure 3.1	Grille horaire prévisionnelle de la pré-affectation des véhicules aux créneaux34
Figure 3.2	Graphique du nombre total d'interventions par année35
Figure 3.3	Capture d'écran du logiciel Google Earth, avec la sectorisation de l'île de Montréal.....38
Figure 3.4	Capture d'écran du logiciel QGIS, représentant l'ensemble des interventions sur 4 années.....39
Figure 3.5	Nombre d'interventions total sur par mois par secteur cumulé sur 4 années41
Figure 3.6	Nombre d'interventions total sur 4 ans par jour par secteur cumulé sur 4 années.....41
Figure 3.7	Nombre d'interventions total sur 4 ans par heure par secteur cumulé sur 4 années.....42
Figure 3.8	Histogramme de la durée des interventions par tranche de 10 mins.....48
Figure 3.9	Représentation macro du fonctionnement du modèle de simulation49
Figure 3.10	Représentation de la dispersion géographique des bornes d'acquisition des données de la ville de Montréal51
Figure 3.11	Vitesse moyenne des véhicules par heure pour les différents jours de la semaine de l'île de Montréal52
Figure 3.12	Processus itératif de réduction du nombre de véhicules55

Figure 3.13	Schéma présentant l'adaptation de l'heuristique du plus proche voisin.....	58
Figure 3.14	Schéma présentant l'adaptation de l'heuristique de Clark & Wright.....	60
Figure 4.1	Exemple de prévisions obtenues à l'aide de la méthode de la régression linéaire avec facteurs de saisonnalité.....	64
Figure 4.2	Nombre d'interventions en fonction du taux d'utilisation moyen des véhicules des CO par jour	65
Figure 4.3	Nombre minimal de véhicules nécessaires obtenu avec les stratégies d'affectation proposées pour 173 demandes journalières	67
Figure 4.4	Répartition du temps d'attente moyen sur 30 réplifications pour 173 demandes journalières.....	67
Figure 4.5	Répartition du taux d'utilisation moyen sur 30 réplifications pour 173 demandes journalières.....	68
Figure 4.6	Répartition de la distance moyenne parcourue par véhicule sur 30 réplifications pour 173 demandes journalières.....	68

LISTE DES ABRÉVIATIONS, SIGLES ET ACRONYMES

STM	Société de transport de Montréal
CO	Chef d'Opération
CT	Centre de Transport
COP	Centre Opérationnel Principal
MILP	Mixed Integer Linear Programming
VRP	Vehicle Routing Problem
CR	Current Rule
C-CR	Centralized Current Rule
GRA	Greatest Remaining Autonomy
LUV	Least Used Vehicle

INTRODUCTION

Dans le cadre de son engagement envers les objectifs de durabilité, la Société de transport de Montréal (STM), une entreprise de transport public au Québec (Canada), vise à électrifier l'ensemble de sa flotte de bus et de véhicules de service d'ici 2027 (STM, 2023). Parmi les véhicules de service à électrifier, nous nous intéressons en particulier à ceux utilisés par les chefs d'opérations (CO). Ces véhicules permettent aux CO d'intervenir rapidement sur le réseau de bus pour résoudre des problèmes pouvant perturber le service, tels que des détours, des problèmes de signalisation, des pannes de matériel léger et des conflits entre passagers. La mission des CO est d'être présents en tout temps sur le territoire de l'île de Montréal afin de minimiser l'impact négatif de ces perturbations. L'île de Montréal est divisée en 15 secteurs géographiques, au sein desquels les véhicules de huit centres de transport (CT) opèrent. En effet, les CT servent à la fois de centres de transport de bus, mais aussi de centres d'opérations de maintenance. Lorsqu'un incident survient, le conducteur de bus concerné contacte le centre opérationnel principal (COP), qui est responsable du maintien de service de bus. Actuellement, la stratégie du COP consiste à attribuer le véhicule de service disponible le plus proche pour prendre en charge l'incident. Cette stratégie présente l'avantage d'être facilement mise en œuvre dans la pratique et d'offrir une réponse rapide au problème d'affectation des véhicules. Cependant, elle pourrait ne pas être la plus appropriée dans le cadre d'une volonté de réduction de la taille de la flotte.

Étant donné que l'électrification d'une flotte entière de véhicules est très coûteuse et que le problème d'optimisation du dimensionnement de la flotte n'a pas été étudié, l'objectif de notre étude est de définir la taille minimale de la flotte de véhicules de CO nécessaire pour la prise en charge de l'ensemble des demandes, tout en tenant compte des contraintes spécifiques des véhicules électriques et en préservant la même qualité de service. De plus, nous proposons d'évaluer différentes stratégies d'affectation (par simulation) et de construire des tournées de véhicules (en utilisant des heuristiques) afin de réduire le plus possible la taille de la flotte de véhicules de service. Plus précisément, nous proposons une méthodologie séparée en trois parties majeures : 1) la prévision des interventions futures, 2) la création d'un modèle de

simulation dans un contexte stochastique et 3) le développement d'heuristiques dans un contexte déterministe. Le choix du modèle de simulation est justifié par la nature stochastique du problème étudié, en particulier la grande variabilité de la demande d'intervention dans le temps et dans l'espace. Les heuristiques quant à elles seraient utilisées dans un contexte où les prévisions des demandes d'interventions seraient suffisamment fiables. L'approche proposée est destinée à évaluer et améliorer certains indicateurs de performance qui ont été définis en fonction des priorités de l'entreprise, à savoir : 1) la taille de la flotte, 2) le temps d'attente entre l'appel au COP et l'arrivée du véhicule, 3) la distance totale parcourue et 4) le taux d'utilisation des véhicules. Ces indicateurs ont un niveau de priorité décroissant, du plus important au moins important. Nous réalisons une étude expérimentale pour évaluer et comparer les différentes stratégies d'affectation (aussi désignées par le terme *dispatching*) au regard de ces indicateurs. Cette étude s'accompagne d'une analyse de sensibilité pour tenir compte de plusieurs scénarios de mise à l'échelle de la demande en raison de l'indisponibilité de données complètes.

Notre contribution réside dans le traitement des données permettant de mimer l'apparition spatiotemporelle des demandes d'interventions combiné dans un premier temps, à la simulation et ensuite à des heuristiques qui ont servi au dimensionnement de la flotte des véhicules de service. Notre étude est basée sur des données réelles que nous avons analysées notamment pour établir des modèles de prévision des demandes d'intervention. Le modèle de simulation développé permet d'évaluer de nouvelles stratégies d'affectation des véhicules aux interventions, et de déterminer la taille de la flotte de véhicules de service. Enfin, nous avons testé des heuristiques de construction de routes, afin de dimensionner la flotte, dans le cas où les prévisions des demandes d'interventions seraient assez précises.

Ce mémoire est organisé en 5 chapitres. Le premier détaille le cas d'étude. Le deuxième chapitre présente notre revue de la littérature, détaillant un état de l'art des méthodes de prévisions, suivi par une présentation des outils d'aide à la décision, tels que l'optimisation, les heuristiques et la simulation à événement discret, utilisées dans le cadre du dimensionnement de flottes de véhicules de service. Le troisième chapitre est consacré à la méthodologie mise en place, constituée de trois parties : 1) prévisions des interventions futures,

2) construction du modèle de simulation et enfin 3) mise en place d'heuristiques de planification de tournées. Le chapitre 4 expose les résultats des prévisions et analyse les performances et limites de chaque stratégie testée en simulation à événement discret et des heuristiques. Enfin le chapitre 5 est consacré à la discussion des résultats, aux recommandations pour la STM et enfin aux travaux futurs.

CHAPITRE 1

DESCRIPTION DU CAS D'ETUDE

Dans ce chapitre, nous allons décrire et définir le problème décisionnel rencontré en présentant le fonctionnement de l'entreprise partenaire qui est la société de transport de Montréal (STM). La STM est la plus grande entreprise de transports public de l'agglomération de Montréal. Cette dernière a notamment permis de réaliser plus de 288 millions de déplacements utilisateurs sur son réseau, au cours de l'année 2023, soit une augmentation de 21% comparativement à l'année précédente (STM, 2023). Afin d'assurer ces déplacements, la STM exploite des métros, des bus et des navettes. En particulier, sur 228 lignes de bus, la STM gère une flotte de 1992 bus.

Dans cette étude, nous allons nous intéresser en particulier à la prise en charge des incidents sur le réseau de bus. Pour ce faire, nous présentons les processus en place pour répondre aux interventions et les enjeux liés à ce service. Ainsi, dans un premier temps, nous nous intéressons à l'exploitation des bus et à leur maintien en conditions opérationnelles. Pour ce faire, nous allons analyser les données disponibles concernant l'ensemble des interventions réalisées.

1.1 Exploitation des bus

L'entreprise partenaire est constituée de nombreuses entités, chacune responsable d'un secteur d'activités. On peut par exemple séparer l'exploitation des bus, de la maintenance des bus. L'exploitation est responsable de l'offre de services liée aux bus. En effet, cette entité s'occupe d'affecter des chauffeurs à des bus et à des lignes. L'objectif pour l'exploitation est d'avoir un taux de service maximal c'est-à-dire le plus proche de 100%. Pour ce faire, il est nécessaire de répondre au mieux à la demande, en faisant en sorte que les bus circulant sur le réseau aient le moins de retard possible. L'exploitation compte sur la maintenance préventive, prédictive et curative, généralement réalisées au sein des centres de transport (CT). Cependant, il peut arriver que des pannes matérielles surviennent en cours de service, ou autres types d'incidents,

tels que des incidents voyageurs, des travaux sur la voix, etc. Pour coordonner l'exploitation et la maintenance, le centre opérationnel principal (COP) centralise les appels des chauffeurs de bus afin d'envoyer sur place un chef d'opération (CO).

1.2 Maintenance des bus

Les CO font partie de l'unité d'affaire de la maintenance des bus. La maintenance des bus est séparée en plusieurs entités : la maintenance en CT, à savoir en dépôt et les opérations sur le terrain.

1.2.1 Maintenance en CT

La maintenance en CT réalise tous les types de maintenance : préventive, prédictive et curative. Cette dernière s'organise au sein des 8 CT de bus de l'île de Montréal.

Cette maintenance est répartie en deux catégories : « mineur autobus » et « majeur autobus ». La catégorie « mineur autobus » est réalisée dans les huit CT de bus de l'île de Montréal. Les opérations sous cette catégorie sont principalement des opérations de changements de composants. Cependant, lorsque les autobus ont besoin de réparations plus importantes, ces derniers sont envoyés dans les centres responsables des opérations de la catégorie « majeur autobus ».

1.2.2 Tâches des chefs d'opération (CO)

Les CO sont responsables des interventions sur le réseau, en outre des imprévus et urgences, car pouvant impacter le taux de service. Ces interventions peuvent être dues à de nombreuses raisons, telles que des pannes matérielles, des incidents voyageurs, des contournements, des embourbements, etc.

Les véhicules des CO sont répartis dans les huit CT de l'île de Montréal. Chacun de ces centres est assigné à un ou plusieurs secteurs, voir figure 1.1. Plus précisément, la STM a fait le choix de découper l'île de Montréal en 15 secteurs.




Figure 1.1 Carte de la sectorisation de l'île de Montréal de la STM et des CT obtenue sur QGIS

Au cours de leur quart de travail, les CO interviennent dans les secteurs attribués à leur CT. Après réception d'un appel d'un chauffeur de bus, si le COP juge nécessaire l'envoi d'un CO, le COP va déterminer quel CO est le plus approprié pour prendre en charge l'intervention en cours de traitement. Pour ce faire, le COP se réfère à une règle d'affectation qui consiste à assigner le véhicule disponible le plus proche du lieu de l'intervention. Le CO est alors contacté et il se rend sur le lieu de l'intervention dès que possible. Dès lors que ce dernier finit son intervention, il peut être recontacté pour une nouvelle intervention et ce jusqu'à la fin de son quart de travail. Ce processus est présenté dans la figure 1.2.




Figure 1.2 Cartographie du processus d'affectation des véhicules des CO aux demandes d'interventions

Les CO peuvent également être amenés à réaliser des interventions planifiées. Ces dernières sont demandées par le responsable des CO, à savoir le gestionnaire des CO. Ces opérations concernent généralement le marquage lié à des contournements (par exemple le cas de routes barrées) pour informer les usagers du nouveau trajet du bus.

Chaque véhicule (CO), à la fin de son quart de travail rentre au CT. Au sein de chaque CT se trouvent des bornes de recharge pour les véhicules électriques des CO. En outre, à la suite de cette étude, ces bornes serviront à recharger l'ensemble de la flotte.

Ainsi, le problème posé pour cette étude est le dimensionnement de la flotte de véhicules de service, qui sera électrifiée, avec pour objectif, une réduction de sa taille d'au moins 20%. Une estimation du nombre d'interventions future doit être réalisée, à l'aide de méthodes de prévisions. Cette évaluation sera réalisée grâce à un modèle de simulation à événement discret afin de tester plusieurs stratégies d'affectation ainsi qu'à évaluer la taille de la flotte « optimale » pour chacune d'entre elles. Enfin, dans un contexte où les prévisions des demandes d'interventions seraient considérées comme étant fiables (contexte déterministe), des heuristiques seront développés afin de construire des tournées et de dimensionner la flotte de manière à réduire sa taille. Ainsi, dans cette partie, nous avons délimité les contours du problème.

CHAPITRE 2

REVUE DE LA LITTÉRATURE

Ce chapitre présentera un état de l'art sur les prévisions dans des cas se rapprochant de notre problème, suivi par une revue sur les modèles d'aide à décision pour le dimensionnement de flottes de véhicules et les stratégies d'affectation. Dans un premier temps, des termes clés utilisés seront définis. Par la suite, ce chapitre sera scindé en deux parties majeures, la première portera sur quelques modèles de prévision proposés dans la littérature, notamment ceux basés sur les séries temporelles. La seconde partie est dédiée aux travaux relatifs aux modèles d'aide à la décision proposés pour les problèmes d'affectation de véhicules et/ou de dimensionnement de flottes de véhicules pour réaliser des intervention (exemple : véhicules d'urgence).

2.1 Les travaux de la littérature portant sur les prévisions de la demande

Dans cette section, nous analysons les travaux les plus proches du notre problème de prévision. Ceux-ci portent sur des méthodes utilisées dans la prévision d'incidents. Nous nous sommes intéressés à plusieurs types d'incidents, et en particulier à des incidents routiers, ou à des urgences médicales, car nous n'avons pas trouvé d'exemples suffisamment proche de notre cas d'étude.

2.1.1 Quelques concepts importants

Cette section présente quelques termes clés liés au sujet de ce mémoire. La bonne compréhension de ces concepts sera nécessaire à l'appréciation de ce travail de recherche.

Prévision :

La prévision est l'action d'évaluer les conditions commerciales futures dans le but de préciser les objectifs d'une entreprise et les moyens à mettre en place afin de les atteindre. Ainsi, la prévision permet à une entreprise d'anticiper les phénomènes futurs afin de mieux répondre aux demandes futures (Nahmias et Olsen, 2015). La prévision joue donc un rôle majeur dans l'industrie, et en particulier, dans notre cas (évaluation du nombre d'incidents sur le réseau de bus).

Taux de service :

Comme de nombreuses entreprises, un des indicateurs de performance orientés client le plus important, notamment pour une entreprise d'exploitation d'équipements, est le taux de service. Cet indicateur permet de mesurer la proportion de la demande qui pourra, en moyenne, être satisfaite sans retard (Asenov et al., 2019). Dans notre cas, les « clients » directement impactés sont aux chauffeurs de bus. Ainsi, cet indicateur permet de faire le lien entre la maintenance et l'exploitation. En effet, dès lors qu'un incident intervient sur le réseau de bus, les chauffeurs peuvent se voir empêchés de continuer leur route, entraînant ainsi des retards sur leur trajet. Les CO ont donc pour objectif d'intervenir le plus vite possible afin de maximiser le taux de service.

Séries et granularité temporelles :

Une série temporelle est une suite de valeurs numériques représentant l'évolution d'une quantité spécifique au cours du temps, dans un ordre chronologique (Nahmias et Olsen, 2015). L'horizon de temps est ainsi divisé en périodes, généralement toutes égales, pouvant aller de la seconde à l'année selon la granularité souhaitée. Par exemple, dans notre cas, à chaque période, un nombre d'incidents est associé. Les séries temporelles sont souvent envisagées comme une première approche pour représenter une évolution du nombre d'évènements tels que les incidents au cours du temps. Toutefois, en fonction de la nature du problème la définition de la granularité temporelle est importante en fonction du niveau décisionnel correspondant. Par exemple, pour un problème stratégique, la granularité

temporelle appropriée pourrait relever du mois ou des semaines alors que pour un problème opérationnel, une granularité plus fine relevant d'un quart de travail décomposant la journée ou la journée elle-même serait plus adaptée.

2.1.2 Méthodologie de recherche bibliographique

Nous avons défini des mots clés correspondant à notre travail afin de le situer par rapport à l'existant. Dans notre cas, cette recherche repose d'abord sur les méthodes de prévisions de la demande ce qui dans notre cas correspond au nombre d'interventions devant être prises en charge par des véhicules de service. Par conséquent, nous avons défini un plan de concepts. Ce plan est représenté par un tableau qui permet de répertorier les concepts importants et leurs synonymes (voir tableau 2.1).

Tableau 2.1 Concepts et mots clés relatifs aux prévisions de la demande d'interventions utilisés pour notre revue de littérature

Concept 1	Concept 2	Concept 3
Forecasting	Incident	Maintenance
Prediction	Accident	Emergency
Forecast	Demand	Public Transports
Predict	Intervention	Public Commuting
		Firefight*
		Medical
		Police
		Tow*

Le plan de concepts ainsi construit maximise la couverture des requêtes associées ce qui permet d'identifier un plus grand nombre de travaux à partir des bases de données identifiées. Ainsi, on obtient la requête suivante : ((« *Forecasting* » OR « *Prediction* » OR « *Forecast* » OR « *Predict* ») AND (« *Incident* » OR « *Accident* » OR « *Demand* » OR « *Intervention* ») AND

(« *Maintenance* » OR « *Emergency* » OR « *Public Transport* » OR « *Public Commuting* » OR « *Firefight** » OR « *Medical* » OR « *Police* » OR « *Tow** »)).

Notre recherche a été menée sur plusieurs bases de données scientifiques. Entre autres à l'aide de Google Scholar, Sciencedirect et Scopus. Nous avons interrogé ces bases de données sur la requête présentée, au mois de mai 2025, ce qui a permis d'obtenir environ 2200 d'articles. Cependant, afin de réduire le nombre d'articles, le choix a été fait d'appliquer un filtre temporel afin de ne choisir que des articles récents, à savoir publiés après 2010, et de ne sélectionner que les articles présentant les études les plus proches de notre problème (lecture du titre et de l'*abstract*).

2.1.3 Catégorisation des profils de demande

Avant de nous intéresser aux méthodes de prévisions communément utilisées pour le type de problème abordé dans ce mémoire, à savoir les prévisions d'incidents / urgences sur le réseau routier, il semble important de mettre en avant la catégorisation des profils de demande. En effet, comme évoqué précédemment, la catégorisation des profils de demande est commune chez les praticiens, afin d'utiliser des méthodes de prévision adaptées. Dans le cadre de la prévision de consommation de pièces durant les inventaires, une classification (Williams, 1984) a été proposée. Cette dernière est constituée de cinq catégories : lisse, irrégulière, *slow-moving*, erratique et hautement erratique. Cette classification a par la suite été simplifiée, toujours dans le même domaine, par Syntetos et al. (2005) en quatre catégories : lisse, erratique, intermittente et grumeleuse. Le choix de cette référence est justifié par son utilisation par la STM. En effet des projets au sein de l'entreprise partenaire ont déjà utilisé cette référence. Ces catégories sont basées sur deux métriques nommées « ADI » et « CV² ». La première signifie « *Average demand interval* », elle caractérise l'intervalle entre deux demandes et elle est calculée comme le rapport entre le nombre de périodes total sur le nombre de périodes avec une demande non nulle. La deuxième métrique, est un coefficient de variation de la quantité de demande par période. Elle est calculée comme le rapport au carré, entre

l'écart-type de la demande σ et la moyenne des demandes μ . Les formules mathématiques sont présentées ci-dessous :

$$ADI = \frac{\text{Nombre total de périodes}}{\text{Nombre de périodes avec demande non nulle}} \quad (2.1)$$

$$CV^2 = \left(\frac{\sigma}{\mu} \right)^2 \quad (2.2)$$

Syntetos et al. (2005) ont fixés les valeurs permettant de classifier en quatre catégories les profils de demande à : $ADI = 1,32$ et $CV^2 = 0,49$. Contrairement à Williams (1984), qui avait choisi ses seuils arbitrairement, Syntetos et al. (2005) se sont basés sur la « MSE », « *Mean Squared Error* ». Cette métrique permet d'évaluer l'erreur moyenne au carré. Ils ont donc utilisé cet indicateur afin de positionner ces seuils.

Ainsi, les catégories de cette classification sont :

- **Lisse** : la quantité d'incidents et les délais entre ces derniers varient peu ($ADI < 1,32$ et $CV^2 < 0,49$) ;
- **Intermittente** : la quantité d'incidents varie peu et les délais entre ces derniers varient fortement ($ADI \geq 1,32$ et $CV^2 < 0,49$) ;
- **Erratique** : la quantité d'incidents varie fortement et les délais entre ces derniers varient peu ($ADI < 1,32$ et $CV^2 \geq 0,49$) ;
- **Grumeleuse** : la quantité d'incidents et les délais entre ces derniers varient fortement ($ADI \geq 1,32$ et $CV^2 \geq 0,49$).

Ces catégories et leurs seuils sont représentés dans la figure 2.1 :




Figure 2.1 Représentation graphique des profils de demande dans la catégorisation ADI / CV2 (Adam et al., 2024)

L'identification de la classe à laquelle notre demande appartenait s'est avérée nécessaire dans notre étude. En effet, en raison du fort caractère stochastique de la demande et du faible nombre d'interventions par jour, il était indispensable de situer notre demande. En particulier, la classification des profils de demande est très peu abordée dans le cas de la prévision des demandes d'interventions dans le cas d'incidents, à la lecture des différentes références étudiées dans cette revue de la littérature. Ainsi, en l'absence de classification spécifique à notre application, nous avons choisi d'utiliser celle dédiée à la gestion de l'inventaire et de faire l'analogie avec notre problème. Il nous suffit de considérer la quantité demandée durant une période comme étant le nombre d'incidents durant une période. Cette classification nous

a ainsi permis de déterminer pour quels profils de demande il est possible d'obtenir des prévisions cohérentes et inversement pour lesquels un travail supplémentaire sur les données est nécessaire. En effet, les prévisions basées sur des séries grumeleuses sur un horizon de temps long, sont compliquées à mettre en place aux vues des méthodes présentes dans l'état de l'art actuel, il est ainsi nécessaire de réaliser un travail sur les données afin de s'extraire du cas grumeleux.

2.1.4 Données d'entrée et méthodes de prévisions

2.1.4.1 Données d'entrée

Dans leur article, Gutierrez-Osorio et al. (2020) soulignent que de bonnes prévisions passent nécessairement par des bases de données fiables et complètes. Dans notre cas, le choix concernant la source des données à utiliser pour les prévisions impacte directement la qualité de la prévision car en pratique l'information est disséminée dans plusieurs sources de données qui sont liées aux incidents décrivant les demandes d'interventions. En pratique, ces données ont cinq origines différentes qui sont : les données gouvernementales ou les « *open data* », les données des outils de mesures, les données captées avec les technologies de communications qu'équipent les véhicules et les réseaux sociaux.

Les bases de données gouvernementales sont générées, collectées, conservées, stockées et rendues accessibles par une entité publique, telle qu'une ville, un pays, etc. Les « *open data* » sont des données produites et financées par des fonds publics, partagées et rendues accessibles sans restriction. Ces deux types de bases de données sont considérées comme fiables (Chand et al., 2021).

Les bases de données des outils de mesures, sont construites à partir des données collectées par des équipements présent sur le réseau routier, tels que des caméras, des radars, etc. Généralement, ces données sont également considérées comme fiables, car résistantes aux conditions extérieures (You et al., 2017).

Les bases de données obtenues à partir d'équipements présents dans les véhicules sont stockées ou transmises à des centres de collecte de données. Elles sont construites à partir d'équipements tels que des accéléromètres mesurant l'accélération du véhicule, des antennes GPS captant la position du véhicule dans l'espace, etc. Ces données sont très intéressantes pour mener à bien les problèmes de prévisions, seulement, elles ne sont pas toujours fiables. En effet, elles nécessitent un grand travail de préparation des données en amont de leur utilisation car certains équipements peuvent être dysfonctionnels. En effet, des capteurs peuvent être hors service ou transmettre des données erronées telles qu'une mauvaise position GPS (Gutierrez-Osorio et al., 2020).

Les réseaux sociaux sont également exploités comme source de données qui ont été utilisées dans le cas des prévisions d'incidents sur le réseau routier (Ning et al., 2019). Ce sont les bases de données les plus récentes dans les prévisions d'incidents. Les sources de données les plus utilisées viennent de *Waze*, *Google Maps* et *Twitter*. Ces dernières sont considérées comme non fiables, partiales et difficiles à interpréter.

Un autre type de base de données utilisé est la base de données d'entreprise (Shah et al., 2024). Cette dernière permet généralement de traiter des problèmes plus spécifiques. En effet, dans le cadre d'incidents sur le réseau routier, ces bases de données ne recensent que les données relatives aux véhicules de l'entreprise. Ainsi, bien que plus restreintes, ces bases de données sont généralement considérées comme fiables.

De plus, certaines études, utilisent des données générées par simulation afin d'évaluer les incidents futurs. Ces sources de données prouvent leur utilité lorsqu'un manque de données est observé. Par exemple, dans le cas d'un incident routier, le temps de reprise du trafic peut être estimé à l'aide de modèles de simulation (Li et al., 2018).

Enfin, les fusions de sources de données sont une source de données grandement utilisée dans la prévision des incidents (Gutierrez-Osorio et al., 2020). Ces fusions permettent généralement d'améliorer les modèles en liant à l'historique des incidents avec des données complémentaires

telles que la météo, le trafic routier, les travaux, etc. Ainsi, les sources de données permettant de réaliser des prévisions liées à des incidents sur le réseau routier sont nombreuses. Le critère principal de sélection d'une source par rapport à une autre est sa fiabilité. Cependant, les bases de données sont généralement fusionnées afin de disposer de l'information la plus complète possible ce qui permet d'améliorer la qualité des prévisions.

2.1.4.2 Les travaux sur les méthodes de prévisions pour les incidents

Zheng et Liu (2009) proposent une vue d'ensemble des méthodes de prévision habituellement utilisées pour les incidents. Dans leur étude, Zheng et Liu (2009) listent les principales catégories de méthodes : les méthodes régressives, les séries temporelles, les chaînes de Markov et les réseaux de neurones. Ces approches ont longtemps constitué la base de la gestion des risques, en exploitant des données historiques pour identifier des tendances et des corrélations possibles.

Les méthodes historiquement les plus utilisées sont les modèles reposant sur une équation fixe. En effet, Shah et al. (2024) souligne l'apport de ces modèles basés sur des séries temporelles, tels que ARIMA et le lissage exponentiel. Ces derniers peuvent prendre en compte la tendance, tout en restant simples à mettre en place.

Parmi les modèles utilisés sur des séries temporelles simples, le lissage exponentiel est couramment utilisé. Cette méthode est particulièrement efficace pour des séries temporelles ne présentant pas de saisonnalité et ayant une tendance constante ou changeant graduellement (Shah et al., 2024).

Contrairement au lissage exponentiel, Ingle et al. (2019) explique que le modèle Holt-Winters, qui est un lissage exponentiel triple, permet de prendre en compte la tendance et la saisonnalité. Ce modèle est également connu sous le nom de triple lissage exponentiel.

Le modèle ARIMA, est une forme généralisée du modèle ARMA, constitué d'une partie autorégressive (AutoRegressive : AR) et d'une partie de moyenne mobile (*Mobile Average* : MA). Cette forme permet de réaliser des prévisions sur des séries temporelles non stationnaires (Zheng et Liu, 2009). Ce modèle permet de prendre en compte la saisonnalité et la tendance dans une série temporelle.

Avec l'explosion des volumes de données disponibles et les progrès rapides dans le domaine de l'intelligence artificielle, les méthodes traditionnelles de modélisation ont été progressivement enrichies, voire remplacées, par des approches issues de l'apprentissage automatique (*machine learning* : ML) et du forage de données (*data mining*). Ces techniques modernes permettent de traiter de grands volumes de données aux structures complexes, d'extraire automatiquement des tendances, et d'apprendre de ces données pour effectuer des prédictions plus précises et plus adaptatives, comme le précisent Gutierrez-Osorio et Pedraza (2020).

L'apprentissage automatique repose sur la capacité des algorithmes à s'entraîner à partir de données historiques, sans être explicitement programmés pour chaque situation. Contrairement aux modèles statistiques classiques qui nécessitent des hypothèses fortes (linéarité, normalité, indépendance des variables), les modèles ML s'adaptent mieux à des données bruitées, incomplètes, ou fortement corrélées.

Gutierrez-Osorio et Pedraza (2020) identifient plusieurs algorithmes couramment utilisés dans le domaine des prévisions des incidents, tels que les arbres de décision (*Decision Trees*), les forêts aléatoires (*Random Forests*), les machines à vecteurs de support (*Support Vector Machines*), les réseaux de neurones profonds (*Deep Neural Networks*) et les réseaux bayésiens (Bayesian Networks).

Ces modèles permettent non seulement de prédire la probabilité d'incidents, mais aussi d'identifier les variables explicatives les plus critiques, comme les conditions météorologiques, le comportement du conducteur, ou la configuration de l'infrastructure.

Au-delà du transport routier, ces méthodes sont aussi appliquées dans d'autres domaines. Eslamzadeh et al. (2022) proposent un cadre structuré d'allocation des ressources dans les services d'incendie, basé sur une analyse systématique des contributions existantes. Leur étude montre comment l'apprentissage automatique s'est imposé au cours des dernières années pour modéliser la probabilité d'intervention, optimiser la localisation des équipements, et prévoir les zones à haut risque.

Shah et al. (2024) mettent en évidence l'intérêt des modèles prédictifs avancés pour prévenir les accidents pour l'activité minière. En particulier, les réseaux de neurones profonds et les algorithmes d'ensemble (comme *XGBoost*) y sont utilisés pour détecter des signaux faibles dans les données d'exploitation, anticiper les pannes ou anomalies, et déclencher des mesures de sécurité préventives.

La distinction entre prévision historique et prévision en temps réel représente une rupture méthodologique majeure dans les systèmes d'aide à la décision en matière de prévisions des incidents, comme abordé par Eslamzadeh et al. (2022). Alors que les approches historiques s'appuient sur l'analyse a posteriori de données collectées sur le long terme, les systèmes en temps réel cherchent à détecter ou prédire les incidents de manière dynamique, à savoir en continu, grâce à des données captées et traitées en continu.

Pendant des décennies, la prévision des accidents reposait uniquement sur des analyses historiques. Ces approches utilisent des bases de données consolidées, souvent issues de rapports d'accidents, d'enquêtes ou de capteurs enregistrant des conditions de circulation passées. Comme l'explique Li et al. (2018), ces modèles sont des modèles en un temps, signifiant qu'ils sont utilisés une fois afin de réaliser des prévisions mais ils ne sont pas réutilisés afin de corriger les prévisions réalisées à l'aide de nouvelles données.

Eslamzadeh et al. (2022) soulèvent ce problème dans son étude, en soulignant qu'une majorité des références traitées ne prenaient pas en compte les données de manière dynamique dans leurs

prévisions. Cette utilisation des données à l'aide des modèles en un temps implique certaines limites pour la gestion opérationnelle telles qu'une faible réactivité face à des changements imprévus et une modélisation statique, souvent non adaptable aux changements de comportements ou de contextes.

À l'opposé, la prévision en temps réel s'appuie sur des flux continus de données issues de capteurs routiers, GPS, réseaux sociaux, vidéosurveillance ou données météorologiques. Des modèles sont capables d'intégrer ces données immédiatement et de produire des alertes ou des prédictions instantanées. You et al. (2017) explorent cette approche sur les autoroutes, en utilisant des techniques de fouille de données pour prédire des accidents à venir. Leur modèle, alimenté par des données comme la densité de trafic, la vitesse moyenne ou les variations météorologiques, permet d'anticiper les collisions avant qu'elles ne surviennent.

De même, Gutierrez-Osorio et Pedraza (2020) soulignent l'intérêt des systèmes intelligents de transport (ITS) qui intègrent les technologies de l'internet des objets (*Internet of Things, IoT*), du *cloud computing* et de l'apprentissage automatique pour renforcer la résilience des réseaux routiers au fil du temps.

Plutôt que d'opposer les deux modèles, les chercheurs tendent aujourd'hui à les combiner. L'historique permet d'entraîner et de paramétrer les algorithmes d'apprentissage automatique tandis que les données en temps réel viennent les alimenter pour les ajuster. L'intégration des deux démarches permet d'offrir une représentativité validée statistiquement (via l'historique) et une précision robuste (via les données en temps réel).

Cela est particulièrement pertinent dans les environnements industriels ou urbains dynamiques, comme le montrent Shah et al. (2024), qui plaident pour une analyse en continu dans le secteur minier afin d'optimiser la sécurité opérationnelle et prévenir les incidents graves.

L'analyse spatio-temporelle représente une avancée méthodologique majeure dans le domaine de la prévision des accidents et des événements critiques. Contrairement aux approches

classiques qui traitent l'espace et le temps comme des variables indépendantes ou secondaires, les modèles spatio-temporels intègrent simultanément la localisation géographique et la dynamique temporelle des événements, permettant une compréhension plus fine de leur distribution et de leur évolution. Ning et al. (2019) proposent un cadre méthodologique pour la prévision d'événements spatio-temporels et l'identification de leurs précurseurs, combinant *deep learning*, graphes dynamiques et analyse multi-échelles. Leur modèle peut être utilisé pour anticiper des accidents dans des zones denses, comme les carrefours urbains, en fonction des flux de véhicules, de la temporalité, et de leur historique. Les avantages clés de ces méthodes incluent la détection de tendances dans l'espace et dans le temps et une capacité d'anticipation géolocalisée des risques.

Du et Ding (2023) proposent une revue systématique des méthodes de prédiction spatio-temporelle, en s'appuyant sur des applications dans le domaine de la sécurité liées à la criminalité. Leur travail, bien que centré sur un autre champ, met en lumière des techniques facilement transposables à la prévision d'accidents ; les réseaux de neurones convolutifs spatio-temporels, LSTM spatio-temporels, les modèles à attention spatiale, etc. L'avantage principal de ces méthodes est leur capacité à changer d'échelle d'analyse ; elles peuvent à la fois capturer des phénomènes globaux (tendances régionales, saisonnalité mensuelle) et détecter des variations locales fines (quartiers, tronçons routiers, moments critiques, saisonnalité horaire).

Bien que les méthodes spatio-temporelles offrent un grand potentiel, elles posent aussi plusieurs défis. Ces méthodes nécessitent une grande capacité calculatoire principalement en raison du large volume des données, mais également de la complexité des algorithmes utilisés. De plus, ces méthodes nécessitent d'avoir des bases de données robustes et donc des capteurs et processus de stockage de données fiables. Malgré ces limites, les travaux récents, notamment ceux de Ning et al. (2019) et Du et Ding (2023), montrent que l'intégration spatio-temporelle dans les modèles prédictifs constitue aujourd'hui un axe prometteur pour l'anticipation fine des risques, que ce soit dans les transports, les services d'urgence ou l'industrie. Il faut

cependant avoir des matrices de données, à savoir le nombre d'incidents par période et par localisation, très denses afin d'obtenir des résultats fiables.

2.1.4.3 Evaluation des méthodes de prévision

La diversité des approches présentées dans la littérature, allant des modèles classiques aux techniques de *machine learning*, implique de devoir choisir le modèle le plus adapté. Cette sélection ne se limite pas à la performance des méthodes, mais s'appuie également sur plusieurs niveaux d'analyse et de critères méthodologiques.

Le premier critère de sélection concerne l'adéquation entre le type de modèle et la nature des données (Zheng et Liu, 2009). Si les données sont linéaires, peu volumineuses et bien structurées, les méthodes classiques peuvent suffire. Pour des données non linéaires, massives, bruitées ou hétérogènes, les méthodes d'intelligence artificielle (comme les réseaux de neurones ou les forêts aléatoires) sont plus appropriées. Ce niveau de sélection implique une analyse approfondie des données. Il faut entre autres étudier la saisonnalité, la tendance, le caractère erratique et intermittent des données, la variabilité spatio-temporelle, la présence de valeurs manquantes ou aberrantes (Syntetos et al., 2005).

Le deuxième niveau de sélection repose sur l'évaluation statistique de la performance prédictive (Zheng et Liu, 2009). Plusieurs indicateurs sont utilisés afin de comparer les modèles :

- MAPE (*Mean Absolute Percentage Error*) : exprime l'erreur moyenne en pourcentage par rapport aux valeurs observées. Il est particulièrement utile pour comparer des performances sur des échelles différentes.

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{A_i - F_i}{A_i} \right| \quad (2.3)$$

- MSE (*Mean Squared Error*) : calcule la moyenne des carrés des erreurs. Il pénalise fortement les grandes erreurs, ce qui en fait un bon indicateur lorsqu'on cherche favoriser une faible erreur constante plutôt qu'une ou plusieurs fortes erreurs.

$$MSE = \frac{1}{n} \sum_{i=1}^n (A_i - F_i)^2 \quad (2.4)$$

- MAD (*Mean Absolute Deviation*) : mesure l'écart absolu moyen, offrant une mesure plus robuste en cas de présence de valeurs aberrantes.

$$MAD = \frac{1}{n} \sum_{i=1}^n |A_i - F_i| \quad (2.5)$$

Avec :

- n : Nombre total d'observations
- A_i : Valeur réelle observée au temps i
- F_i : Valeur prévisionnelle au temps i

Le troisième niveau porte sur l'évaluation informationnelle du modèle. Cela traduit la capacité d'un modèle à être équilibré entre la complexité et la performance. Le recours à de telles métriques permet d'éviter le sur-apprentissage des modèles de prévisions. Zheng et Liu (2009) présentent deux indicateurs régulièrement utilisés :

- AIC (*Akaike Information Criteria*) : mesure la qualité d'un modèle en pénalisant les modèles complexes. Un AIC plus faible indique un meilleur compromis entre précision et simplicité.
- SIC (*Schwarz Information Criteria*) : similaire à l'AIC mais avec une pénalisation plus forte pour les modèles complexes.

2.2 Les travaux sur les stratégies d'affectation et le dimensionnement de flotte de véhicules

Dans cette section nous aborderons les méthodes d'amélioration de la performance des flottes de véhicules de service dans le cadre de leur dimensionnement. En effet, faute de références portant précisément sur notre cas d'étude, à savoir une flotte de véhicules électriques de services, nous avons fait le choix d'analyser des flottes de véhicules intervenant de manière similaire, tels que les véhicules d'urgence (pompiers, ambulances, dépanneuses, etc).

2.2.1 Stratégie de recherche bibliographique

Comme précédemment, la recherche bibliographique a été menée à partir d'un plan de concepts. Ce dernier est présenté dans le tableau 2.

Tableau 2.2 Concepts et mots clés relatifs aux stratégies d'affectation et au dimensionnement utilisés pour notre revue de littérature

Concept 1	Concept 2	Concept 3
Fleet siz*	Incident	Maintenance
Affectation rule	Accident	Emergency
Assignment rule	Demand	Public Transports
Dispatch*	Intervention	Public Commuting
		Firefight*
		Medical
		Police
		Tow*
		Electric

A partir du plan de concept nous obtenons l'équation de recherche suivante : ((« Fleet siz* » OR « Affectation rule » OR « Assignment rule » OR « Dispatch* ») AND (« Incident » OR

« Accident » OR « Demand » OR « Intervention ») AND (« Maintenance » OR « Emergency » OR « Public Transport » OR « Public Commuting » OR « Firefight* » OR « Medical » OR « Police » OR « Tow* » OR « *Electric** »)).

Cette dernière a été réalisée sur Google Scholar et ScienceDirect. Elle nous a permis d'obtenir des articles précisément sur le sujet. Cependant une recherche sans le concept 3 a permis d'élargir les recherches et de comprendre les méthodes mises en place dans d'autres domaines, tels que la livraison de colis.

2.2.2 Stratégies d'affectation et méthodes de dimensionnement de flotte

À notre connaissance, le problème de dimensionnement de flotte et de répartition des véhicules n'a pas encore été abordées dans le contexte des véhicules électriques en vue de maintenir un système de transport en conditions opérationnelles. L'objectif étant de tester différentes stratégies d'affectation et de déterminer pour chacune d'entre elles le nombre de véhicules optimal. Toutefois, des problématiques similaires ont été étudiées dans d'autres domaines d'application tels que les véhicules d'urgence, de lutte contre les incendies ou de police. Dans ces travaux, la modélisation couramment utilisée est le « *mixed-integer linear programming* (MILP) ». En effet, Bélanger et al. (2019) proposent un modèle d'optimisation pour l'affectation des véhicules médicaux d'urgence. Dans cette étude, les auteurs montrent comment un modèle d'optimisation peut améliorer la prise de décision lors du choix des stratégies d'affectation et du dimensionnement d'une flotte, tout en soulignant les limites de l'approche déterministe, et recommandent d'adopter des approches dynamiques et stochastiques pour considérer la variabilité des problèmes réels. En effet, les approches dynamiques permettent d'ajuster les solutions en prenant en compte des changements de demande ou de disponibilité de ressources. De plus, l'utilisation de modèles stochastiques permet de prendre en compte l'incertitude de certaines données telles que les temps d'interventions ou leurs positions ainsi que les temps de trajet, etc.

Luzon et al. (2023) ont proposé un MILP visant à déterminer la taille optimale d'une flotte de véhicules d'urgence pour la lutte contre les incendies. Les auteurs obtiennent de bons résultats, ce qui s'explique par le fait que les véhicules d'urgence sont moins sensibles aux conditions de circulation, ces derniers ayant la priorité sur la route, le temps de trajet de ces derniers est prévisible. Leur modèle d'optimisation s'appuie sur la théorie des files d'attente. De la même manière, sur le même sujet que le notre, à savoir le dimensionnement d'une flotte de véhicules de service électriques pour les CO à la STM, Ben Messabih et al. (2025), proposent un MILP permettant de minimiser le nombre de véhicules utilisés. Ce modèle présente de bons résultats pour de petites instances, cependant le temps computationnel requis pour résoudre de plus grandes instances (cas réel) rend la résolution du problème impossible.

Les approches d'optimisation peuvent également se montrer utiles au niveau opérationnel, en proposant une affectation des ressources dynamique. En effet, Haghani et Yang (2007) insistent sur l'importance de considérer les données de manière dynamique (trafic, disponibilité des véhicules, urgences simultanées) pour améliorer la gestion des interventions. Leur modèle combine l'optimisation avec une gestion dynamique considérant des flux d'informations continus. En effet, contrairement à des modèles d'optimisation tels que des MILP, n'utilisant qu'un nombre fixe d'interventions, l'ajout en continu d'opérations à réaliser permet d'utiliser les modèles d'optimisation à un niveau opérationnel, améliorant par conséquent la gestion de l'ensemble des opérations. Dans la même logique, Polyviou (2011) développe un modèle de simulation orienté vers la gestion dynamique des flottes de bus en contexte urbain. Il s'intéresse à l'impact des incidents de circulation sur la ponctualité et la continuité du service. Son modèle permet d'évaluer en temps réel des options de redéploiement, afin de limiter les effets de propagation des retards et d'améliorer la robustesse du réseau de transport.

Cependant, bien que les MILP se montrent particulièrement performant sur certains problèmes, ils présentent un inconvénient lié à la complexité algorithmique lors de la résolution, qui dépend de la taille du problème. En effet, la taille des problèmes qui peuvent être résolus est souvent faible. Ainsi des méthodes telles que les heuristiques et méta-heuristiques à la complexité plus faible permettent de trouver de bonnes solutions dans des temps plus

raisonnables pour des problèmes réels. Comme notre problème a de nombreuses caractéristiques propres au fonctionnement de la STM, il n'y a pas de modèle existant dans la littérature pour y apporter une solution. Cependant les problèmes de tournée de véhicules (VRP « *Vehicle Routing Problem* ») ont beaucoup été étudiés par les chercheurs opérationnels. Et en particulier les problèmes de VRP avec TW « *Time Window* ». Une comparaison peut être faite entre les problèmes de VRPTW et le problème d'affectation de véhicules de service, où les livraisons sont dans notre cas des interventions.

Les heuristiques visent à générer rapidement une solution initiale, en construisant les tournées client par client. Parmi les approches les plus simples, l'algorithme du plus proche voisin (Rosenkrantz et al., 1977) est souvent utilisé comme point de départ. Il consiste à construire une tournée partant du dépôt, en visitant à chaque étape le client le plus proche qui permet de garder la solution réalisable, c'est-à-dire le client non encore visité qui minimise la distance (ou un coût tenant compte des contraintes temporelles, économique ou autre). Bien que cette méthode génère souvent des solutions sous-optimales voire de mauvaise qualité, sa rapidité en fait un outil de construction utile, notamment pour fournir des solutions initiales à des méta-heuristiques. L'algorithme de Savings proposé par Clarke et Wright en 1964 constitue également une référence historique. Il repose sur un critère d'économie de coût pour fusionner progressivement des tournées. Cette méthode a été adaptée pour gérer les contraintes temporelles à travers différentes variantes (Solomon, 1987). Solomon (1987) a également proposé d'autres heuristiques spécifiques pour le VRPTW, qui restent des références importantes dans la littérature. Ces approches comprennent des algorithmes d'insertion séquentielle, qui insèrent les clients un par un au meilleur emplacement, selon des règles telles que l'insertion la plus proche, l'insertion la moins coûteuse, ou encore l'insertion basée sur le regret (regret insertion). L'insertion basée sur le regret favorise l'insertion dans la tournée de demandes, pas nécessairement les moins coûteuses, mais présentant le plus grand regret, si elles ne sont pas traitées rapidement. Ces méthodes tiennent compte explicitement des fenêtres temporelles lors de la construction des tournées. D'autres approches géométriques, comme l'algorithme de balayage (Gillett et Miller, 1974), permettent d'ordonner les clients en fonction de leur angle polaire par rapport au dépôt, avant de construire les tournées. Le balayage de

chemin (*Path Scanning*) constitue une variante qui intègre directement les contraintes temporelles dans le processus de balayage.

Les heuristiques de construction sont généralement suivies d'une phase d'amélioration basée sur des heuristiques de recherche locale ou des méta-heuristiques plus sophistiquées permettant d'améliorer les solutions trouvées initialement. Les méthodes de recherche locale classiques telles que le 2-opt et le 3-opt (Lin, 1965) permettent de réorganiser les arcs des tournées pour réduire la distance totale ou améliorer le respect des fenêtres temporelles. Des mouvements inter-tournées, tels que la relocation, l'échange ou le cross-exchange, sont également très efficaces pour optimiser les solutions. Parmi les méta-heuristiques, la recherche Tabou (*Tabu Search*) (Glover, 1989) a montré d'excellentes performances sur le VRP. Taillard et al. (1997) ont proposé une variante adaptée aux contraintes de temps, intégrant des stratégies de mémoire afin d'éviter des cycles et d'améliorer les performances de leur méthode. Les algorithmes génétiques (Holland, 1975), combinant sélection, croisement et mutation, ont également été largement appliqués au VRPTW. Une difficulté spécifique de ces approches réside dans le maintien de la faisabilité temporelle après l'application des opérateurs. Enfin, d'autres approches sont inspirées de la nature, telles que l'optimisation par colonie de fourmis (Ant Colony Optimization) (Dorigo et Gambardella, 1997), ces méthodes exploitent des mécanismes d'émergence et de stigmergie via une mémoire collective pour orienter la recherche vers les meilleures solutions ou des régions prometteuses. Cette dernière a été adaptée au problème de tournée de véhicules électriques avec fenêtres temporelles (Electric-VRPTW) par Mavrovouniotis et al. (2022). Le recuit simulé (Simulated Annealing) (Kirkpatrick et al., 1983) constitue une autre alternative intéressante, en permettant d'échapper aux minima locaux par un mécanisme de refroidissement stochastique. Cette méta-heuristique est inspirée du processus de recuit métallurgique et l'algorithme explore d'abord l'espace des solutions avec une température élevée, ce qui lui permet d'accepter non seulement des améliorations, mais aussi, avec une certaine probabilité, des dégradations de la fonction objectif. Au fur et à mesure que la température décroît selon une loi de refroidissement prédéfinie (linéaire, géométrique, logarithmique, etc.), cette probabilité diminue

progressivement, ce qui favorise la convergence vers une solution de plus en plus stable et proche de l'optimum global.

Cependant, les méthodes présentées jusqu'alors sont déterministes ce qui ne permet pas d'adresser des problèmes stochastiques. A l'inverse, la simulation permet de modéliser le comportement d'un système complexe, en tenant compte de multiples sources d'aléas (temps de réponse, disponibilité des unités, embouteillages, etc.). Contrairement aux modèles déterministes, elle offre une grande souplesse de modélisation et permet d'analyser le fonctionnement du système dans une variété de scénarios. En effet, la simulation à événement discret permet de rapidement et facilement comparer des stratégies dans le cadre de choix de stratégies et du dimensionnement d'une flotte de véhicules. Toutefois, les outils de simulations ne permettent pas de prouver la qualité de la solution.

Carter et Ignall (1970) sont parmi les premiers à proposer un modèle de simulation pour les services d'incendie, intégrant la gestion des appels, la disponibilité des camions, et les temps de trajet. Leur modèle permet d'évaluer différents schémas de déploiement des véhicules en fonction des contraintes géographiques et temporelles. Cette approche reste pertinente aujourd'hui, notamment pour simuler les interactions entre plusieurs événements simultanés, et évaluer la résilience du système face à des pics d'activité.

Dans un contexte différent, Malan (2017) utilise la simulation à événement discret pour la gestion d'une flotte de tracteurs dans une mine souterraine. Son approche permet d'analyser différentes configurations de flotte et d'identifier les goulets d'étranglement dans le cycle de production. La simulation sert ici d'outil de validation opérationnelle des solutions. Cette étude identifie des configurations permettant d'améliorer les coûts et l'efficacité opérationnelle, en développant un outil d'aide à la décision dans un environnement réaliste et complexe.

Haghani et Yang (2007) montrent que la simulation est souvent utilisée en complément des modèles d'optimisation, notamment pour valider les solutions optimales dans un contexte réaliste avec prise en compte d'aléas et simuler des processus décisionnels dynamiques (ex.

dispatching adaptatif) et des règles heuristiques. Cette approche hybride permet de combiner la puissance théorique de l'optimisation avec la flexibilité expérimentale de la simulation, et s'avère particulièrement pertinente dans les environnements incertains et critiques.

2.3 Conclusion

Grâce à cette revue de la littérature, nous avons pu présenter les travaux les plus intéressants concernant notre problème de dimensionnement de flotte de véhicule, allant, de la prévision des demandes futures aux stratégies d'affectation des véhicules aux interventions. En effet, dû à la spécificité du problème que nous étudions, nous devons faire des analogies avec d'autres domaines. Contrairement aux documents étudiés, qui basent principalement leurs études sur des données historiques, nous proposons de réaliser notre étude sur les stratégies d'affectation des véhicules aux interventions à partir de prévisions basées sur les données historiques. De plus, les modèles développés retranscriront au mieux la réalité, en prenant en compte le plus possible les spécificités du problème.

Nous allons résoudre ce problème en proposant une approche permettant de dimensionner une flotte de véhicules de service électriques combinant le traitement des données pour prévoir le nombre d'interventions futures, un modèle de simulation afin d'évaluer de nouvelles stratégies d'affectation des véhicules aux interventions et de dimensionner la flotte de véhicules de service (contexte stochastique), et enfin des heuristiques permettant de construire des routes et dimensionner la flotte dans un contexte déterministe.

CHAPITRE 3

METHODOLOGIE

Dans cette section nous présenterons la méthodologie mise en place pour construire notre outil d'aide à la décision. Pour ce faire, dans une première partie nous aborderons la collecte des données qui nous permettront de réaliser les prévisions des interventions futures, puis nous présenterons le modèle de simulation, qui nous a permis d'évaluer d'une part plusieurs scénarios, en fonction de différents volumes d'interventions et d'autre part de comparer différentes stratégies de dispatching. Enfin, nous avons adapté plusieurs heuristiques en considérant cette fois-ci la version déterministe du problème c'est-à-dire que les demandes d'interventions sont considérées comme étant connues à l'avance. Cette étude déterministe nous a, entre autres, permis de déterminer les horaires idéaux des quarts de travail des CO.

3.1 Collecte des données

La prévision des incidents est un enjeu majeur dans l'industrie. Dans notre cas, les prévisions portent sur les incidents sur le réseau routier, impactant les bus du réseau. L'intérêt de la prévision dans notre cas est de pouvoir par la suite dimensionner correctement notre flotte de véhicule de service, afin que les incidents engendrent le moins de retards pour l'ensemble des usagers, permettant ainsi de conserver un taux de service élevé. Ainsi, les prévisions des incidents sont nécessaires et se déroulent en deux grandes étapes. La première étant la récolte des données utiles et le développement de méthodes adaptées (Li et al., 2018).

3.1.1 Source des données

Différentes sources de données ont été mises à disposition par la STM. Parmi ces dernières, on retrouve celles liées à la pré-affectation des CO à leur quart de travail. Celles-ci sont disponibles via un fichier Excel qui permet de recenser l'ensemble des quarts de travail des huit CT. Il définit quel quart de travail est assigné à quel secteur, à quel CO, et enfin à quel véhicule. Un exemple de ce plan de pré-affectation est présenté dans la figure 3.1. Par exemple,

le quart de travail 5002, correspond au quart de travail allant de 6h à 12h, utilisant le véhicule 119-1002, affecté au CT 50, à savoir le CT Stinson.




Figure 3.1 Grille horaire prévisionnelle de la pré-affectation des véhicules aux quarts de travail

De plus, les données des interventions du COP sont enregistrées grâce au logiciel de gestion Logic 2.0. Au cours de chaque intervention, les CO, doivent compléter le suivi sur le logiciel, à savoir, indiquer les étapes importantes, telles que l’heure de fin de l’intervention. Ce suivi est réalisé afin d’obtenir la base de données compilant l’ensemble des interventions. Cependant ce processus n’a pu être implémenté qu’en 2020. Ainsi, toutes les données antérieures à l’année 2020, date de changement de process, ne traduisent pas la même réalité. Par conséquent, elles ne sont pas utilisables dans le cadre de notre étude. En effet, comme on peut le constater sur la figure 3.2, le nombre total d’interventions par an ne s’est stabilisé qu’à partir de l’année 2020. Par ailleurs, bien que cette base de données nous fournisse des données essentielles, elle ne couvre pas l’ensemble des interventions réalisées par les CO. Cette dernière ne recense que les interventions pilotées par le COP. En effet, le COP n’est pas le seul acteur pouvant demander aux CO de réaliser une intervention. Le gestionnaire des CO planifie également des interventions. L’historique de ces dernières est compilé dans une autre base de données.




Figure 3.2 Graphique du nombre total d'interventions par année

3.1.2 Structure des données

La première base de données que nous avons utilisée est celle provenant de Logic 2.0, à savoir celle du COP. Cette base de données liste l'ensemble des interventions prises en charge par le COP. Cette base de données est structurée avec les informations suivantes :

- Numéro de l'intervention ;
- Heure de début de l'intervention ;
- Heure de fin de l'intervention ;
- Lieu de l'intervention ;
- Description ;
- Numéro du véhicule ;
- Centre de transport du véhicule ;
- Description du type d'évènement ;
- Description de la catégorie de l'intervention.

Le numéro de l'intervention est l'identifiant unique assigné par Logic 2.0 à une intervention. Ceci permet de croiser des bases de données entre elles. L'heure de début de l'intervention est l'heure à laquelle le CO est contacté, afin qu'il se rende sur le lieu de l'intervention. L'heure de fin de l'intervention est l'heure à laquelle le CO finit l'intervention. Le lieu de l'intervention est indiqué par un croisement de rues et non par des coordonnées longitude et latitude. La description de l'évènement permet de décrire succinctement la raison de l'intervention. Le numéro du véhicule permet d'identifier le véhicule qui a pris en charge l'intervention correspondante.

De même pour le CT, l'information est stockée sous forme d'identifiant, avec pour correspondance une région de Montréal, par exemple, 50000 correspond à Stinson ; 54000 à Anjou et 55000 à Saint-Denis.

La description du type d'évènement est toujours indiquée par le message « intervention CO ». De même pour la description de la catégorie, la colonne correspond toujours au message « défectuosité véhicule », même pour les incidents voyageurs et autre. Ces colonnes, pourraient présenter des informations importantes pour notre étude, cependant, elles ne sont aujourd'hui pas pertinentes. Nous avons donc fait le choix de ne pas les utiliser.

La deuxième base de données est celle du gestionnaire des CO. Elle recense les interventions demandées par le gestionnaire mais également une partie de celle demandées par le COP. Cependant, cette base de données fournit moins d'informations que la précédente. En effet, la localisation de l'intervention, ainsi que son heure de fin n'y sont pas mentionnées. De plus, la clé d'identification de l'intervention ne suit pas la même codification que Logic 2.0. Ainsi, il nous a été impossible de croiser les deux bases de données. Le choix a donc été fait de travailler avec la première base de données et de proposer un passage à l'échelle grâce au modèle de simulation pour remédier au potentiel manque de données.

3.1.3 Localisation des demandes d'interventions

Dans la première base de données utilisée dans notre étude, comme expliqué précédemment, le lieu de l'intervention n'est donné que par un croisement de rues. Cette donnée n'est pas utilisable en l'état. Ainsi, un traitement avancé des données a été réalisé et l'implémentation des programmes qui permettent de réaliser ce traitement est fait à l'aide de Python et de la bibliothèque *geopy*. Au sein de cette bibliothèque la fonction *geocode* permet de faire correspondre à une adresse, un nom de magasin, un croisement de rue, etc., une position géographique donnée en coordonnées. A noter qu'un filtre a été codé, permettant de ne renvoyer que des positions GPS d'adresses présentes sur l'île de Montréal. En effet, le risque étant qu'une autre ville possède des rues portant le même nom, ce qui renverrait de fausses positions GPS.

Ainsi après un traitement avancé des données disponibles, les informations pertinentes que nous avons retenues sont les suivantes :

- Numéro de l'intervention ;
- Heure de début de l'intervention ;
- Heure de fin de l'intervention ;
- Lieu de l'intervention ;
- Latitude ;
- Longitude ;
- Numéro du véhicule ;
- Centre de transport du véhicule.

3.1.4 Sectorisation des interventions

Dans cette section, nous proposons une méthode pour construire des matrices de demandes d'interventions, à savoir le nombre d'interventions par tranche horaire et par secteur. En effet, afin d'étudier les demandes d'interventions par secteur, il nous est nécessaire de créer un filtre pour chaque intervention permettant de déterminer à quel secteur appartient cette dernière.

Pour ce faire, à l'aide du logiciel *Google Earth*, nous avons géocodé les secteurs, sous forme de polygones, tels qu'indiqués dans la figure 3.3.




Figure 3.3 Capture d'écran du logiciel Google Earth, avec la sectorisation de l'île de Montréal

Une fois ces polygones construits, nous les avons importés sur le logiciel QGIS, qui est un système d'information géographique. Nous avons également importé dans ce logiciel l'ensemble des interventions. Cette carte est présentée dans la figure 3.4. Nous avons alors réalisé une intersection entre chaque secteur et l'ensemble des interventions, afin d'obtenir pour chaque intervention le secteur auquel elle est rattachée.




Figure 3.4 Capture d'écran du logiciel QGIS, représentant l'ensemble des interventions sur 4 années

Enfin, à l'aide d'un programme informatique codé en langage python, nous avons agrégé les données en considérant plusieurs granularités temporelles, dans l'optique de développer des modèles de prévisions des demandes d'intervention. En effet, nous avons évalué plusieurs granularités afin d'analyser le profil des demandes, entre autres, en considérant la saisonnalité, la tendance mais également les métriques ADI et CV^2 présentées précédemment. Ces deux dernières métriques permettent, pour la première de quantifier le nombre de périodes sans interventions entre deux périodes avec interventions et la deuxième la variation de la quantité d'interventions par période. Plus exactement, nous avons analysé les granularités temporelles par mois, par jour et par intervalle d'heures (6 heures, 4 heures, 3 heures, 2 heures et 1 heure).

Nous avons alors construit des matrices de demandes pour chaque granularité temporelle résumant l'activité historique avec pour chaque tranche horaire le nombre d'interventions constatées.

3.2 Développement des modèles de prévisions des demandes d'interventions

3.2.1 Analyse des données

A partir des sources de données retenues dans le chapitre présentant le cas d'étude, nous avons analysé ces dernières afin de développer des méthodes de prévisions des demandes d'interventions. Pour ce faire, nous nous sommes intéressés à la saisonnalité et à la tendance en considérant plusieurs granularités temporelles. Cette étude est menée sur un historique de 4 années, comme expliqué précédemment. En effet, cette question doit répondre à un compromis entre précision souhaitée et volume de données à gérer. Autrement dit, si le niveau de granularité est gros on risque de perdre de l'information. A l'opposé, si le niveau de granularité est très fin, on retombe sur de très faibles volumes d'interventions ce qui devient très difficile à prédire. Étant donné que notre étude a pour but de s'intéresser aux règles d'affectation des véhicules aux interventions, nous devons déterminer le juste compromis pour la granularité temporelle à considérer par la suite. Ainsi, nous avons évalué les durées de périodes suivantes en étudiant la saisonnalité et la tendance :

- Mois
- Journée
- 6 heures
- 4 heures
- 3 heures
- 2 heures
- 1 heure

L'analyse des données permet d'identifier la présence d'une saisonnalité au sein des données. Le profil de la demande présente trois niveaux de saisonnalité : au mois (figure 3.5), à la

journée (figure 3.6) et à l'heure (figure 3.7). De plus, on observe une tendance à la baisse, bien que le nombre de bus en service soit en augmentation depuis 2020. On remarque, que l'hiver et l'été présentent en moyenne une plus forte demande, comparée à l'automne et au printemps. De même, la demande est plus faible en fin de semaine. Enfin, il y a des pics de demande aux heures de pointe, là où, la demande observée est très faible la nuit.




Figure 3.5 Nombre d'interventions total sur par mois par secteur cumulé sur 4 années




Figure 3.6 Nombre d'interventions total sur 4 ans par jour par secteur cumulé sur 4 années




Figure 3.7 Nombre d'interventions total sur 4 ans par heure par secteur cumulé sur 4 années

3.2.2 Les modèles de prévision des demandes d'interventions

Nous avons d'abord fait le choix d'adapter les modèles basés sur les séries temporelles avec des agrégations allant de 1h à 6h, pour chaque secteur. Ce choix-ci, a été fait, comme expliqué précédemment, pour garder un maximum d'informations sur la répartition des interventions. Notre revue de la littérature nous a permis de sélectionner les modèles suivants : la régression linéaire avec facteurs de saisonnalité, le double lissage exponentiel (*Holt*) avec facteurs de saisonnalité et le triple lissage exponentiel (*Holt-Winters*).

Cependant, la distribution de la demande étant trop intermittente et trop variable, à ces niveaux d'agrégation, elle peut être qualifiée de grumeleuse, à l'aide de la classification ADI/CV² (Syntetos et Boylan, 2005). En effet, nous avons obtenu pour chaque secteur et pour chaque agrégation proposée un ADI > 1,32 et un CV² > 0,49. Par exemple pour une agrégation à l'heure pour le secteur 1, nous obtenons ADI = 2,51 et CV² = 2,57. Ainsi, aucune de ces méthodes ne nous a permis d'obtenir des prévisions précises. L'analyse des données à l'échelle de l'heure, par secteur, n'a donc pas été traitée. En revanche, l'échelle de la journée est plus raisonnable car elle permet de densifier la série temporelle. Pour autant, l'évaluation du nombre d'interventions à l'heure sera reprise a posteriori dans le modèle de simulation. À l'aide des répartitions historiques, des prévisions horaires seront réalisées dans le modèle de simulation.

De même, la spatialisation des interventions ne sera prise en compte que dans le modèle de simulation à évènement discret. Et les prévisions seront réalisées pour l'ensemble de l'île de Montréal.

Ainsi, les prévisions ont été réalisées avec plusieurs granularités, et en agrégeant l'ensemble des secteurs de l'île de Montréal. Les méthodes de prévision choisies sont la régression linéaire avec facteurs de saisonnalité, le double lissage exponentiel (*Holt*) avec facteurs de saisonnalité et le triple lissage exponentiel (*Holt-Winters*) (Nahmias et Olsen, 2015). Ce travail sur les données nous a ainsi permis de ne plus avoir un profil de demande d'interventions grumeleux. Et donc d'obtenir de meilleures prévisions. En effet, nous avons obtenu un ADI de 1 et un CV² de 0,19.

a. La méthode de la régression linéaire avec facteurs de saisonnalité :

Cette méthode est réalisée en 3 phases. La première est de désaisonnaliser la série temporelle présentant les demandes d'intervention des 4 années considérées, à partir des facteurs de saisonnalité. Ces derniers sont obtenus en divisant la valeur observée par la moyenne. Ces résultats sont alors normalisés. La deuxième phase est d'appliquer la méthode de prévisions, à savoir la régression linéaire. Parmi les modèles de régression linéaire, l'ajustement affine est le plus simple. Il vise à déterminer la droite qui décrit le mieux la relation entre deux variables statistiques, en modélisant la variable y , ici le nombre d'interventions à venir, comme une fonction affine de la variable t , ici le nombre d'interventions par jour enregistrés. Enfin, une fois la régression linéaire utilisée et les prévisions calculées, on resaisonnalise les prévisions.

- y_t Nombre d'interventions du jour t
- α Coefficient directeur de la droite (pente)
- β Ordonnée à l'origine

L'équation finale s'écrit :

$$y_t = \alpha \cdot t + \beta \tag{3.1}$$

b. La méthode de *Holt* :

Comme précédemment, la série est dans un premier temps désaisonnalisée. Ensuite, on applique la méthode de Holt, qui est une extension du lissage exponentiel simple, conçue pour les séries temporelles présentant une tendance. Elle repose sur deux composantes : le niveau (il repose sur une moyenne pondérée) et la tendance, qui sont lissés de manière exponentielle et mis à jour à chaque période. Enfin, on resaisonnalise les prévisions réalisées.

Paramètres :

- L_t Niveau lissé à l'instant t
- T_t Tendance lissée à l'instant t
- α Paramètre de lissage pour le niveau ($0 < \alpha \leq 1$)
- β Paramètre de lissage pour la tendance ($0 < \beta \leq 1$)
- h Nombre de période futures à prédire

Les prévisions s'appuient sur les deux équations suivantes :

Niveau (L_t) :

$$L_t = \alpha \cdot y_t + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (3.2)$$

Tendance (T_t) :

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (3.3)$$

Prévision pour h périodes dans le futur (y_{t+h}) :

$$y_{t+h} = L_t + h \cdot T_t \quad (3.4)$$

Fonctionnement :

Le lissage de niveaux permet d'ajuster la valeur actuelle de la série en fonction de la tendance estimée. Le lissage de la tendance permet la capture de la vitesse de changement dans la série

temporelle. Ces deux composantes permettent une prévision adaptative, particulièrement utile lorsque la série suit une tendance linéaire.

c. La méthode de *Holt- Winters* :

La méthode de Holt-Winters est une extension de la méthode de Holt qui inclut une composante saisonnière en plus des composantes de niveau et de tendance. Elle est adaptée aux séries temporelles présentant des variations saisonnières régulières (Nahmias et Olsen, 2015).

Les équations de Holt-Winters se déclinent selon la nature de la saisonnalité : additive (si l'amplitude de la saisonnalité reste constante) ou multiplicative (si l'amplitude varie proportionnellement au niveau de la série). Dans notre cas, le niveau moyen de la demande reste à peu près constant, nous avons donc choisi d'utiliser la méthode additive (Koelher et al., 2001).

Voici les paramètres de cette méthode :

- γ Paramètre de lissage pour la saisonnalité
- s Longueur d'un cycle de saisonnalité (ex. 12 pour des données mensuelles avec saisonnalité mensuelle)
- k Nombre de cycles future à prédire

Voici les composantes de la méthode additive :

Niveau (L_t) :

$$L_t = \alpha(y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (3.5)$$

Tendance (T_t) :

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (3.6)$$

Saisonnalité (S_t) :

$$S_t = \gamma(y_t - L_t) + (1 - \gamma)S_{t-s} \quad (3.7)$$

Prévision pour h périodes dans le futur :

$$y_{t+h} = L_t + h.T_t + S_{t+h-s(k)} \quad (3.8)$$

Avec :

$$k = \left\lfloor \frac{h-1}{s} \right\rfloor \quad (3.9)$$

3.3 Un cadre générique de modélisation basé sur la simulation à évènement discret

Comme mentionné précédemment, nous avons proposé un cadre générique de modélisation par simulation pour les problèmes de dimensionnement et d'affectation d'une flotte de véhicules électriques. Ce choix se justifie par la nécessité de prendre en compte le comportement dynamique de la demande d'interventions. En effet, la modélisation par simulation à évènement discret est particulièrement bien adaptée pour représenter les fluctuations importantes de la demande d'interventions, qui varient à la fois dans le temps et dans l'espace. Cette partie du mémoire a fait l'objet d'un article de conférence internationale (Jezequel et al., 2025).

3.3.1 Hypothèses et indicateurs de performance

3.3.1.1 Hypothèses

Afin de développer un modèle de simulation le plus fidèle possible au comportement de la flotte de la STM, les hypothèses suivantes ont été formulées :

Chaque véhicule est affecté à un CT, et possède un ou plusieurs quarts de travail, suivant le document de pré-affectation des véhicules utilisé au printemps 2024. De plus, chaque secteur est pré-affecté à un ou plusieurs CT. En outre, nous avons intégré au modèle de simulation l'ensemble des règles opérationnelles définissant les opérations des COs. Par exemple, un véhicule assigné à un secteur s'y déplace en début de quart de travail, puis se rend sur le lieu

d'une intervention. Une fois cette dernière finie, il reste dans les alentours avant d'être appelé pour une nouvelle intervention.

Les distances parcourues par les CO, d'un lieu à un autre sont des distances euclidiennes, c'est-à-dire que nous ne considérons pas les itinéraires réels sur la carte. Toutefois, nous proposons d'appliquer un coefficient de correction pour réduire l'écart entre la distance euclidienne et la distance réelle. En effet, nous avons comparé pour plusieurs trajets le temps de trajet réel au temps calculé par notre modèle. Nous avons à partir de ces données obtenu un coefficient rectificatif.

En raison d'un manque de données, il a été impossible de mettre en œuvre une priorisation entre les interventions. Par conséquent, la première intervention à apparaître est la première à se voir attribuer un véhicule (règle FIFO).

À partir des données du logiciel Logic 2.0 (voir section 3.1.2), nous avons pu obtenir la durée pour chaque intervention entre le début et la fin de l'intervention. Ainsi, la durée des interventions a pu être représentée sur un histogramme présenté dans la figure 3.8, qui permet d'observer la répartition des durées d'interventions. Ce dernier présente le nombre d'interventions observées, sur 4 ans, par tranche de temps de 10 minutes. Nous avons ainsi déterminé à l'aide de l'outil *input analyzer* intégré au logiciel Arena, que la durée des interventions suivait une loi de Poisson, avec une moyenne déterminée lors de l'analyse des données, à 30 minutes.




Figure 3.8 Histogramme de la durée des interventions par tranche de 10 mins

3.3.1.2 Indicateurs de performance

Avant le début de ce projet, la STM n'avait pas encore défini des indicateurs de performance concernant la gestion des interventions par sa flotte de véhicules de service. C'est pourquoi, en collaboration avec trois gestionnaires de la STM, nous avons défini cinq indicateurs et fixé une cible pour chacun d'eux, comme présenté dans le tableau 3.1. Nous proposons d'utiliser ces indicateurs pour évaluer les différentes stratégies de dispatching des véhicules. De plus il est important de noter que ces indicateurs n'ont pas le même ordre d'importance. Ainsi, nous les présentons du plus important au moins important, conformément aux priorités définies par nos interlocuteurs de l'entreprise.

Tableau 3.1 Tableau décrivant les indicateurs et leurs cibles

Indicateur	Description	Cibles
Taille de la flotte	Nombre de véhicules utilisés pour les interventions	< 30
Taux moyen d'utilisation de la flotte (UR)	Pourcentage du temps d'utilisation des véhicules pour des interventions au cours d'une journée	> 70 %
Temps moyen d'attente	Somme du temps de réponse et du temps de déplacement	< 35 minutes
Distance moyenne quotidienne parcourue moyenne totale	Distance moyenne parcourue quotidiennement par chaque véhicule	≤ 150 km

3.3.2 Le modèle de simulation

Le modèle de simulation proposé peut être divisé en quatre étapes successives, comme illustré dans la figure 3.9 présentée ci-dessous.



Figure 3.9 Représentation macro du fonctionnement du modèle de simulation

La première étape consiste en la génération de la demande d'interventions, qui dépend à la fois du temps et de l'espace. La deuxième étape correspond à la définition d'une stratégie de *dispatching* des véhicules, c'est-à-dire la règle de décision utilisée pour assigner les véhicules aux interventions. Enfin, la troisième étape est la modélisation du processus décrivant le

comportement des véhicules. Plus précisément, on modélise l'ensemble des étapes réalisées par les véhicules une fois affectés, telles que les déplacements et l'exécution des tâches requises. La dernière étape est l'évaluation des indicateurs de performance au vu des résultats générés.

Concernant la première étape, nous avons défini une répartition spatiale et temporelle des interventions à partir des données historiques. Ainsi, nous obtenons un nombre d'interventions par période temporelle (par heure) et par secteur. Cette répartition dépend du jour de la semaine. Ce processus se déroule en deux phases successives. D'abord, on définit la distribution temporelle ce qui permet de générer le nombre d'intervention selon l'heure de la journée en semaine. Dans notre cas nous avons modélisé un jour de semaine typique (pas les jours de fin de semaine car la demande est plus basse). Ensuite, la localisation des interventions est obtenue à l'aide de la répartition historique en fonction de l'heure du temps (heure, jour de la semaine et mois). On assigne alors chaque intervention à un secteur, et par la suite, une adresse est choisie aléatoirement à partir des données de ce secteur.

La vitesse des véhicules est obtenue à l'aide d'une étude de données de la ville de Montréal. En effet cette vitesse dépend de l'heure de départ du véhicule, et du jour de l'intervention. En effet, en se basant sur des données de la ville de Montréal, (Ville de Montréal, 2023), nous avons pu obtenir la vitesse sur des tronçons de route en fonction de l'heure de départ. L'acquisition des données se fait grâce à des bornes réparties sur des tronçons qui sont représentées sur la figure 3.10.




Figure 3.10 Représentation de la dispersion géographique des bornes d'acquisition des données de la ville de Montréal

Cependant, nous avons constaté que les tronçons équipés de bornes sont majoritairement situés au centre de l'île de Montréal. Ainsi, le choix a été fait de prendre une vitesse moyenne commune à l'ensemble de l'île. Une étude de ces données nous a permis d'obtenir la vitesse moyenne par heure sur l'île de Montréal, par jour de la semaine, représentée dans la figure 3.11. Le premier constat qui peut être fait en analysant ces courbes est que la vitesse est au plus bas aux heures de pointe qui correspondent aux heures d'activité (6h-10h et 15h-19h). De plus, on peut noter une fois de plus l'importance de séparer les jours de la semaine, de ceux de la fin de la semaine puisque leur tendance est clairement distincte dans les deux cas.




Figure 3.11 Vitesse moyenne des véhicules par heure pour les différents jours de la semaine de l'île de Montréal

Chaque véhicule reste sur le lieu de l'intervention, et sa position est enregistrée une fois l'intervention terminée, ce qui signifie qu'il ne retourne pas au CT tant qu'une nouvelle intervention ne lui a pas été attribuée. Cependant, à la fin du quart de travail, les véhicules retournent dans leur CT. Le modèle de simulation prend donc en compte le calcul de la distance entre la position actuelle de chaque véhicule, à l'emplacement de la dernière intervention, et le lieu de la prochaine intervention.

3.3.3 Génération de plusieurs niveaux de densité de la demande pour une mise à l'échelle du nombre d'interventions

Pour cette étude, les données requises consistent principalement en les données historiques des interventions. Néanmoins, comme expliqué dans le chapitre 2, les données extraites du logiciel Logic 2.0, ne correspondent qu'aux interventions demandées par le COP. Ainsi, les interventions demandées par le gestionnaire n'y apparaissent pas. En raison de leur fiabilité et leur niveau de détail, nous avons choisi d'utiliser la base de données du logiciel Logic 2.0. Par conséquent, pour pallier l'incomplétude probable des données, nous avons proposé de mettre ces dernières à l'échelle en considérant les données disponibles comme étant incomplètes. Plus précisément, puisque l'entreprise est en mesure d'évaluer le taux d'utilisation de ses véhicules, nous proposons d'utiliser cette information afin de mettre à l'échelle le volume total d'interventions. Cette opération de mise à l'échelle est réalisée grâce au modèle de simulation. En effet, la méthode choisie a été de faire varier de manière itérative le volume des interventions généré sur une journée moyenne (une journée avec une répartition moyenne des interventions observées sur les 4 ans d'historiques des données) en entrée du modèle de simulation jusqu'à l'obtention du taux d'utilisation souhaité.

3.3.4 Évaluation des différentes stratégies de dispatching

Comme l'objectif est d'évaluer et potentiellement d'améliorer la stratégie d'affectation de la STM, dans le but ultime de dimensionner la nouvelle flotte de véhicules électriques, nous avons proposé plusieurs alternatives. Celles-ci ont été implémentées dans le modèle de simulation et sont présentées dans le tableau 3.2.

Tableau 3.2 Tableau récapitulatif des règles de dispatching

Stratégie	Description
Règle actuelle (CR)	Chaque intervention est assignée au véhicule disponible le plus proche géographiquement.
Dépôt centralisé avec règle actuelle (C-CR)	Une centralisation de tous les véhicules de service au sein d'un même CT est envisagée à la place de plusieurs CT géographiquement dispersés. La stratégie d'affectation reste la même, c'est-à-dire que chaque intervention est affectée au véhicule disponible le plus proche géographiquement.
Priorité au véhicule avec la plus grande autonomie restante (GRA)	Chaque intervention est assignée au véhicule ayant la plus grande autonomie de batterie restante (nombre de kilomètres restants à parcourir). L'objectif est de repousser au plus la recharge de manière à ne pas en avoir lors du quart horaire.
Priorité au véhicule le moins utilisé (LUV)	Chaque intervention est assignée au véhicule disponible le moins utilisé en termes de taux d'utilisation. Cette règle vise à équilibrer la charge de travail des CO.

Puisque l'objectif du modèle de simulation est de trouver une meilleure alternative pour mieux dimensionner la taille de la flotte, nous proposons de comparer les stratégies de répartition décrites ci-dessus.

Pour ce faire, nous proposons une approche itérative ; à chaque itération, le modèle de simulation est exécuté avec un nombre donné de véhicules. En particulier, nous commençons ce processus avec le nombre actuel de véhicules en service et, à chaque itération, nous éliminons le véhicule le moins utilisé (c'est-à-dire celui ayant un taux d'utilisation inférieur à un seuil prédéfini), jusqu'à ce que tous les indicateurs respectent les cibles fixées. Ainsi, lorsque la condition d'arrêt est satisfaite, on obtient dans la dernière itération un nombre minimal de véhicules qui respecte l'ensemble des cibles des indicateurs. Ce processus itératif est décrit à l'aide d'un diagramme présenté dans la figure 3.12.




Figure 3.12 Processus itératif de réduction du nombre de véhicules

Ainsi, nous avons présenté dans cette partie la méthodologie utilisée afin de déterminer des meilleures règles d'affectation des véhicules pour améliorer le dimensionnement de la flotte de véhicules de service. Le choix a été fait de développer un modèle de simulation à événement discret, car il nous permet de prendre en compte le fort caractère stochastique du problème, ainsi que les nombreuses variables influant sur le système. Les résultats obtenus à l'aide de cette méthode seront présentés dans le chapitre suivant.

3.4 Heuristiques pour la variante déterministe

Toujours dans la perspective de dimensionner la flotte, mais dans l'hypothèse où nous connaîtrions à l'avance les demandes d'interventions, nous avons mis en place des heuristiques de construction de tournées. Ces heuristiques nous permettent également de mieux déterminer

les horaires adaptés pour les quarts de travail. Ainsi, nous proposons quelques heuristiques qui pourraient s'appliquer dans ce cas bien précis.

Nous nous sommes inspirés de travaux réalisés dans le cas de livraisons de colis, afin de construire des tournées de véhicules. Les camions livrant les colis seront dans notre cas les véhicules de CO, tandis que les livraisons seront les demandes d'interventions. La particularité de notre cas comparée à des problèmes de tournées de véhicules classique, est la durée sur le lieu de la livraison / intervention. Ici, ces durées peuvent s'étaler sur plusieurs dizaines de minutes. De même, notre problème est multi-dépôts et nos véhicules ne peuvent circuler que pendant une durée donnée.

La difficulté liée à la mise en place d'heuristiques sur un tel problème est la particularité de notre cas. Nous conservons les hypothèses antérieures en les intégrant lors de l'adaptation de nos heuristiques, à l'exception de la nature des demandes d'interventions qui est déterministe dans ce cas-ci. Ainsi, celles-ci doivent répondre à un problème de tournées de véhicules dans un cas multi-dépôts avec fenêtres de temps. Nos heuristiques prendront également en compte le trafic routier de la même manière que dans le modèle de simulation. Enfin, de manière à pouvoir travailler sur des données similaires à celles utilisées par le modèle de simulation (demandes d'intervention), la liste des interventions prévues dans une journée, est extraite du modèle de simulation pour être utilisées dans les heuristiques. En effet, nous avons fait tourner le modèle précédemment présenté, et nous avons enregistré pour plusieurs journées les interventions, à savoir leur heure d'apparition ainsi que leur localisation.

Comme présenté dans la revue de la littérature, les premières méthodes à mettre en place dans le cadre de la résolution du problème de tournées de véhicules sont les heuristiques de construction. En effet, elles permettent de construire une solution de manière itérative sans aucune connaissance de solution initiale. Les travaux dans la littérature sur les tournées de véhicules suggèrent plusieurs heuristiques tels que le plus proche voisin, *Clark & Wright*, la recherche tabou, les algorithmes génétiques, etc. Nous avons fait le choix de nous intéresser aux heuristiques du plus proche voisin, de Clark & Wright et basé sur l'aléatoire. En effet, ces

heuristiques sont faciles à mettre en place pour des problèmes classiques et peuvent être adaptées à des problèmes plus complexes.

3.4.1 Heuristique du plus proche voisin

La première heuristique que nous avons mise en place est l'heuristique du plus proche voisin. Cependant, son implémentation est moins triviale en raison de la prise en compte de l'ensemble des contraintes du problème, à savoir, la disponibilité des véhicules via la prise en compte des quarts de travail, le respect de la chronologie des interventions et enfin, la gestion de plusieurs dépôts.

Cette heuristique assigne chaque intervention au véhicule le plus proche géographiquement. Cependant, comme dans notre cas, les interventions ne peuvent être traitées indépendamment du temps, ces dernières sont traitées dans leur ordre d'apparition. Ainsi, dans cet ordre chaque intervention est assignée au véhicule le plus proche. Par ailleurs, avant d'assigner une intervention au véhicule le plus proche, il faut vérifier que ce dernier est disponible, c'est-à-dire que la durée entre l'heure de fin de la précédente intervention et l'intervention actuelle est non négative. L'heure de fin de la précédente intervention est donnée par l'addition du temps de trajet et du temps sur le lieu de l'intervention. Alors, dans l'ordre d'apparition, chaque intervention est assignée au véhicule le plus proche disponible. A la fin de l'algorithme, l'ensemble des tournées sont enregistrées, nous permettant de mesurer les différents indicateurs, soit, le nombre de véhicules, le taux d'utilisation, la distance parcourue en moyenne par véhicule et le temps d'attente moyen. Les étapes de cette heuristique sont présentées dans le schéma de la figure 3.13. Nous avons relancé cette heuristique, en retirant à chaque itération le véhicule le moins utilisé (à partir de son taux d'utilisation) jusqu'à obtenir les meilleurs résultats possibles, en accord avec les seuils de la STM. Cette approche est similaire à celle présentée précédemment dans la figure 3.12.




Figure 3.13 Schéma présentant l'adaptation de l'heuristique du plus proche voisin

3.4.2 Heuristique de *Clark & Wright*

Dans un second temps, nous avons testé l'heuristique de Clark & Wright. Dans le cadre d'un problème de tournée de véhicules classique, l'heuristique est initialisée en construisant une route par intervention, en outre un aller retour du dépôt au lieu de l'intervention. Ensuite, la matrice des économies est calculée, permettant d'évaluer l'économie réalisée en combinant deux interventions au sein d'une même route. A l'aide de cette matrice et par ordre décroissant

des économies, les routes sont construites jusqu'à ne plus pouvoir combiner de routes. Comme précédemment, des modifications ont dû être effectuées afin de l'adapter à notre cas d'étude. Entre autres, le problème a été découpé de manière à le ramener à un problème avec un seul dépôt, en associant chaque intervention à son dépôt le plus proche géographiquement. Ensuite, les routes sont combinées dans l'ordre obtenu à l'aide de la matrice des économies. Les économies dans notre cas, sont des réductions en termes de distance parcourue. Cependant des tests de faisabilité sont mis en place avant de combiner deux routes, permettant de vérifier la disponibilité du véhicule ainsi que le non-dépassement de la durée du quart de travail, et enfin que les interventions se suivent bien chronologiquement. Le fonctionnement de ce dernier est présenté dans le logigramme de la figure 3.14.




Figure 3.14 Schéma présentant l'adaptation de l'heuristique de Clark & Wright

3.4.3 Heuristique basée sur l'aléatoire

Finalement, nous avons testé l'heuristique aléatoire. Celle-ci affecte les interventions aux véhicules disponibles de manière aléatoire. En effet, l'heuristique dans l'ordre d'arrivée des interventions affecte chacune des interventions à un véhicule disponible de manière aléatoire. Un véhicule est disponible, s'il est utilisé pour un quart de travail, et s'il n'est pas déjà affecté à une intervention. Cette opération d'affectation est réalisée pour l'ensemble des interventions.

Afin d'obtenir des résultats intéressants, nous réalisons plusieurs répliques pour chaque jeu de données et nous gardons la meilleure. Ainsi, à la fin de chaque réplique, les métriques sont mesurées, à savoir le nombre de véhicules, le taux d'utilisation des véhicules, le temps d'attente, pour chaque intervention, et la distance parcourue par chaque véhicule. Afin d'obtenir des routes intéressantes, il est nécessaire de réaliser de nombreuses répliques. Ainsi, on relance l'algorithme un nombre donné de fois, ici 10000 fois, et on garde la meilleure solution basée sur les métriques.

Dans ce chapitre nous avons présenté la méthodologie que nous avons mise en place. Cette dernière est composée de trois étapes majeures. La première est la prévision, permettant de réaliser une évaluation du nombre d'interventions futures en fonction. Le choix d'une méthode a été fait afin que ce travail puisse être repris par l'entreprise partenaire. En effet, le choix d'une méthode de prévision classique a été fait, de manière à ce que l'entreprise partenaire puisse s'approprier ce travail. Ensuite, nous avons développé un modèle de simulation à événement discret afin de comparer différentes stratégies de *dispatching* et afin de dimensionner la flotte selon chaque stratégie. Le choix de la simulation à événement discret est justifié par le fort caractère stochastique de notre problème et à la complexité spatio-temporelle des demandes d'interventions, la présence de plusieurs dépôts et quarts de travail. Enfin, dans l'optique où nous aurions des prévisions suffisamment fiables, nous avons développé des heuristiques de création de routes afin de nous aider à évaluer les routes

optimales que devraient suivre les CO et ainsi obtenir un dimensionnement de la flotte de véhicules de CO dans un contexte déterministe.

CHAPITRE 4

RESULTATS

Les résultats de la méthodologie développée dans le chapitre précédent seront présentés dans cette partie. Ces résultats ont été obtenue sur un PC équipé d'un processeur i7-11800H @ 2.30GHz et de 16 Go de mémoire vive. De plus, l'ensemble des algorithmes ont été codés sur Python 3.9.12 et les modèles de simulation à évènement discret ont été développés sur Arena 7.0.1.

4.1 Evaluation des modèles de prévision des demandes d'interventions

En appliquant les méthodes présentées précédemment, nous avons obtenu les résultats présentés dans le tableau 4.1, et un exemple est présenté en figure 4.1 pour :

- une granularité au jour ;
- un horizon temporel de 365 jours ;
- un cycle saisonnier de 7 jours ;
- l'ensemble de l'île de Montréal
- un jeu de données historiques couvrant une période de 4 ans.

Tableau 4.1 Tableau récapitulatif des résultats des méthodes de prévisions

Méthodes	MAPE	MSE	MAD
Facteurs saisonniers et régression linéaire	28,63%	16,01	3,03
Facteur saisonniers et méthode de Holt	29,63%	20,65	3,45
Méthode Holt-Winters	34,48%	26,48	4,09




Figure 4.1 Exemple de prévisions obtenues à l'aide de la méthode de la régression linéaire avec facteurs de saisonnalité

Les prévisions obtenues à partir de la méthode de la régression linéaire avec facteurs de saisonnalité fournissent les meilleurs résultats pour les trois indicateurs MAPE, MSE et MAD. Les erreurs sont tout de même élevées, ce qui, comme dit précédemment, s'explique par le caractère erratique du profil de demande, de nombreuses valeurs étant fréquemment proches de 0. Dans ce cas, même si l'erreur est faible, l'écart indique une importante déviation. De ce fait, dans la partie suivante une autre méthode pour estimer les demandes d'interventions a été mise en place. Il est important de rappeler que nous travaillons sur des données potentiellement incomplètes. Si toutes les données étaient disponibles, les résultats des modèles utilisés seraient probablement plus précis.

4.2 Validation du modèle de simulation à évènement discret

4.2.1 Mise à l'échelle de la demande d'interventions

Comme mentionné précédemment, les données disponibles relatives aux demandes d'interventions sont probablement incomplètes. Nous avons donc proposé de générer plusieurs scénarios en considérant différents niveaux de densité des interventions ce qui a permis d'obtenir différents taux d'utilisation des véhicules des CO, comme présenté dans le graph 4.2. Après validation avec la STM, nous avons retenu un taux d'utilisation des véhicules de 50 %, correspondant à un total de 173 interventions par jour (en semaine).




Figure 4.2 Nombre d'interventions en fonction du taux d'utilisation moyen des véhicules des CO par jour

4.2.2 Comparaison des stratégies d'affectation

Nous initialisons le modèle de simulation avec la flotte actuelle de l'entreprise, composée de 38 véhicules. Comme expliqué précédemment, la démarche de modélisation par simulation est un processus itératif d'amélioration (voir figure 3.12) où chaque nouvelle itération correspond à une simulation réalisée avec un nombre réduit de véhicules. Les résultats présentés sont ceux

de la dernière itération répondant aux cibles fixées pour les indicateurs de la STM. Ils ont été obtenus pour une demande de 173 interventions quotidiennes en semaine.

Un des défis en simulation réside dans l'obtention de résultats robustes. En effet, il est nécessaire de réaliser plusieurs réplifications du modèle pour obtenir des résultats statistiquement significatifs. Hoad et al. (2010) proposent une méthode pour déterminer la valeur du nombre de réplifications nécessaires et ainsi garantir la robustesse et la reproductibilité des résultats.

Le nombre de réplifications a été calculé à partir des données initialement obtenues avec 10 réplifications, et recalculé une fois le nombre de réplifications modifié. Nous avons obtenu pour notre cas, un nombre de réplifications de 30. Ce résultat a été validé à chaque itération de notre processus d'évaluation de nos stratégies d'affectation. L'équation est présentée ci-après :

$$N = \left(\frac{Z_{\alpha/2} \cdot S}{E} \right)^2 \quad (4.1)$$

Avec :

N	Nombre de réplifications
S	Ecart-type estimé à partir des réplifications initiales
E	Tolérance d'erreur
$Z_{\alpha/2}$	Valeur critique de la loi Normale pour un niveau de confiance donné (par exemple 1,96 pour 95%)

Les résultats obtenus pour le scénario avec 173 demandes journalières, soit un taux d'utilisation moyen de 50% actuellement, sont présentés dans les figures 4.3 à 4.6. La figure 4.3 présente le nombre de véhicules composant la flotte par stratégie de dispatching, la figure 4.4 présente la répartition du temps d'attente moyen sur 30 réplifications, la figure 4.5 présente

la répartition du taux d'utilisation moyen sur 30 réplications et enfin la figure 4.6 présente la répartition du kilométrage moyen par véhicule sur 30 réplications.




Figure 4.3 Nombre minimal de véhicules nécessaires obtenu avec les stratégies d'affectation proposées pour 173 demandes journalières




Figure 4.4 Répartition du temps d'attente moyen sur 30 réplications pour 173 demandes journalières




Figure 4.5 Répartition du taux d'utilisation moyen sur 30 répliques pour 173 demandes journalières




Figure 4.6 Répartition de la distance moyenne parcourue par véhicule sur 30 répliques pour 173 demandes journalières

En comparant les différentes stratégies d'affectation, il apparaît clairement que la stratégie GRA (règle basée sur l'autonomie des véhicules) présente systématiquement de meilleurs résultats (voir figures 4.3 à 4.6). En effet, cette stratégie requiert le plus petit nombre de

véhicules nécessaire pour répondre à l'ensemble des interventions tout en respectant les cibles des indicateurs. Ces résultats doivent toutefois être interprétés avec précaution, car cette stratégie ne prend pas en compte, dans le processus de recherche du véhicule le plus adapté, ni la position des véhicules ni leur éloignement par rapport aux interventions, elle ne repose que sur l'autonomie restante du véhicule. Enfin, la stratégie basée sur le taux d'utilisation (LUV) semble moins performante, produisant des résultats systématiquement moins bons que ceux des autres stratégies. Concernant la stratégie C-CR, il convient de noter que le regroupement de l'ensemble de la flotte dans un seul CT centralisé (ici Stinson, car le plus central), bien qu'offrant des résultats similaires à la stratégie actuelle de l'entreprise (CR), cette dernière n'est pas réaliste dans l'état actuel. En effet aucun des huit centres techniques n'est dimensionné pour accueillir toute la flotte. En revanche, suite à la réduction du nombre de véhicules, ce scénario permettrait de réduire les coûts liés aux infrastructures de recharge, car les bornes seraient mutualisées pour l'ensemble de la flotte. Des analyses complémentaires sont nécessaires afin d'évaluer la faisabilité d'un tel regroupement centralisé. Enfin, la règle actuelle (CR), permet à la STM, sans modifier leur organisation de tout de même réduire fortement le nombre de véhicule composant leur flotte.

4.2.3 Analyse de sensibilité

Compte tenu du fait que le nombre d'interventions estimé en semaine repose sur un ensemble de données possiblement incomplètes, nous avons proposé de réaliser une analyse de sensibilité pour étudier la mise à l'échelle de la demande. Pour cela, nous avons défini plusieurs scénarios, chacun correspondant à un niveau de demande donné. Chaque niveau de demande génère un taux d'utilisation différent. Nous avons évalué les stratégies d'affectation précédentes pour les scénarios suivants :

- Scénario 1 : 98 interventions et un taux d'utilisation de 30 %
- Scénario 2 : 143 interventions et un taux d'utilisation de 40 %
- Scénario 3 : 209 interventions et un taux d'utilisation de 60 %
- Scénario 4 : 241 interventions et un taux d'utilisation de 70 %

Les résultats de l'ensemble des scénarios sont présentés dans le Tableau 4.2.

Tableau 4.2 Tableau récapitulatif des résultats pour chaque règle d'affectation pour différents scénarios

Scenarios		Nombre de véhicules	Taux d'utilisation moyen (%)	Temps d'attente moyen (mins)	Distance moyenne par véhicule (km)
Scenario 1	CR	10	51,05	29,65	85,79
	LUV	12	48,40	38,36	99,63
	GRA	8	56,86	38,49	122,23
	C-CR	10	49,76	28,27	84,36
Scenario 2	CR	14	51,65	30,56	91,48
	LUV	17	49,68	36,91	102,56
	GRA	14	52,68	36,53	114,68
	C-CR	14	51,02	29,07	90,45
Scenario 3	CR	19	54,47	29,79	89,32
	LUV	24	50,25	38,70	104,24
	GRA	19	55,27	37,01	117,82
	C-CR	19	53,52	27,39	91,60
Scenario 4	CR	23	50,87	27,27	82,09
	LUV	26	51,86	38,57	108,17
	GRA	20	56,94	34,71	115,69
	C-CR	22	52,24	27,09	88,35

L'analyse des résultats du Tableau 4.2 confirme la supériorité de la stratégie GRA pour tous les scénarios, celle-ci permettant toujours de mobiliser le nombre minimal de véhicules. L'analyse de sensibilité permet ainsi d'obtenir des conclusions plus significatives et consistantes malgré les données potentiellement incomplètes. Comme la stratégie GRA permet d'utiliser le moins de véhicules, par conséquent, elle permet d'offrir le meilleur taux d'utilisation. En effet, moins le nombre de véhicules est élevé plus les véhicules vont devoir parcourir des distances plus élevées et donc cela augmente systématiquement leur taux d'utilisation.

4.3 Evaluation des heuristiques

Dans un dernier temps, nous avons appliqué les heuristiques de tournées de véhicules présentées dans le Chapitre 3, à savoir, le plus proche voisin, Clark & Wright et enfin aléatoire, que nous avons adapté à notre cas d'étude. Nous rappelons que nous avons posé l'hypothèse, où les demandes d'interventions seraient connues à l'avance. Ceci correspondrait au cas où nous aurions de très bonnes prévisions des demandes d'interventions. Par ailleurs, ce travail pourrait aider le gestionnaire dans la construction de son planning de pré-affectation des ressources au vue des besoins opérationnels.

Nous présentons dans ce qui suit les résultats des heuristiques testées, en premier lieu, l'heuristique du plus proche voisin, puis l'heuristique de *Clark & Wright* et enfin l'heuristique basé sur l'aléatoire. En nous intéressant aux mêmes indicateurs que dans la partie précédente, nous obtenons pour ces heuristiques, appliquées à plusieurs jeux de données obtenues à partir d'extractions du modèle de simulation, les résultats présentés dans le tableau 4.3.

Tableau 4.3 Tableau récapitulatif des résultats pour chaque heuristique

173 Int / Jour	Nombre de véhicules	Taux d'utilisation moyen (%)	Temps d'attente moyen (mins)	Distance moyenne par véhicule (km)
Plus proche voisin	16	54,16%	16,14	59,24
Clark & Wright	23	23,99%	8,90	25,49
Meilleure réplique aléatoire	16	72,55%	33,40	143,74

L'analyse des résultats du tableau 4.3 confirme l'efficacité de la règle d'affectation du plus proche voisin. En effet, cette heuristique permet de minimiser le nombre de véhicules composant la flotte. Cependant, l'heuristique de *Clark & Wright* apporte une piste de recherche permettant de construire des routes dans le cadre où la STM ne souhaiterait pas réduire sa flotte de véhicules de services au minimum. En effet, cet heuristique permet également d'obtenir les horaires idéaux où placer les quarts de travail des CO.

4.4 Conclusion

Ainsi dans cette partie nous avons dans un premier temps comparé les résultats de différentes méthodes de prévisions des interventions futures. La méthode la plus prometteuse obtenu est la méthode de la régression linéaire avec facteurs de saisonnalité. Par la suite, à l'aide du modèle de simulation à évènement discret, nous avons proposé de rectifier le nombre d'interventions du fait que les données disponibles sont potentiellement incomplètes. Plusieurs stratégies de *dispatching* ont été testées, parmi lesquelles deux sont très avantageuses, la première étant celle basée sur l'autonomie des véhicules et la deuxième celle centralisant la flotte au sein d'un seul CT. Enfin, à l'aide d'heuristiques de construction de tournées de véhicules que nous avons adaptées à notre problème, nous avons pu dimensionner la flotte dans l'hypothèse où nous connaîtrions la demande.

CONCLUSION

Ce travail est le fruit d'une collaboration avec la société de transport de Montréal (STM) qui nous a permis de définir un problème décisionnel qui vise à maintenir sa flotte d'autobus en conditions opérationnelles. En particulier, l'entreprise canadienne souhaitait convertir ses véhicules de service thermiques en véhicules électriques, ce qui engendre le besoin d'outils d'aide à la décision permettant de déterminer la taille optimale de la flotte tout en respectant certaines cibles de performance. Ainsi, nous avons proposé comme première contribution plusieurs modèles de prévision des interventions basées sur l'historique des données mises à disposition par la STM. Notre seconde contribution est la proposition d'un cadre générique de modélisation par simulation afin de représenter le comportement réel de la flotte de l'entreprise considérant l'aspect fortement stochastique de la demande qui est spatio-temporelle. Ce modèle de simulation a permis d'évaluer plusieurs scénarios de niveaux de demande en raison de la potentielle incomplétude des données disponibles. Ensuite, nous avons proposé et mis en œuvre plusieurs stratégies d'affectation afin d'améliorer la stratégie actuelle de l'entreprise, en tenant compte de différents indicateurs de performance ayant différentes priorités. Le modèle de simulation prend en compte les contraintes liées à l'autonomie des véhicules électriques. Les résultats préliminaires ont montré que la règle d'affectation basée sur l'autonomie des véhicules surpasse les autres stratégies. Cependant, la règle basée sur la proximité des interventions aux véhicules, à savoir la règle utilisée actuellement, a montrée, malgré sa simplicité de mise en place une certaine robustesse et efficacité. Enfin, nous avons considéré la version déterministe du problème dans la perspective de développement d'un modèle de prévision plus précis. Dans ce contexte, nous avons adapté des heuristiques pour construire des solutions réalisables rapidement. Les instances considérées dans la phase expérimentale sont basées sur un problème réel issu des services de transport public de la STM.

Pour les travaux futurs, d'après la revue de la littérature, il serait intéressant d'explorer des méthodes de prévision avancées basées sur l'apprentissage profond afin d'améliorer la précision des prévisions de la demande d'interventions. Il pourrait également être bénéfique de prendre en compte les routes du réseau routier pour estimer plus précisément les temps de

déplacement des véhicules. Un autre aspect important à considérer est l'opération de recharge des véhicules. En effet, il n'est pas réaliste de recharger tous les véhicules dans leurs centres techniques dédiés en même temps ; il serait donc nécessaire de planifier la recharge de certains véhicules pendant leurs trajets, ce qui pourrait réduire le nombre de véhicules disponibles au cours d'un même quart de travail. Enfin, des approches d'optimisation stochastique ou dynamique pourraient être explorées pour déterminer la taille optimale de la flotte de véhicules ainsi que des stratégies alternatives d'affectation.

Dans la suite de l'étude nous proposons à l'entreprise partenaire, la STM, de mettre en place plusieurs process de gestion des données afin de pouvoir obtenir des résultats plus précis. En effet, le manque de données précises est un gros frein à ce projet. Cependant, si cette proposition semble trop compliquée à mettre en place, il faudrait construire un indicateur permettant d'évaluer le taux d'utilisation des véhicules de service afin de pouvoir estimer le nombre d'interventions réel. Avec ces actions prises, l'entreprise pourra alors choisir la stratégie d'affectation la plus adaptée. La règle d'affectation basée sur l'autonomie semble intéressante, de même que la centralisation de la flotte au sein d'un même centre de transport. Cependant, si cela ne peut être mis en place, l'utilisation de la règle actuelle permet tout de même de réduire le nombre de véhicules composant la flotte. Enfin, la STM pourra se baser sur les résultats des heuristiques développées afin d'évaluer le dimensionnement de leur flotte de CO dans l'hypothèse où les demandes d'interventions seraient connues à l'avance. De plus, ces méthodes pourraient à terme permettre à la STM de construire leur planning de pré-affectation. A partir de l'ensemble de ces résultats la STM sera en capacité d'évaluer le nombre de véhicule optimal pour sa flotte de véhicules de service électriques.

LISTE DE RÉFÉRENCES BIBLIOGRAPHIQUES

- Vitrine Linguistique, Prévision, Tiré de <https://vitritelinguistique.oqlf.gouv.qc.ca/fiche-gdt/fiche/8429437/prevision>, [consulté le 20 mai 2025]
- Site officiel de la STM, Rapport d'activité annuel, Tiré de <https://www.stm.info/fr/a-propos/informations-entreprise-et-financieres/rapport-annuel-2023/rapport-dactivite> [consulté le 17 Mars 2024]
- Wikipédia, Série temporelle, Tiré de https://fr.wikipedia.org/wiki/Série_temporelle [consulté le 20 mai 2025]
- Nahmias, S., et Olsen, T. L. (2015). *Production and Operations Analysis* (7th ed.). Waveland Press. <https://doi.org/10.1111/poms.12425>
- Syntetos, A. A., Boylan, J. E., et Croston, J. D. (2005). On the categorization of demand patterns. *Journal of the Operational Research Society*, 56(5), 495-503. <https://doi.org/10.1057/palgrave.jors.2601841>
- Williams, T. M. (1984). Stock Control with Sporadic and Slow-Moving Demand. *The Journal of the Operational Research Society*, 35(10), 939-948. <https://doi.org/10.2307/2582137>
- Vitrine Linguistique, Taux de service, Tiré de <https://vitritelinguistique.oqlf.gouv.qc.ca/fiche-gdt/fiche/2096398/taux-de-service> Vitrine Linguistique, Prévision, Tiré de
- Google Scholar to overshadow them all? Comparing the sizes of 12 academic search engines and bibliographic databases, Michael Gusenbauer, 2018
- Elsevier (2024), *Scopus Content*, Tiré de <https://www.elsevier.com/solutions/scopus/how-scopus-works/content>, [consulté le 20 mai 2025].
- Ville de Montréal. (2023). Temps de parcours sur des segments routiers. <https://donnees.montreal.ca/dataset/temps-de-parcours-sur-des-segments-routiers-historique> [consulté le 12 Décembre 2025].

- Chand, A., Jayesh, S., et Bhasi, A. B. (2021). Road traffic accidents: An overview of data sources, analysis techniques and contributing factors. *Materials Today: Proceedings*, 47, 5135-5141. <https://doi.org/10.1016/j.matpr.2021.05.415>
- Du, Y., et Ding, N. (2023). A Systematic Review of Multi-Scale Spatio-Temporal Crime Prediction Methods. *ISPRS International Journal of Geo-Information*, 12(6), 209. <https://doi.org/10.3390/ijgi12060209>
- Eslamzadeh, M. K., Grilo, A., et Espadinha-Cruz, P. (2022). A Framework for Resource Allocation in Fire Departments: A Structured Literature Review. *Fire*, 5(4), 109. <https://doi.org/10.3390/fire5040109>
- Gutierrez-Osorio, C., et Pedraza, C. (2020). Modern data sources and techniques for analysis and forecast of road accidents: A review. *Journal of Traffic and Transportation Engineering (English Edition)*, 7(4), 432-446. <https://doi.org/10.1016/j.jtte.2020.05.002>
- Li, R., Pereira, F. C., et Ben-Akiva, M. E. (2018). Overview of traffic incident duration analysis and prediction. *European Transport Research Review*, 10(2), 22. <https://doi.org/10.1186/s12544-018-0300-1>
- Ning, Y., Zhao, L., Chen, F., Lu, C.-T., et Rangwala, H. (2019). Spatio-temporal Event Forecasting and Precursor Identification. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery et Data Mining*, 3237-3238. Anchorage AK USA: ACM. <https://doi.org/10.1145/3292500.3332291>
- Ben Messabih, B., Z., Behiri, W., Belmokhtar-Berraf, S., Boukherroub, T., Sahli, A. et Zouaghi, I. (2025). A lexicographic bi-objective approach to fleet sizing and routing for service vehicles in a real-world passenger transport system.
- Shah, K. S., Rehman, H. U., Shahani, N. M., Ullah, B., Abbas, N., Junaid, M., et Hashim, M. H. B. M. (2024). Towards safer mining environments: An in-depth review of predictive models for accidents. *Arabian Journal of Geosciences*, 17(11), 292. <https://doi.org/10.1007/s12517-024-12090-4>
- Koehler, A. B., Snyder, R. D., & Ord, J. K. (2001). Forecasting models and prediction intervals

- for the multiplicative Holt–Winters method. *International Journal of Forecasting*, 17(2), 269-286. [https://doi.org/10.1016/S0169-2070\(01\)00081-4](https://doi.org/10.1016/S0169-2070(01)00081-4)
- You, J., Wang, J., et Guo, J. (2017). Real-time crash prediction on freeways using data mining and emerging techniques. *Journal of Modern Transportation*, 25(2), 116-123. <https://doi.org/10.1007/s40534-017-0129-7>
- Zheng, X., et Liu, M. (2009). An overview of accident forecasting methodologies. *Journal of Loss Prevention in the Process Industries*, 22(4), 484-491. <https://doi.org/10.1016/j.jlp.2009.03.005>
- Ingle, Y. V., Dongre, S. S., Wankhede, M. M., et Barve, S. P. (2019). Demand forecasting: Literature review on various methodologies. *International Journal of Research in Engineering, Science and Management*, 2(3), 719–724.
- Malan, M. (2017). Determining the tractor fleet size in an underground coal mine through simulation modelling. *Journal of the Southern African Institute of Mining and Metallurgy*, 117(1), 65–70.
- Hoad, K., Robinson, S., et Davies, R. (2010). Automated selection of the number of replications for a discrete-event simulation. *Journal of the Operational Research Society*, 61(11), 1632–1644.
- Bélangier, V., Ruiz, A., et Soriano, P. (2019). Recent optimization models and trends in location, relocation, and dispatching of emergency medical vehicles. *European Journal of Operational Research*, 272(1), 1–23.
- Dorigo, M., et Gambardella, L. M. (1997). Ant colony system: A cooperative learning approach to the traveling salesman problem. *IEEE Transactions on Evolutionary Computation*, 1(1), 53-66. <https://doi.org/10.1109/4235.585892>
- Gillett, B. E., et Miller, L. R. (1974). A Heuristic Algorithm for the Vehicle-Dispatch Problem. *Operations Research*, 22(2), 340-349. <https://doi.org/10.1287/opre.22.2.340>
- Glover, F. (1989). Tabu Search—Part I. *ORSA Journal on Computing*, 1(3), 190-206.

<https://doi.org/10.1287/ijoc.1.3.190>

Holland, J. H. (1992). *Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence*. The MIT Press. <https://doi.org/10.7551/mitpress/1090.001.0001>

Kirkpatrick, S., Gelatt, C. D., et Vecchi, M. P. (1983). Optimization by Simulated Annealing. *Science*, 220(4598), 671-680. <https://doi.org/10.1126/science.220.4598.671>

Jezequel, S., Boukherroub, T. et Berraf-Belmokhtar, S. (2025). Dynamic Electric Vehicle Dispatching Problem: A Simulation Modelling Framework. CODIT 2025.

Lin, S. (1965). Computer Solutions of the Traveling Salesman Problem. *Bell System Technical Journal*, 44(10), 2245-2269. <https://doi.org/10.1002/j.1538-7305.1965.tb04146.x>

Mavrovouniotis, M., Ellinas, G., Li, C., et Polycarpou, M. (2022). A Multiple Ant Colony System for the Electric Vehicle Routing Problem with Time Windows. *2022 IEEE Symposium Series on Computational Intelligence (SSCI)*, 796-803. Singapore, Singapore: IEEE. <https://doi.org/10.1109/SSCI51031.2022.10022257>

Rosenkrantz, D. J., Stearns, R. E., et Lewis, P. M. (1977). An Analysis of Several Heuristics for the Traveling Salesman Problem. *SIAM Journal on Computing*, 6(3), 563-581. <https://doi.org/10.1137/0206041>

Solomon, M. M. (1987). Algorithms for the Vehicle Routing and Scheduling Problems with Time Window Constraints. *Operations Research*, 35(2), 254-265. <https://doi.org/10.1287/opre.35.2.254>

Taillard, É., Badeau, P., Gendreau, M., Guertin, F., et Potvin, J.-Y. (1997). A Tabu Search Heuristic for the Vehicle Routing Problem with Soft Time Windows. *Transportation Science*, 31(2), 170-186. <https://doi.org/10.1287/trsc.31.2.170>

Carter, G., et Ignall, E. (1970). A simulation model of fire department operations. *IEEE System Science and Cybernetics*, 5(4), 282-293.

- Haghani, A., et Yang, S. (2007). Real-time emergency response fleet deployment: Concepts, systems, simulation et case studies. In B. Golden, S. Raghavan, et E. Wasil (Eds.), *Dynamic fleet management* (pp. 133–162). Springer.
- Luzon, Y., Baron, O., Verter, V., et Berman, O. (2023). On designing a fire emergency vehicle fleet. *SSRN Electronic Journal*.
- Polyviou, Polyvios (2011) Modelling traffic incidents to support dynamic bus fleets management for sustainable transport. *University of Southampton, School of Civil Engineering and the Environment, Doctoral Thesis*, 263pp.
- Adam, L. F. F. (2024). Valorisation des données de maintenance extraites d'un ERP : développement d'un modèle utilisant l'intelligence artificielle pour la prédiction des consommations. *Mémoire de maîtrise, Polytechnique Montréal. PolyPublie*. <https://publications.polymtl.ca/58315/>