

UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES

GESTION INTELLIGENTE DE LA RECHARGE DES VÉHICULES
ÉLECTRIQUES DANS LE SECTEUR RÉSIDENTIEL

THÈSE PRÉSENTÉE
COMME EXIGENCE PARTIELLE
DU DOCTORAT EN GÉNIE ÉLECTRIQUE

PAR
ABDOUL WAHAB DANTE

août 2023

Université du Québec à Trois-Rivières

Service de la bibliothèque

Avertissement

L'auteur de ce mémoire, de cette thèse ou de cet essai a autorisé l'Université du Québec à Trois-Rivières à diffuser, à des fins non lucratives, une copie de son mémoire, de sa thèse ou de son essai.

Cette diffusion n'entraîne pas une renonciation de la part de l'auteur à ses droits de propriété intellectuelle, incluant le droit d'auteur, sur ce mémoire, cette thèse ou cet essai. Notamment, la reproduction ou la publication de la totalité ou d'une partie importante de ce mémoire, de cette thèse et de son essai requiert son autorisation.

UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES
DOCTORAT EN GÉNIE ÉLECTRIQUE (PH.D.)

Direction de recherche :

Prof. Kodjo AGBOSSOU

Directeur de recherche

Prof. Souso KELOUWANI

Codirecteur de recherche

Jury d'évaluation :

Prof. Kodjo AGBOSSOU,

Université du Québec à Trois-Rivières

Prof. Souso KELOUWANI

Université du Québec à Trois-Rivières

Prof. Messaoud AHMED OUAMEUR, président du jury Université du Québec à Trois-Rivières

Prof. Keyhan SHESHYEKANI, évaluateur externe

École polytechnique de Montréal

Prof. Miloud BAGAA,

Université du Québec à Trois-Rivières

Résumé

L'électrification du secteur des transports est l'une des voies privilégiées par les sociétés modernes pour réduire leur empreinte carbone. Stimulées principalement par des subventions politiques et des avancées technologiques, les ventes de véhicules électriques (VÉ) ont connu une croissance rapide ces dernières années, faisant des VÉs un nouveau type de charge électrique émergente sur le réseau électrique (RÉ). L'augmentation accrue de la pénétration des VÉs dans les réseaux de distribution nécessite de traiter les ressources stratégiques afin de faire face à leurs besoins énergétiques. Une étude minutieuse des questions liées à la contrôle de la recharge des VÉs dans des circonstances réelles peut être considérée comme une étape critique pour permettre ce processus.

La littérature scientifique s'est largement penchée sur la question de la planification intelligente de la recharge des VÉs en proposant différentes stratégies basées sur des techniques d'optimisation mathématique. Ces stratégies visent à réduire les coûts énergétiques de la recharge tout en satisfaisant les préférences des utilisateurs et en améliorant les fonctions du réseau. Cependant, la plupart des travaux existants ne prennent pas en compte certains aspects importants du monde réel tels que les sources d'incertitude et l'accès à un espace d'information complet. L'omission de ces aspects dans la conception des mécanismes de contrôle pourrait entraver la mise en œuvre et l'adoption des technologies reposant sur les algorithmes et les schémas de contrôle proposés. Les progrès des méthodes d'intelligence artificielle et de l'optimisation stochastique ont été reconnus comme l'une des voies les plus prometteuses pour relever les défis susmentionnés, notamment l'incertitude associée au comportement stochastique des utilisateurs, la non-linéarité du profil de la puissance de charge et l'accès complet aux informations clés. Dans cette perspective, des algorithmes de

contrôle basés sur des modèles stochastiques ont émergé ces dernières années pour répondre aux problèmes susmentionnés. Cependant, les défis liés à la complexité et à la prise en compte de l'ensemble des facteurs susmentionnés restent à relever.

Cette thèse propose des modèles, des stratégies et un algorithme de contrôle pour estimer les besoins de recharge en fonction du type de véhicule et optimiser les séquences de recharge en tenant compte des habitudes et le confort des utilisateurs. Le contrôleur proposé s'appuie sur un ensemble d'algorithmes efficaces pour planifier la recharge des VÉs en tenant compte des sources d'incertitude inhérentes. En particulier, il tire parti d'un modèle de prévision basé sur l'inférence bayésienne pour prédire les besoins énergétiques pour la recharge et l'optimisation stochastique pour planifier la recharge en fonction des préférences de l'utilisateur et des prix de l'électricité. Plusieurs études de cas ont été menées pour évaluer les performances de l'algorithme de contrôle proposé en exploitant des données réelles de sessions de recharges des VÉs. Le processus d'évaluation est réalisé à travers une analyse comparative entre les performances du schéma de contrôle proposé avec la méthode déterministe, comme cas idéal, qui exploite un espace d'information complet. Les résultats démontrent que la procédure proposée peut offrir des programmes de charge compétitifs, capables de minimiser les coûts énergétiques liés à la charge tout en satisfaisant les préférences de charge des utilisateurs. Le contrôleur conçu parvient avec succès à gérer la charge des VÉs en présence de phénomènes stochastiques et avec un accès limité aux informations, permettant ainsi une mise en œuvre physique de la solution proposée.

Remerciements

Je tiens à exprimer ma profonde gratitude envers mon directeur de recherche, le Professeur Kodjo Agbossou, ainsi que mon codirecteur, le Professeur Souso Kelouwani, pour leur encadrement exceptionnel, leur soutien scientifique et leurs commentaires constructifs tout au long de cette thèse. Leurs conseils éclairés et leurs encouragements ont été inestimables à chaque étape de mes recherches. Je saisis également cette occasion pour exprimer mes remerciements sincères au Professeur Alben Cardenas et au Dr. Nilson Henao pour leur suivi attentif et leurs contributions précieuses tout au long de ce travail de recherche.

Je tiens à adresser mes remerciements aux chercheurs du Laboratoire des Technologies de l'Énergie (LTE) d'Hydro-Québec pour leur expertise et leur engagement scientifique, ainsi que pour le temps consacré à nos échanges et à la révision de documents liés à mes travaux de recherche.

Ma gratitude va également aux organismes subventionnaires qui ont généreusement soutenu financièrement cette recherche, notamment le LTE d'Hydro-Québec, le Conseil de Recherche en Sciences Naturelles et en Génie du Canada (CRSNG), la Fondation UQTR, l'Institut de Recherche sur l'Hydrogène (IRH) et Mitacs.

Enfin, je tiens à exprimer ma reconnaissance envers ma famille pour son soutien indéfectible, son amour incommensurable et sa patience inépuisable. Mes amis et collègues ont également été une source inestimable de soutien et d'encouragement tout au long de ce parcours, en particulier mes collègues du Laboratoire d'Innovation et de Recherche en Énergie Intelligente (LIREI) de l'Institut de Recherche sur l'Hydrogène, avec qui j'ai eu le privilège de collaborer et de partager de précieux moments.

Table des matières

Résumé	i
Remerciements	iii
Table des matières	iv
Table des figures	vii
Liste des acronymes	ix
Liste des symboles	xi
Chapitre 1 - Introduction	1
1.1 Contexte général de la recherche.....	1
1.2 Historique et statistiques de l'évolution du marché des véhicules électriques....	3
1.3 Impact et opportunités de la recharge des véhicules électriques pour le réseau électrique.....	6
1.4 Problématique de recherche.....	10
1.5 Objectifs et contributions.....	12
1.5.1 Objectifs	12
1.5.2 Contributions	13
1.6 Méthodologie adoptée	14
1.7 Infrastructure de recherche	17
1.8 Structure de la thèse.....	17
Chapitre 2 - État de l'art	19
2.1 Concept de gestion de la recharge des VÉs	19
2.2 Architecture de contrôle	21

2.3	Algorithmes de planification de la recharge des VÉs.....	26
2.3.1	Techniques d'optimisation	27
2.3.2	Approche de contrôle des VÉs	27
2.3.2.1	Approche déterministe	28
2.3.2.2	Approche stochastiques	30
2.4	Caractérisation et modélisation de la demande de recharge des VÉs.....	33
2.4.1	Heures d'arrivée et de départ	33
2.4.2	Demande d'énergie pour la recharge	34
2.4.3	Flexibilité de la demande d'énergie et préférences de l'utilisateur	36
2.4.4	Dynamisme des paramètres du modèle d'état	37
2.5	Synthèse du chapitre.....	37
Chapitre 3 - Caractérisation et planification de la demande de recharge des VÉs		40
3.1	Introduction.....	40
3.2	Détection et identification en ligne des VÉs.....	42
3.2.1	Extraction de caractéristiques discriminatoires	43
3.2.2	Classification des profils de charge	45
3.2.2.1	Réseau de neurones à propagation avant	46
3.2.2.2	Machines à vecteurs de support	48
3.2.3	Méthode SFS pour la sélection des caractéristiques les plus utiles	50
3.3	Modélisation des habitudes de recharge.....	50
3.3.1	Modélisation des heures d'arrivée et de départ	51
3.3.2	Modélisation des demandes d'énergie pour la recharge	54
3.3.2.1	Modèles non paramétriques	54
3.3.2.2	Modélisation des habitudes de recharge	55
3.3.3	Modèle d'anticipation des besoins de recharge des VÉs	55
3.3.4	Estimation du profil de charge	60
3.4	Planification de la recharge des VÉs : Approche déterministe.....	62
3.4.1	Formulation du problème d'optimisation	63
3.5	Planification de la recharge des VÉs : Formulation stochastique.....	67
3.5.1	Modélisation stochastique du problème de la recharge des VÉs	69

3.5.2	Mise en œuvre du contrôleur de charge de VE proposé	74
Chapitre 4 - Évaluation de la méthode		75
4.1	Système de mesure des données pour la validation du modèle et la stratégie de contrôle	75
4.2	Validation de l’algorithme de détection et d’identification des VÉs	77
4.2.1	Utilisation de toutes les caractéristiques d’entrée	77
4.2.2	Sélection des caractéristiques et étude de la sensibilité du modèle . . .	81
4.2.3	Comparaison de la performance des deux classificateurs basés sur le SVM et le réseau de neurones	83
4.2.4	Détection d’une nouvelle classe	85
4.3	Modélisation statistique des heures d’arrivée et de départ	87
4.4	Prévision des demandes individuelles des VÉs	88
4.4.1	Analyse de sensibilité	90
4.4.2	Étude comparative	90
4.5	Planification de la recharge des VÉs	93
4.5.1	Préparation de l’étude de cas	93
4.5.2	Processus de contrôle en ligne	96
4.5.2.1	Fonctionnement du contrôleur proposé	96
4.5.2.2	Performance du contrôleur proposé	97
Chapitre 5 - Conclusions et recommandations		101
5.1	Conclusions.....	101
5.2	Recommandations.....	104
Bibliographie		107

Table des figures

1-1	Stock mondial de VÉs entre 2010 et 2021 [8].	4
1-2	Parts historiques et ciblées de VÉs dans les ventes de véhicules particuliers neufs par marchés [9].	5
1-3	Évolution de la part des véhicules électriques et intelligents dans le parc Nord-Américain [11]	6
1-4	Puissance installée par Hydro-Québec et besoins de puissance en période de pointe [23]-[32].	7
1-5	Demande horaire moyenne d'électricité au Québec, ainsi que pour les journées de plus forte consommation et de plus faible consommation en 2017 [3].	9
1-6	Les six grandes catégories «d'objectifs de forme» de la courbe de charge [36]	9
1-7	Illustration du problème l'interopérabilité dans la charge des VÉs (tirée du projet de recherche en coopération sur la communication <i>VÉ-Infrastructure-système électrique</i> [42])	11
1-8	Méthodologie de recherche adoptée.	15
2-1	Représentation des différents systèmes de tarification de l'électricité [5].	20
2-2	Recharge d'un véhicule électriques dans le cadre de la gestion de la demande d'une maison individuelle [57].	22
2-3	Architecture de contrôle centralisé de la recharge de plusieurs VÉs. [5].	25
2-4	Architecture de contrôle décentralisé de la recharge de plusieurs VÉs. [5].	25
2-5	Modélisation des systèmes déterministes et stochastiques [73].	28

3-1	Schéma du processus de planification de la recharge des VÉs proposé.	41
3-2	Profils de charge typiques de 5 VÉs pendant plusieurs sessions de charge . . .	43
3-3	Processus complet de reconnaissance des VÉs après l'entraînement du modèle.	43
3-4	Topologie du réseau de neurones utilisé	46
3-5	Construction de matrices d'entrée et de cible	48
3-6	Exemple d'hyperplan et de marges maximales pour un SVM entraîné avec des échantillons de deux classes c_i et c_j	49
3-7	Catégorisation des différentes sessions de recharge selon l'heure de branchement.	53
3-8	Densités de probabilité de la demande d'énergie des 5 VÉs (estimation de densité par noyau et histogramme).	56
3-9	Profil typique de la puissance de charge non contrôlée pour une batterie Li-ion.	62
3-10	Exemple de distribution de probabilité conditionnelle de l'heure de départ par rapport à l'heure de branchement.	73
3-11	Exemple typique du profil d'insatisfaction de l'utilisateur.	73
4-1	La borne de recharge institutionnelle locale comme fournisseur de données. .	76
4-2	Banc d'essai expérimental.	76
4-3	Plusieurs profils du courant de charge types des cinq VÉs.	79
4-4	Résultats de la classification du réseau de neurones « feed-forward ».	80
4-5	Résultats de la classification des performances du réseau de neurones à pro- pagation avant sur les données de profils de charge de la base de données 2.	81
4-6	Description de la base de données pour les 4 scénarios (entraînement et test).	83
4-7	Comparaison de la capacité de généralisation du modèle de reconnaissance des VE en utilisant les différents sous-ensembles de caractéristiques sélectionnés à partir de bases de données de différentes tailles en utilisant le classificateur SVM, la base de données 2 a été utilisée pour la phase de test.	84

4-8	Comparaison de la capacité de généralisation du modèle de reconnaissance des VÉ en utilisant différentes tailles de bases de données et les caractéristiques optimales F_{local}^4 (sélectionnées à partir de toute la base de données 1) en utilisant le classificateur SVM.	85
4-9	Comparaison des performances du classificateur SVM et du classificateur de réseau de neurones à propagation avant utilisant les caractéristiques optimales F_{local}^4 (sélectionnées dans 100 % de la base de données 1) et 75 % de la base de données 1 pour la formation et la base de données 2 pour la phase de test.	86
4-10	Reconnaissance des VÉs effectuée sur les bornes de recharge au cours d'une journée type.	87
4-11	Distribution de l'heure d'arrivée et de départ.	88
4-12	Différentes distributions des heures de départ, résultant de la phase de clustering.	88
4-13	Histogramme et Kernel lissé de la demande d'énergies de charge historiques pour les 5 VÉs (1,2,3,4 et 5).	89
4-14	Analyse de sensibilité des entrées du modèle prédictif.	91
4-15	Résultats de l'estimation du besoin de la charge du VÉ par les modèles prédictifs basés sur l'inférence bayésienne et la régression Ridge.	92
4-16	Distribution de l'heure d'arrivée et de départ.	94
4-17	Signaux de prix de l'électricité.	95
4-18	Différentes distributions des heures de départ, résultant de la phase de clustering.	95
4-19	Fonctionnement en ligne du contrôleur proposé pendant les phases de planification et de mise en œuvre des signaux de commande.	98
4-20	Le coût de recharge cumulé de différentes stratégies de recharge incluant le contrôleur proposé.	100

Liste des acronymes

- ADMM** Algorithme des directions alternées des multiplicateurs (*Alternating Direction Method of Multipliers* en anglais)
- BEV** Véhicule électrique à batterie (Battery Electric Vehicle en anglais)
- BMS** Système de contrôle des batteries (*Battery Management System* en anglais)
- CEM** Conférence ministérielle sur l'énergie propre (*Clean Energy Ministerial* en anglais)
- CR** Contrôleur de gestion de la Recharge des VÉs
- DR** Réponse à la Demande (*Demand Response* en anglais)
- DSM** Gestion Locale de la demande (*Demand Side Management* en anglais)
- EVI** Initiative pour les Véhicule Électrique (*Electric Vehicles Initiative* en anglais)
- EVSE** Borne de recharge (Electric Vehicle Supply Equipment en anglais)
- IRH** Institut de Recherche sur l'Hydrogène
- KDE** Estimation de la densité du noyau (Kernel Density Estimation en anglais)
- LIREI** Laboratoire d'Innovation et de Recherche en Énergie Intelligente
- MAE** Erreur absolue moyenne (*Mean absolute error* en anglais)
- MAP** maximale a posteriori
- MPC** Commande Prédicative (Model Predictive Control en anglais)
- OR** Opérateur du réseau électrique
- PHEV** Véhicule hybride rechargeable (Plug-in Hybrid Electric Vehicle en anglais)
- RFID** Radio-identification (*radio-frequency identification* en anglais)
- RMSE** Erreur quadratique moyenne (*Root-Mean-Square Error* en anglais)

RÉ Réseau Électrique

RÉI Réseau Électrique Intelligent

SVM Machines à vecteurs de support (Support Vector Machine en anglais)

TOU Prix d'électricité basé sur la Période d'Usage

UQTR Université du Québec à Trois-Rivières

V2G Véhicule-vers-réseau (Vehicle-to-Grid en anglais)

V2H Véhicule-vers-maison (Vehicle-to-Home en anglais)

V2I Véhicule-vers-infrastructure (Vehicle-to-Infrastructure en anglais)

VZE Véhicule Zéro Émission

VÉ Véhicule Électrique Rechargeable

Liste des symboles

\bar{T}_s Température moyenne le jour de la s^e session de recharge en $^{\circ}C$

$\bar{S}l_s$ Ensoleillement moyen le jour de la s^e session de charge en kJ/m^2

$\hat{\theta}_{MAP}$ Estimation maximale a posteriori du paramètre du modèle θ

\hat{y}_s^{\min} Besoin minimal en énergie pour la recharge du VÉ à la s^e session de charge en considérant le niveau de satisfaction de l'utilisateur de η , en kWh

\hat{y}_s Estimation de l'énergie nécessaire à la recharge d'un VE lors de la s^e session de recharge η , en kWh

n nombre d'observations (sessions de recharge déjà réalisées)

Pr_s Précipitations moyennes le jour de la s^e session de recharge

wd_s Jour de la semaine correspondant à la s^e session de recharge

wk_s Numéro de la semaine correspondant à la s^e session de recharge

x_s Vecteur des variables d'entrée exogènes du modèle prédictif f

y_s Vecteur de la variable endogène historique du modèle prédictif f

θ_x Vecteurs des paramètres du modèle prédictif associés aux prédicteurs x_s

θ_y Vecteurs des paramètres du modèle prédictif associés aux prédicteurs y_s

F_1 Caractéristiques extraites de l'échantillon brut

F_2 Caractéristiques extraites de l'estimation de la densité spectrale de puissance (PSD) de Welch

F_3 Caractéristiques extraites de l'estimation de la densité multi-couches standard de Thomson

F_4 Écart-type de l'échantillon brut

F_5 Asymétrie de l'échantillon brut

- F_6 Sixième moment central de l'échantillon brut
- F_7 Écart type de l'approximation de la première résolution extrait de l'échantillon de mesure
- F_8 Écart type du détail de la première résolution extrait de l'échantillon de mesure
- F_9 Écart type de l'approximation de la deuxième résolution extrait de l'échantillon de mesure
- F_{10} Écart type du détail de la deuxième résolution extrait de l'échantillon de mesure
- F_{11} Écart type de l'approximation de la troisième résolution extrait de l'échantillon de mesure
- F_{12} Écart type du détail de la troisième résolution extrait de l'échantillon de mesure
- f Modèle mathématique pour la prévision de la demande d'énergie pour la recharge du VÉ
- Q_b Capacité nominale de la batterie en kWh
- SOC_k État de charge du pack de batterie à l'instant k
- t_s^{dep} Heure du débranchement du VÉ à la borne pour la s^e session de recharge
- t_s^{pi} Heure du branchement du VÉ à la borne pour la s^e session de recharge
- X Observations historiques des prédicteurs (entrées)
- y_s^{CC} Quantité d'énergie requise pour recharge le VÉ jusqu'à la fin de la phase courant constant (autour de 80%)
- y_l^{CV} Quantité d'énergie requise pour recharge le VÉ de la fin de la phase courant constant (autour de 80%) jusqu'à la charge complète
- Y Observations historiques de la demande d'énergie (sortie)

Chapitre 1 - Introduction

Cette thèse s'est concentré sur l'exploration de stratégies et d'algorithmes pour la planification intelligente de la recharge des véhicules électriques (VÉs) en milieu résidentiel. L'analyse englobe les perspectives des fournisseurs d'électricité, notamment Hydro-Québec¹, ainsi que celles des propriétaires de VÉs. Plus précisément, l'objectif de cette recherche est de proposer de nouvelles méthodes pour modéliser, caractériser et prédire les besoins énergétiques de recharge des VÉs, ainsi que leur durée de stationnement. Ces méthodes visent à élaborer des stratégies de planification de la recharge, générant des économies sur les coûts énergétiques et réduisant la demande agrégée d'électricité pendant les périodes de forte consommation. Tout cela se fait en prenant en compte les préférences de charge des propriétaires de VÉs. Ce chapitre présente une description du contexte de la recherche, de la problématique abordée, des objectifs et la méthodologie de recherche adoptée et enfin, les principales contributions.

1.1 Contexte général de la recherche

Le réchauffement climatique et l'épuisement projeté des ressources en combustibles fossiles posent des défis substantiels aux générations présentes et futures. En réponse à ces enjeux, les acteurs mondiaux s'engagent de plus en plus à accélérer la transition énergétique, visant à réduire l'empreinte carbone des sociétés. De nombreux pays développés ont élaboré des plans directeurs pour cette transition, avec des objectifs ambitieux à moyen et long terme en matière de réduction des émissions de gaz à effet de serre. Ces objectifs englobent divers secteurs, notamment la production d'électricité, ainsi que l'électrification des secteurs à forte consommation de produits pétroliers, comme le secteur du transport électrique. Soutenue par

1. Hydro-Québec est une entreprise publique responsable de la production, du transport et de la distribution de l'électricité au Québec.


des subventions politiques et des avancées technologiques, la part des productions décentralisées à partir de sources d'énergie propres et renouvelables dans le mix énergétique est en augmentation constante, tandis que le secteur du transport s'oriente de plus en plus vers l'électrification.

Face à la transformation structurelle en cours des réseaux de distribution et à la forte croissance attendue de la consommation d'électricité, principalement due à l'électrification massive du secteur du transport, les gestionnaires de réseaux doivent concevoir des solutions innovantes pour faire face à l'augmentation considérable de la demande d'énergie et de puissance ainsi qu'à la complexité de la gestion globale des réseaux. En effet, plusieurs études ont montré que la pénétration à grande échelle des véhicules électriques dans les réseaux de distribution pourrait avoir un impact significatif sur leur fonctionnement, notamment sur leur fiabilité et leur résilience [1]. Traditionnellement, les opérateurs de réseaux planifient les renforcements nécessaires des réseaux pour surmonter les problèmes futurs anticipés en ajoutant des transformateurs, des lignes de transmission et de la production [2], [3]. Cependant, ces solutions sont très coûteuses et ne sont pas toujours efficaces car les réseaux électriques sont parfois surdimensionnés pour faire face à des pointes de consommation qui se produisent moins de 5 % des jours de l'année [3]. Dans ce contexte, les gestionnaires de réseaux et la communauté scientifique ont réfléchi et introduit le concept de Réseau Électrique Intelligent (RÉI) (*Smart Grid*, en anglais), comme nouveau paradigme de gestion au début des années 1980 [4]. Dans ce paradigme, le client, en tant que consommateur final d'électricité, devient un acteur important dans la gestion globale. En effet, le RÉI est une vision de réseau électrique moderne qui intègre les nouvelles technologies pour permettre une communication bidirectionnelle entre les fournisseurs d'énergie et les consommateurs afin de faciliter la participation active de ces derniers. Dans ce nouveau paradigme, les clients sont encouragés à gérer leur consommation en temps réel en fonction des conditions du réseau. Plusieurs études ont montré qu'une participation plus active des clients à la gestion globale peut les aider à éviter les coûts inverses du renforcement de la capacité de production et du renforcement des lignes et des transformateurs pour supporter les projections de consommation de pointe élevée [3], [5]. La participation active du client en temps réel en réponse aux conditions du réseau est connu sous le nom populaire de Réponse à la Demande ou DR (*Demand Response* en anglais) [4].

Ce nouveau paradigme de Gestion Locale de Demande ou DSM (*Demand Side Management* en anglais) ouvre plusieurs opportunités pour les clients. Par exemple, en participant aux programmes de DR, les clients peuvent faire des économies monétaires sur leurs factures énergétiques en prenant des mesures qui réduisent leur consommation pendant certaines heures (de pointe) ou en déplaçant une grande partie de la consommation de certains usages vers les heures creuses. Le mécanisme des RÉIs repose essentiellement sur un mécanisme de prix de l'électricité dynamique que les gestionnaires de réseau doivent élaborer en fonction des conditions du réseau. Ce signal de prix peut être proposer aux clients en temps réel, plusieurs en avance. Il peut être aussi sous forme de signaux d'incitation monétaires ou de transaction, voire des alertes, pendant certaines périodes critiques du fonctionnement du réseau. En retour, les clients sont appeler à moduler leur consommation en réponse à ces signaux notamment en contrôlant certaines charges électriques flexibles grâce à des contrôleurs intelligents [6]. Ainsi, les VÉs représentent une grande opportunité pour les RÉIs en raison du potentiel de flexibilité de leur demande énergétique, leur puissance de charge relativement élevé et de leur capacité de stockage d'énergie.

1.2 Historique et statistiques de l'évolution du marché des véhicules électriques

Les véhicules électriques personnels sont relativement nouveaux sur les routes. En effet, leur expansion a été marquée par un développement accéléré depuis l'établissement de l'Initiative pour les VÉs (ou EVI, Electric Vehicles Initiative en anglais) en 2009. Cette initiative, un forum politique multigouvernemental créé lors de la conférence ministérielle sur l'énergie propre (connue sous le nom de CEM, Clean Energy Ministerial en anglais), a pour objectif de favoriser le déploiement des VÉs dans le monde entier [7]. Alors que leur nombre était encore limité à quelques dizaines de milliers à l'échelle mondiale en 2010, la population de VÉs a rapidement augmenté pour dépasser les 16 millions au cours de la décennie suivante. Cette croissance s'est caractérisée par une trajectoire quasi exponentielle, comme en témoigne la courbe de la figure 1-1. En 2021, près de 10 % des ventes mondiales de voitures correspondaient à des modèles électriques, et dans certains pays, ce pourcentage atteignait même 70 à 86 %, notamment en Suède et en Norvège, deux pays leaders dans la transition énergétique du secteur de la mobilité [8], [9]. Par ailleurs, l'Agence internationale de l'énergie prévoit



PHEV : véhicule hybride rechargeable (Plug-in Hybrid Electric Vehicle en anglais).

BEV : véhicule électrique à batterie (Battery Electric Vehicle en anglais en anglais).

FIGURE 1-1 Stock mondial de VÉs entre 2010 et 2021 [8].

qu'environ 20 % des ventes mondiales de véhicules en 2030 seront des modèles électriques, incluant à la fois les véhicule hybride rechargeable (PHEV, *Plug-in Hybrid Electric Vehicle* en anglais) et les véhicule électrique à batterie (BEV, *Battery Electric Vehicle* en anglais en anglais). Cette projection correspond aux politiques actuels et est reflétée dans le scénario de politiques déclarées [8]. Si cette prévision se réalise, cela pourrait multiplier le parc automobile par un facteur de 11 par rapport aux niveaux actuels, portant ainsi le nombre total de véhicules électriques à 200 millions [8].

La figure 1-2 présente la part historique et la part visée de VÉs dans les ventes de véhicules de passagers neufs pour plusieurs pays leaders de la mobilité électrique. On peut noter que la plupart de ces pays visent une part de 100 % des ventes de VÉs (y compris les véhicules électriques à pile à combustible) d'ici 2050. Alors que certains leaders comme la Norvège visent ce taux de pénétration à l'horizon 2025 ou 2035 pour le Canada.

La pénétration progressive du marché par les technologies de VÉs entraînera des changements substantiels dans la composition et la taille du parc automobile nord-américain d'ici 2050. En effet, plusieurs études prévoient que la part des VÉs dans le pack de véhicules variera de 15 % à 44 % d'ici 2030, comparativement à 41 % à 88 % d'ici 2050, comme le montre la figure 1-3. La proportion des VÉs sur les ventes au Canada s'élevait à 5,2 % en 2021. Le




FIGURE 1-2 Parts historiques et ciblées de VÉs dans les ventes de véhicules particuliers neufs par marchés [9].

Canada a les objectifs parmi les plus ambitieuses avec un objectif de 20 % de nouvelles ventes de véhicules zéro émission (VZE)² à l'horizon 2026, 60 % des ventes en 2030 et 100 % des ventes d'ici 2035 [10].

Grâce à ses tarifs d'électricité résidentiels, qui sont parmi les plus bas d'Amérique du Nord, ainsi qu'aux ambitions et aux incitations du gouvernement, le Québec est aujourd'hui la province qui enregistre la plus grande part des ventes totales de VÉs au Canada (un peu plus de 40 % des VÉs enregistrés) [12], [13]. En septembre 2022, Le parc de VÉs Québec comptait , un peu plus de 160 000 véhicules électriques ou hybrides rechargeables [14], [15]. Cependant, le gouvernement vise à augmenter ce nombre à 1,6 million d'ici 2030, et à 5,2 millions de VÉs à l'horizon 2040 avec comme ambition d'atteindre 100 % le nombre de VZE qui devrait être vendu à l'horizon 2035 et l'année à partir de laquelle la vente de véhicules neufs à essence sera interdite au Québec [16].

2. Les véhicules zéro émission incluent les véhicules électriques à batterie, véhicules hybrides électriques rechargeables et les véhicules à pile à hydrogène selon la désignation du gouvernement fédéral

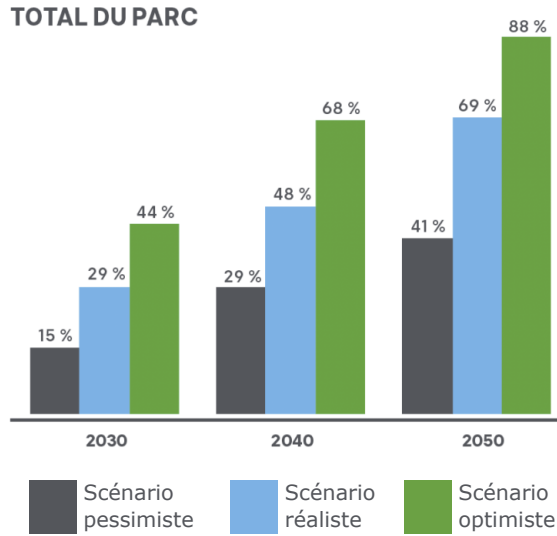


FIGURE 1-3 Évolution de la part des véhicules électriques et intelligents dans le parc Nord-Américain [11]

1.3 Impact et opportunités de la recharge des véhicules électriques pour le réseau électrique

En tant que nouvelle catégorie émergente de charges électriques, les VÉs occupent une place de plus en plus prépondérante parmi les charges électriques résidentielles, en particulier en ce qui concerne leur puissance électrique. Avec la progression significative de l'électrification dans le secteur des transports, les réseaux électriques de distribution sont confrontés à l'intégration croissante des VÉs à court et moyen terme. À l'avenir, l'augmentation substantielle du nombre de VÉs pourrait entraîner une augmentation considérable des pics de puissance dans les réseaux électriques, suscitant ainsi de l'incertitude et de l'instabilité dans leur fonctionnement en l'absence de coordination de la recharge des VÉs [17]-[21]. En effet, des études ont révélé que les utilisateurs ont tendance à brancher leurs VÉs en rentrant du travail le soir, ce qui coïncide avec la période de pic de consommation quotidienne en soirée lorsque l'activité domestique est plus élevée [21].

Au Québec, les pointes hivernales représentent un des plus grands défis pour le fournisseur d'électricité (Hydro-Québec). En effet, au Québec les pointes maximales de la demande de

l'électricité se produisent en hiver dû au fonctionnement en plein régime des systèmes de chauffage³, qui sont principalement électriques. Ces pics élevés de consommation créent une forte sollicitation du réseau électrique et génèrent des coûts supplémentaires pour le gestionnaire du réseau [22]. La Figure 1-4 présente l'évolution des pointes de consommation hivernales et la capacité maximale disponible du réseau électrique pour répondre à la demande de pointe pour la période 2010 à 2019 [23]-[32]. Cette figure montre clairement la problématique des pointes de consommation hivernales où la demande en électricité a dépassé de façon récurrente la capacité installée du réseau d'Hydro-Québec au cours des dernières années. Pour répondre à la demande de pointe dans ces situations, Hydro-Québec achète généralement de l'électricité à court terme sur les marchés voisins à des prix très élevés [33]. La solution à moyen terme consiste à renforcer la capacité du réseau, ce qui nécessite des investissements très importants. En plus du coût de gestion très élevé, les pointes créent également beaucoup de stress sur le réseau (ligne de transmission et transformateurs) ce qui augmente considérablement le risque d'instabilité du réseau et de coupures d'électricité.




FIGURE 1-4 Puissance installée par Hydro-Québec et besoins de puissance en période de pointe [23]-[32].

En temps que nouveau type de charge électrique émergeant dans le secteur résidentiel, la recharge de millions de véhicules peut accroître considérablement les problèmes actuels liés aux pointes de consommation et donc la sécurité et la fiabilité de l'approvisionnement en

3. Au Québec, les systèmes de chauffage et de climatisation et le chauffe-eau représentent respectivement environ 54% et 20% de la consommation résidentielle.

électricité. Des études faites par Hydro-Québec ont montré que la demande de pointe actuelle pourrait augmenter de plus de 2000 MW, soit plus de 6 % d'augmentation (voir la figure 1-5) si la cible de réduction de 40 % de la consommation de produits pétroliers (cible du gouvernement) se traduisait par un remplacement de 40 % des véhicules à essence par des véhicules électriques (VÉ) [3]. Ces chiffres correspondent à environ deux millions de VÉ⁴ qui se chargeraient durant les jours les plus froids selon l'estimation du profil de recharge établi par Hydro-Québec. D'après l'étude, sans changement d'habitude, ni gestion plus active de la demande d'électricité, c'est un projet plus grand que La Romaine, estimé à 6,5 milliards de dollars d'investissement pour 1550 MW qu'il faudrait construire au Québec pour répondre à cette demande [3]. De toute évidence, ces solutions sont très coûteuses et l'ajout de centrales de production pour répondre aux demandes de pointe n'est pas toujours une solution efficace car les réseaux électriques se trouvent parfois trop être surdimensionnés pour faire face à des pointes de consommation qui se produisent moins de 5% des jours de l'année [3], [34]. Une gestion intelligente de leur période de recharge est alors cruciale pour un fonctionnement optimal des réseaux électriques. La participation plus active des utilisateurs finaux d'électricité à la gestion globale du réseau est l'une des voies privilégiées par les fournisseurs d'électricité tels qu'Hydro-Québec pour améliorer l'efficacité du réseau électrique et éviter les coûts élevés du renforcement de la capacité de production et du renforcement des lignes et des transformateurs pour soutenir les projections de consommation de pointe élevée.

Par ailleurs, la communauté scientifique et les fournisseurs d'électricité ont étudié et proposé plusieurs stratégies dans le contexte des REIs pour améliorer l'efficacité globale du système électrique par le biais de programmes de gestion de la demande. L'objectif visé par ces programmes est d'aplatir le plus possible la courbe de la demande agrégée en travers des mécanismes d'incitation ou en modulant le signal du prix de telle sorte à offrir des prix élevés pendant les heures de pointe et des prix plus bas pendant des heures creuses. Ces programmes sont une partie intégrante dans un cadre plus général du concept de gestion locale de la demande (DSM) introduit par les utilités et la communauté scientifique dans les années 80 afin de favoriser et inciter la participation des clients résidentiels dans la gestion globale du réseau électrique [4]. Dans ce cadre, les objectifs généraux de forme de la courbe

4. coïncide en quelque sorte avec les objectifs 2030 du Québec et 40% des objectifs 2050




FIGURE 1-5 Demande horaire moyenne d'électricité au Québec, ainsi que pour les journées de plus forte consommation et de plus faible consommation en 2017 [3].

de charge suivants ont été définis : (1) écrêtage de pic (« *peak clipping* »), (2) conservation stratégique (« *strategic conservation*»), (3) remplissage de vallée (« *valley filling* »), (4) croissance de charge stratégique (« *strategic load growth* »), (5) déplacement de la charge (« *load shifting* ») et (6) forme de charge flexible (« *flexible load shape*») [35]. Celles-ci sont illustrées à la figure 1-6. Plusieurs de ces objectifs ont déjà été mis en œuvre et promus




FIGURE 1-6 Les six grandes catégories «d'objectifs de forme» de la courbe de charge [36]

par les fournisseurs et atteignent progressivement leurs limites en termes d'amélioration de l'efficacité du système, comme les solutions liées au délestage (objectif 1), à l'amélioration de l'efficacité énergétique des équipements (objectif 2), à l'électrification de certains usages pour augmenter la consommation en heures creuses (objectif 3), et à la croissance stratégique de la


charge (objectif 4). En revanche, les solutions liées au déplacement de la charge (usages de l'électricité) (objectif 5) et à la charge flexible (objectif 6) sont les objectifs de forme les moins exploités à ce jour par les fournisseurs d'électricité et ouvrent une grande opportunité pour le contrôle de la recharge de larges flottes de véhicules électriques. En effet, bien que les VÉs peuvent être vus comme une charge électrique supplémentaire importante, ils représentent également un atout majeur pour la gestion de la demande en raison de la flexibilité de la période de charge et de leur potentiel de stockage. En effet, les véhicules figurent parmi les charges électriques les plus flexibles du secteur résidentiel en raison de la durée élevée de stationnement en soirée, de la capacité de la batterie et des besoins en énergie pour les déplacements quotidiens des utilisateurs. En exploitant cette flexibilité de la demande des VÉs, leur recharge peut être planifiée de telle manière à éviter la recharge pendant les périodes de pointe. Mieux encore, leur grande capacité de la batterie peut être mise à profit pour supporter le réseau pendant les périodes de pointes, étant donné leurs besoins énergétiques pour les trajets quotidiens, qui est souvent faible pour une grande partie des utilisateurs [37]. À cet égard, la communauté scientifique a accordé un intérêt particulier au contrôle de la recharge et proposé plusieurs stratégies de contrôle pour permettre l'exploitation effective de leur potentiel pour aider à la fois à améliorer les fonctions du réseau tout en minimisant la facture énergétique des utilisateurs [38]-[41]. La question de la recharge des VÉs a été examinée à des fins diverses (réduction des pointes de consommation, fourniture de service de régulation au réseau, etc.), et à différentes échelles, de la gestion individuelle à la gestion de flotte de VÉs. Cependant, plusieurs défis restent à relever pour que ces solutions soient effectivement applicables dans la vie réelle. Ces défis sont principalement liés à la présence de sources d'incertitude inhérentes qui n'ont pas été suffisamment prises en compte.

1.4 Problématique de recherche

La gestion intelligente de la recharge des VÉs implique la prise en compte de sources d'informations diverses sujettes à des incertitudes. Les paramètres clés liés aux comportements des utilisateurs, tels que les heures d'arrivée, la durée de stationnement et les préférences de recharge, demeurent inconnus pour le contrôleur jusqu'à leur réalisation, sauf s'ils sont préalablement spécifiés par les propriétaires des VÉs. De plus, des facteurs externes tels que

la température ambiante et la dégradation de la batterie peuvent influencer les paramètres associés aux VÉs, notamment l'état de charge, le profil de puissance de charge et la capacité disponible de la batterie. En outre, le contrôleur peut être confronté à un manque d'accès direct à certaines informations clés en raison de problèmes de communication ou même en raison d'un déficit d'infrastructure appropriée, comme l'absence d'accès direct à l'état de charge de la batterie pour une grande majorité de VÉs sur le marché. Malgré la disponibilité de divers protocoles, comme le protocole ISO 15118, qui a pour rôle de faciliter ce type d'échanges d'informations entre les VÉs et les bornes de recharge, ces protocoles n'ont pas encore été mis en œuvre par les fabricants de VÉs. Par ailleurs, avec une variété de modèles de VÉs et de bornes de recharge sur le marché (voir la Figure 1-7), le défi de l'interopérabilité entre différents sous-systèmes émerge comme une préoccupation majeure.

Plus de 20 modèles de VÉ disponibles aux États-Unis



Plus de 45 chargeurs de niveau 2 différents disponibles aux États-Unis

FIGURE 1-7 Illustration du problème l'interopérabilité dans la charge des VÉs (tirée du projet de recherche en coopération sur la communication *VÉ-Infrastructure-système électrique* [42])

Pour parvenir à une gestion optimale de la charge des VÉs, il est essentiel de relever les défis liés à la prise de décision en présence d'incertitudes et d'informations partielles, ce qui forme le cœur de la problématique centrale abordée dans cette thèse. Cette recherche se concentre sur trois problématiques clés : l'identification automatique des VÉs, la caractérisation et l'estimation de leur besoins de recharge en fonction du type de véhicule, ainsi que l'optimisation des séquences des opérations de recharge en contexte d'incertitude en considérant les habitudes et le confort de l'utilisateur. La littérature a exploré diverses approches

pour identifier les VÉs, notamment la technologie d'identification par radiofréquence RFID (*radio-frequency identification* en anglais) basée sur des cartes magnétiques, qui requiert l'intervention régulière des utilisateurs. Dans le but de minimiser cette intervention et d'optimiser l'utilisation de l'infrastructure existante, cette recherche examine l'interaction entre les VÉs et les bornes de recharge pour développer des solutions permettant d'identifier les véhicules en se basant sur des caractéristiques distinctives dans les signaux de puissance électrique mesurée lors de la recharge. L'identification des VÉs à partir de mesures électriques présente des défis algorithmiques liés à la similitude potentielle des caractéristiques de charge de différents VÉs. En ce qui concerne la caractérisation de la demande énergétique de recharge et la prise de décision en situation d'incertitude, les avancées en matière d'intelligence artificielle et d'optimisation stochastique ont été reconnues comme l'une des voies les plus prometteuses pour relever les défis du monde réel.

La littérature a étudié des approches statistiques et d'apprentissage automatique pour modéliser et prédire les besoins énergétiques des VÉs tout en prenant en compte les habitudes stochastiques de stationnement. Ces modèles sont souvent intégrés à des mécanismes de prise de décision basés sur l'optimisation stochastique. Cependant, les défis liés à la complexité et à la prise en compte de tous les facteurs susmentionnés restent à surmonter afin de tirer pleinement parti de la flexibilité potentielle des VÉs, une étape cruciale pour faciliter l'intégration massive de millions de VÉs dans les réseaux électriques.

1.5 Objectifs et contributions

1.5.1 Objectifs

L'objectif principal de cette thèse consiste à proposer un algorithme de gestion avancé capable de gérer la planification de la recharge des VÉ en tenant compte des sources d'incertitude associées aux paramètres clés. Ce travail de recherche vise à proposer des solutions efficaces permettant de réduire la facture énergétique de la recharge pour les propriétaires de VÉ et d'améliorer les fonctions du réseau électrique sans compromettre les préférences de charge des propriétaires, tout en minimisant l'intervention humaine dans le processus de prise de décision. Les objectifs spécifiques de ce travail sont définis comme suit :

- Proposition d'un algorithme de détection et d'identification et de reconnaissance automatique des VÉs au moment de leur branchement.
- Modélisation et caractérisation de la demande de recharge des VÉs par une approche stochastique ;
- Proposition d'un algorithme de contrôle adaptatif basé sur les modèles stochastiques développés précédemment, les préférences de charge de l'utilisateur et le signal de réponse à la demande (prix de l'électricité) ;
- Adaptation des stratégies de gestion aux spécificités du Québec (conditions climatiques).

1.5.2 Contributions

Les principales contributions de cette thèse peuvent être détaillées en termes de propositions suivantes :

- Une approche de détection et de reconnaissance automatique des VÉs individuels partageant les bornes de recharge. Cette proposition s'appuie sur des techniques de classification supervisée basées sur des réseaux neuronaux et des machines à vecteurs de support (*support vecteur machine* en anglais), pour identifier le VÉ à partir des données de courant de charge. Elle répond en partie au problème de minimisation du rôle des utilisateurs dans la fourniture d'informations et facilite également le développement de stratégies de contrôle basées sur des modèles individuels de chaque VÉ ;
- Un modèle prédictif capable d'anticiper les besoins énergétiques des VÉs en fonction de leurs habitudes de recharge aux bornes de recharge locales. Cette proposition s'appuie sur des techniques de prévision basées sur l'inférence bayésienne pour prédire la demande énergétique pour la recharge des VÉs à l'aide de quelques variables indépendantes. Ce modèle présente l'avantage de fournir également un moyen de quantifier l'incertitude du modèle de prévision et de permettre ainsi la mise en œuvre d'un contrôle basé sur le risque. L'utilisation de ce modèle répond d'une part au besoin d'anticipation de la demande énergétique des VÉ pour une meilleure planification des ressources énergétiques partagées entre les VÉs ou entre les VÉs et d'autres charges électriques. D'autre part, il répond partiellement au problème d'accès ou de communication pour

l'obtention de certaines informations clés telles que l'état de charge de la batterie, tout en contribuant à minimiser le rôle des utilisateurs dans la fourniture des informations ;

- Un schéma d'optimisation stochastique capable de proposer un horizon optimal pour le contrôle de la charge des VÉs et les actions de contrôle en tenant compte d'une valeur monétaire pour l'insatisfaction du client liée à l'état énergétique final et au prix de l'électricité. Ce schéma est basé sur la simulation de Monte Carlo et le contrôle robuste basé sur le risque. Le processus de décision de planification de la recharge prend en compte le caractère stochastique de certains paramètres tels que l'heure de départ, l'heure d'arrivée, la demande d'énergie et le profil de puissance en considérant l'incertitude associée à ces paramètres ;
- Une conception de contrôleur pratique pour la recharge des VÉs capable d'effectuer la planification et le contrôle de la charge en ligne avec un minimum d'informations et d'intervention humaine tout en tenant compte de plusieurs défis du monde réel, notamment les sources d'incertitude liées au manque d'accès à certains paramètres critiques et la non-linéarité du profil de la puissance de charge.

1.6 Méthodologie adoptée

Afin de répondre à la problématique abordée, la méthodologie présentée dans la figure 1-8 a été adoptée. La première étape a consisté à faire une brève revue de la littérature scientifique afin d'identifier et de définir le problème à traiter durant la thèse. Par la suite, une revue détaillée de la littérature a été réalisée afin d'acquérir une compréhension approfondie des concepts liés à la problématique de la planification intelligente de la recharge des VÉs. Cette étape nous a permis d'acquérir une compréhension plus détaillée des travaux déjà réalisés dans le domaine de recherche, des différentes méthodes et techniques utilisées ainsi que les limites, contraintes et difficultés associées aux solutions proposées. Ensuite, des améliorations, des ajustements et de nouvelles approches et méthodes ont été graduellement introduits afin de répondre aux critères, aux exigences et aux spécificités du problème traité. Enfin, la dernière étape a consisté à évaluer l'efficacité des propositions par simulation en utilisant des données réelles de profil de recharge. Les résultats sont comparés aux techniques existantes dans la

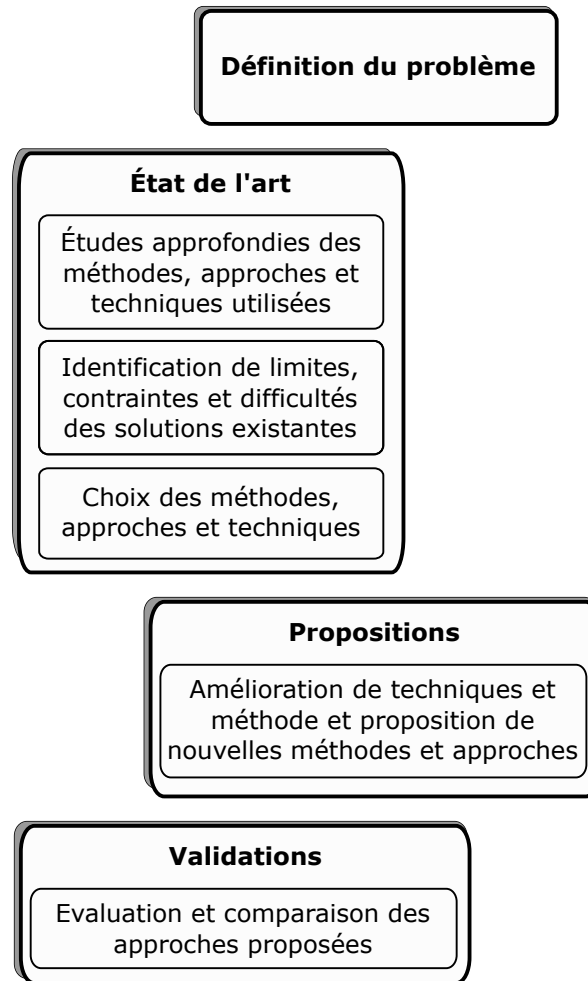


FIGURE 1-8 Méthodologie de recherche adoptée.

littérature. Les données réelles utilisées ont été obtenues à partir de campagnes de mesures que nous avons effectuées au niveau des bornes de recharge locales de l'Université du Québec à Trois-Rivières au début de la thèse.

Dans ce qui suit, les étapes de la méthodologie sont détaillées en fonction de chaque proposition, décrite dans la section précédente.

- **Détection et reconnaissance automatique des VÉs** : Une étude exploratoire nous a permis d'identifier une limite des approches existantes en lien à la gestion d'un ensemble de VÉs partageant des bornes de recharge. Compte tenu de la nécessité de construire des modèles individuels des habitudes et préférences de chaque VÉ et des défis à relever pour minimiser l'invention humaine dans la fourniture d'informations essentielles, nous avons exploré différentes solutions pour détecter les moments de branchement et

identifier le VÉ connecté afin de faciliter la création de modèles stochastiques liés au comportement de charge de chaque utilisateur. Cette analyse nous a permis de choisir une approche basée sur l'infrastructure existante et l'exploitation des données de mesure du courant et de la tension, et de développer des techniques avancées pour la détection et la reconnaissance automatique des VÉs. Nous avons exploré deux des techniques de classification supervisée les plus populaires dans la littérature, à savoir les réseaux de neurones et les machines à vecteurs de support.

- Modélisation et anticipation de la demande de recharge des VÉs : Face aux défis de la minimisation l'intervention humaine (récurrente) dans la fourniture d'informations essentielles, nous avons proposé des modèle stochastiques permettant de caractériser le comportement de charges des VÉs en terme de besoin énergétique et la durée de stationnement. Un modèle prédictif basé sur l'inférence bayésienne a été développé. Ce modèle vise à aider le contrôleur de charge à mieux coordonner la planification de la recharge de plusieurs VÉs en fonction des habitudes de recharge de chaque VÉ à travers les données historiques des sessions de charge. Ce modèle peut également servir d'outil essentiel au contrôleur pour estimer les besoins énergétiques des VÉs dans les situations où le contrôleur ne peut pas obtenir directement l'information du SOC de la batterie en raison, par exemple, d'un manque de communication directe avec le VÉ ou de problèmes de défaillance de communication. Quant aux paramètres liés aux habitudes de stationnement des VÉs, c'est-à-dire les heures de branchement et de débranchement, ils ont été modélisés par une distribution de probabilité avec une approche non paramétrique basée sur l'estimation de la densité par noyau (*kernel density estimation* en anglais) et une technique de clustering. Cette approche a été introduite pour simplifier la complexité de calcul soulevée par certaines méthodes plus populaires dans la littérature.
- Proposition d'un algorithme de planification de la recharge des VÉs : Cette partie du travail est en quelque sorte la concrétisation des travaux effectués dans les étapes précédentes afin proposer d'un algorithme de planification intelligent qui tient compte des habitudes de charge de chaque VÉ, des préférences de charge des utilisateurs et le signal de réponse à la demande (prix de l'électricité, signal de coordination);

L'algorithme de planification tire partie de l'optimisation stochastique u contrôle

- Finalement, la performance des méthodes proposées est analysée dans un environnement simulé en utilisant données réelles session de recharge de VÉs collectées sur des bornes de recharge locale à l'aide d'un banc d'acquisition de données.

1.7 Infrastructure de recherche

Dans le cadre de cette thèse, nous avons réalisé des campagnes de mesures sur quelques bornes de recharge de l'Université du Québec à Trois-Rivières (UQTR) au début la thèse afin d'obtenir des informations utiles pour le développement et la validation de différentes propositions. L'ensemble des ressources informatiques (ordinateurs, licences logicielles, etc.) et électroniques nécessaires pour le développement du système de mesurage et pour les études de modélisation et de simulation ont été fournies par le Laboratoire d'Innovation et de Recherche en Énergie Intelligente (LIREI) de l'Institut de Recherche sur l'Hydrogène (IRH) et par le Département de Génie Électrique et Génie Informatique de l'UQTR.

1.8 Structure de la thèse

Cette thèse est présentée en 5 chapitres, la suite du document est organisée ainsi :

- **Chapitre 2 :** Ce chapitre présente l'état de l'art général du problème de la planification de la recharge des VÉs, les différentes approches et stratégies utilisées dans la littérature ainsi que le potentiel et les limites des méthodes et techniques utilisées.
- **Chapitre 3 :** Ce chapitre présente en détail les travaux réalisés pour atteindre les différents objectifs de la thèse. De plus, il comprend une étude de l'état de la technique correspondant à chaque problème abordé, ainsi il décrit en détail la formulation mathématique de la méthode proposée. Dans ce chapitre, nous présentons dans un premier temps les modèles développés pour la détection et la reconnaissance automatique des VÉ ainsi que la caractérisation et l'anticipation de leur demande de charge (besoin en énergie et temps de stationnement). La réalisation de ces travaux nous a permis d'atteindre les deux premiers objectifs de la thèse. Par la suite, nous présentons l'approche proposée pour la planification de la recharge des VÉs basée sur l'optimisation stochastique et les

modèles stochastiques développés précédemment. La réalisation de ce travail a permis d'atteindre les deux derniers objectifs de la thèse.

- **Chapitre 4 :** Dans ce chapitre, nous présentons les résultats de l'évaluation des méthodes et stratégies proposées. Ces évaluations sont basées sur des données réelles de recharge de VÉs collectées sur des bornes de recharge locales. De plus, une étude comparative est fournie pour évaluer la performance des méthodes et approches proposées avec d'autres méthodes ou approches bien connues dans la littérature.
- **Chapitre 5 :** Enfin, nous présentons la conclusion, les recommandations et les travaux futurs pour améliorer les différentes propositions pour la suite de cette thèse.

Chapitre 2 - État de l'art

Ce chapitre présente un aperçu des travaux connexes sur la planification intelligente de la recharge des véhicules électriques rechargeables. Dans un premier temps, nous ferons un tour d'horizon des différentes stratégies et approches de gestion de la recharge des véhicules électriques dans la littérature. Une discussion détaillée est présentée à la fois pour la planification individuelle de la recharge des VÉs et pour la planification coordonnée d'un ensemble de VÉs. Ensuite, nous présentons les différentes techniques d'optimisation mathématique utilisées pour résoudre le problème de la recharge des VÉs. Enfin, la dernière section résume les limites des efforts déployés pour gérer la recharge des véhicules électriques dans le milieu résidentiel.

L'objectif recherché par l'opérateur du réseau

2.1 Concept de gestion de la recharge des VÉs

En raison de l'impact que la charge non coordonnée de millions de véhicules peut avoir sur les réseaux électriques du fait de leur puissance de charge relativement élevée, la gestion intelligente de leur charge est devenue un axe de recherche important au cours des deux dernières décennies. Les différentes études visent à mettre en exergue les opportunités que représentent cette nouvelle charge électrique pour les réseaux intelligents en raison de la flexibilité de leur période de charge et de leur potentiel de stockage [43].

Un des enjeux principaux de la question de la charge des VÉs est la satisfaction des préférences de charge des utilisateurs en termes d'état de charge de la batterie au départ et à la nature dynamique de plusieurs paramètres, notamment le signal de réponse à la demande, le SOC et le profil de la puissance de charge. Compte tenu de ces défis, la question de la planification de la recharge des VÉs est généralement formulée dans la littérature comme un problème d'optimisation multiobjectif et multicritère. L'objectif des différents problèmes

d'optimisation est, entre autres, de minimiser le coût énergétique de la recharge pour les propriétaires de VÉ et de fournir des services auxiliaires au réseau, tout en tenant compte des préférences de charge du propriétaire du VÉ.

La tarification dynamique du prix de l'électricité (signal de DR), l'énergie transactionnelle et les incitations basées sur le contrôle direct de la charge sont quelques-uns des mécanismes proposés pour promouvoir l'intégration réussie de millions de VE dans les réseaux de distribution. La gestion de la recharge des VÉs a été largement abordé dans le contexte du signal de DR, en tant d'élément important pour tirer parti de la flexibilité de la demande de recharge des VÉs. Ce signal est modulé par l'opérateur du réseau (OR) pour tenir compte de l'intérêt du réseau, par exemple en offrant des prix plus bas pendant les heures creuses et des prix plus élevés pendant les périodes de pointe ou de stress du réseau pour minimiser les coûts d'opération et les contraintes nécessitant un renforcement de la capacité du réseau. L'objectif recherché par l'opérateur du réseau à travers ce signal de prix est d'inciter les clients à modifier leur comportement de consommation par le contrôle de charges flexibles telles que les VÉs. Dans certaines situations, ce signal peut simplement être une consigne, communiquée en temps réel, incitant les clients à réduire leur consommation d'électricité en échange d'un avantage économique. La figure 2-1 illustre plusieurs types de signaux de DR qui peuvent être implémentés être mis en œuvre par les ORs dans le contexte des REIs.

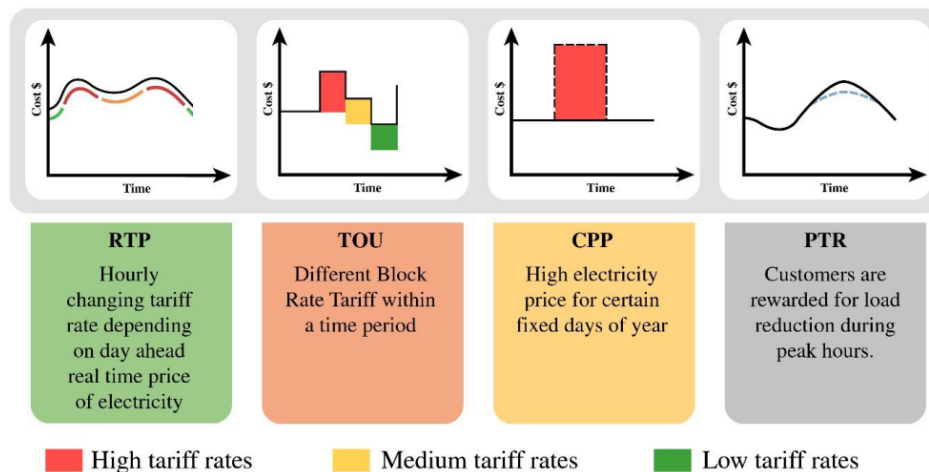


FIGURE 2-1 Représentation des différents systèmes de tarification de l'électricité [5].

Selon la tarification appliqué par l'OR, le signal de DR peut être communiqué aux contrôleurs de charge en temps réel avec un pas de mise à jour compris entre 10 minutes à 1 heure,

ou communiqué plusieurs heures à l'avance avec une mise à jour sur un horizon de 24h. Sur la base de cette information, le contrôleur de charge doit alors planifier la charge du VÉ en fonction des préférences de charge de l'utilisateur de manière à minimiser le coût énergétique de la recharge en exploitant la flexibilité de la charge du VÉ.

Compte tenu du grand intérêt que portent les ORs à la question de la flexibilité de la demande d'électricité, l'émergence de nouveaux acteurs utilisant les nouvelles technologies pour fournir des services d'équilibrage du réseau se dessine, et parmi ces acteurs on peut citer l'agrégateur de VÉ (*EV aggregators* en anglais). En effet, chaque VÉ a une batterie, donc lorsqu'on peut regrouper plusieurs milliers de VÉs, on dispose d'un énorme réservoir de flexibilité. L'agrégateur de VÉ agit ainsi comme une interface entre l'OR et les VÉs pour fournir des services auxiliaires au réseau en exploitant la flexibilité de la demande de recharge des VÉs. En contrepartie, l'agrégateur de VÉ négocie des tarifs préférentiels avec l'OR en fonction de l'amélioration potentielle des fonctions du réseau liée à l'optimisation des plans de recharge de tous les VÉs.

La littérature fournit une variété d'études sur la planification de la charge des VÉs dans le contexte des réseaux intelligents. Ce sujet a été examiné pour différents objectifs de contrôle tels que la minimisation des coûts énergétiques sur la base d'un prix dynamique [44], [45], la fourniture de services auxiliaires à travers le contrôle d'un parc de VÉs [43], [46]-[51], la décision d'investissement dans le secteur des transports [52] etc. Les services auxiliaires potentielles étudiés sont la modulation de la courbe de charge (notamment la réduction de la pointe), la régulation de la tension, la régulation du facteur de puissance, etc.

2.2 Architecture de contrôle

Dans le contexte des REIs, les VÉs peuvent contribuer de deux manières à la gestion globale du réseau, à savoir par la recharge non coordonnée entre les VÉs individuels et la recharge coordonnée d'un ensemble de VÉs.

Recharge non coordonnée

Dans cette architecture, les contrôleurs de charge individuels (CRs) communiquent directement avec l'opérateur de réseau via le signal de DR pour planifier la recharge des VÉs. Dans ce

scénario de recharge, le CR planifie la recharge du VÉ en tenant compte principalement des intérêts du client (minimisation des coûts énergétiques, préférences de charge, etc.), les intérêts de l'OR étant supposés se refléter dans le signal de DR. Cependant, un des problème majeur de cette architecture de recharge est que tous les clients reçoivent le même signal de DR, de ce fait tous les CRs auront tendance à déplacer la consommation des charges flexibles, y compris celle du VÉ, pour commencer à charger à peu près au même moment au début de la période creuse [53]. Cet effet est connu dans la littérature sous le nom de " pics de rebond " (*rebound peaks* en anglais) [54]. Il a été souligné dans la littérature que la recharge non coordonnée de milliers de VÉs basés sur un signal commun de prix d'électricité peut avoir des effets négatifs sur le réseau de distribution, notamment à cause de ces " pics de rebond ". De ce fait, les fournisseurs d'électricité et la communauté scientifique ont réfléchi à un nouveau mécanisme de marché d'électricité basée sur l'énergie transactionnelle [55], [56] ou des prix différées par groupe de client [54]. La Figure 2-2 illustre une exemple de cadre de planification de la recharge d'un VÉ dans le contexte de la gestion de la demande globale d'une maison individuelle [57]. Dans ce cadre de gestion, la recharge du VÉ et le contrôle de l'usage d'autres charges flexibles a été effectué dans le signal de DR a été considérée en utilisant un signal de prix d'électricité dynamique et le signal de prix basé sur la période d'usage TOU.

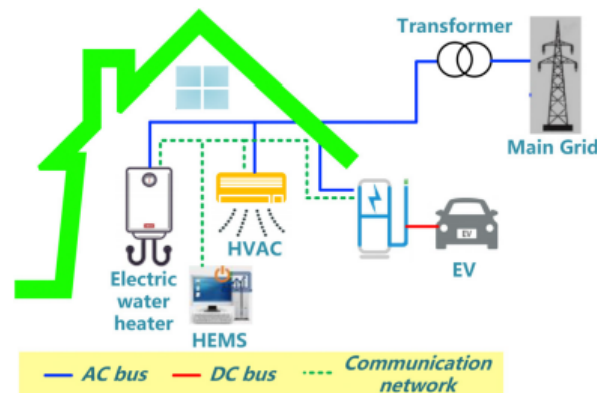


FIGURE 2-2 Recharge d'un véhicule électriques dans le cadre de la gestion de la demande d'une maison individuelle [57].

Recharge coordonnée de plusieurs VÉs

Le contrôle coordonné d'un ensemble de VÉs a été suggérer par la communauté scientifique et les opérateurs de réseaux pour permettre de mieux exploiter le potentiel de flexibilité de la

demande des VÉs pour fournir des services auxiliaires au réseau. Ces services peuvent être la réduction des pics de consommation au niveau du transformateur de distribution [47], [49]-[51], la fourniture de services de régulation tels que la régulation de la tension, la minimisation des pertes de puissance dans les réseaux, la minimisation des surcharges des transformateurs. En contre partie, l'opérateur de réseau offre aux agents participant aux services auxiliaires la possibilité de minimiser leur coût énergétique grâce à des profils de prix préférentiels de l'électricité.

Les algorithmes utilisés dans le cadre de la coordination de la recharge d'un ensemble de VÉs se répartissent en trois catégories selon l'architecture de contrôle, qui sont :

- *Architecture de contrôle centralisé* : Dans cette architecture également appelée architecture de contrôle directe, une seule entité (contrôleur) résout le problème d'optimisation globale pour planifier la recharge de tous les VÉs comme le montre la Figure 2-3. Elle donne cependant un meilleur résultat en termes de convergence et solutions du problème d'optimisation lorsque le nombre de véhicule n'est pas très élevé. Cependant, la complexité de calcul est plus élevée pour ce cadre lorsqu'un grand nombre de VÉs sont concernés par ce modèle, car il implique une grande quantité de données [29], de variables et de contraintes pour ordonnancer la charge. Ainsi, cette approche est considérée que non pratique en raison de la complexité de calcul du système avec des VÉs à grande échelle et le respect de la vie privée des utilisateurs [58]. Ces approches ont été utilisées dans les références [44], [59]. voir [43] pour la liste des travaux
- *Architecture de contrôle décentralisé ou distribué* : Dans cette architecture, chaque véhicule, par le biais de son contrôleur de charge, résout localement le problème d'optimisation pour planifier la période de charge en fonction de sa demande d'énergie et le signal de coordination, tel que illustré sur la Figure 2-4. Cette approche présente l'avantage de respecter la vie privée des participants et de répartir le pouvoir de décision entre les différents clients, comme le montre la Figure 2-4. Il existe différentes variantes de l'architecture décentralisée, à savoir l'architecture décentralisée avec un agent central et l'architecture entièrement décentralisée. Dans la première configuration, un agent de coordination, appelé agrégateur ou nœud maître, coordonne la recharge de tous les VÉs. Cet agent est une interface entre les clients des VÉ et l'opérateur du

réseau de distribution. Cette interface permet aux clients de se connecter au marché de l'électricité pour négocier (en tant que groupe) des tarifs préférentiels en fournissant des services auxiliaires au réseau (maintien de la tension et de la fréquence, équilibrage de la charge et réduction des pertes de puissance) à travers l'exploitation du potentiel de flexibilité de leur demande de recharge. Dans un schéma plus global, les agents coordinateurs peuvent avoir d'autres agents coordinateurs jusqu'à l'opérateur de réseau. Par ailleurs, dans l'architecture entièrement décentralisée (sans agent intermédiaire), les VÉs communiquent directement avec l'opérateur de réseau (généralement au niveau des transformateurs de distribution les plus proches) qui propose des tarifs préférentiels à la flotte de VÉs participant en échange de la fourniture de services auxiliaires au réseau. Dans ce schéma l'opérateur du réseau envoie le signal de coordination à tous les VÉs et met à jour le signal de coordination de façon itérative sur la base des plans de recharge agrégés (profil de puissance agrégé) de la flotte de VÉs. Ce processus est répété de manière itérative jusqu'à ce qu'un accord soit trouvé où la courbe du signal de coordination ne s'actualise plus (convergence) en fonction des plans de recharge qui permettent de mieux améliorer les fonctions du réseau. Parmi les deux configurations, la plus populaire est celle avec des agents centraux en raison de la complexité qui peut être générée dans la deuxième configuration, surtout lorsque le nombre de VÉs devient très important. Bien que l'architecture de contrôle décentralisée permette aux clients de prendre leurs décisions en matière de plan de recharge, elle ne garantit pas nécessairement une solution optimale pour le réseau de distribution, car les agrégateurs ou le coordinateur ne peuvent pas réguler directement les plans de charge de chaque VÉ individuel [5]. Ils peuvent seulement modifier le comportement de charge agrégé des clients en fournissant des incitations attrayantes par le biais du signal de coordination (tarification dynamique de l'électricité) [32]. Un autre défi majeur pour les algorithmes de charge distribuée est la convergence et la performance du critère d'équilibre implémenté selon la méthode proposée [58]. Enfin, dans un scénario de coordination en temps réel, l'arrivée des VÉs est considérée comme une variable aléatoire ; par conséquent, un cadre de contrôle avec un plus haut degré d'évolutivité est très important. Toutefois, le modèle décentralisé offre une plus grande évolutivité à cet égard par rapport au modèle

centralisée [33]. Il est également plus flexible que ce dernier car il permet aux clients de prendre part au processus de décision concernant la recharge de leur VÉ. Par conséquent, il est hautement reconnu dans la conception du contrôle de l'ordonnancement de la charge des VÉ. Ces approches ont été utilisées dans les références [60], [61]

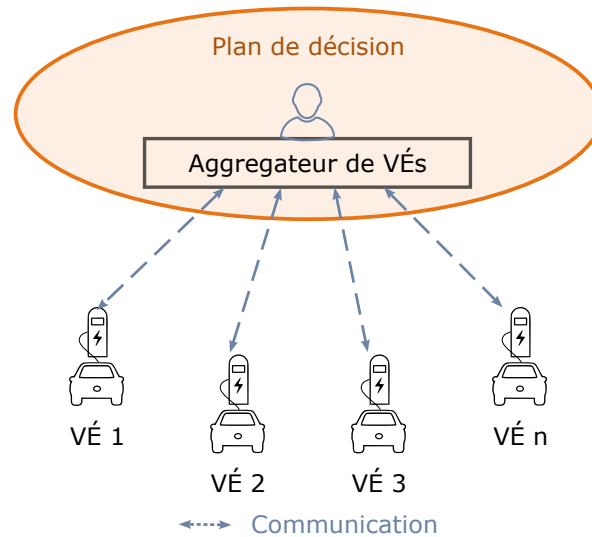


FIGURE 2-3 Architecture de contrôle centralisé de la recharge de plusieurs VÉs. [5].

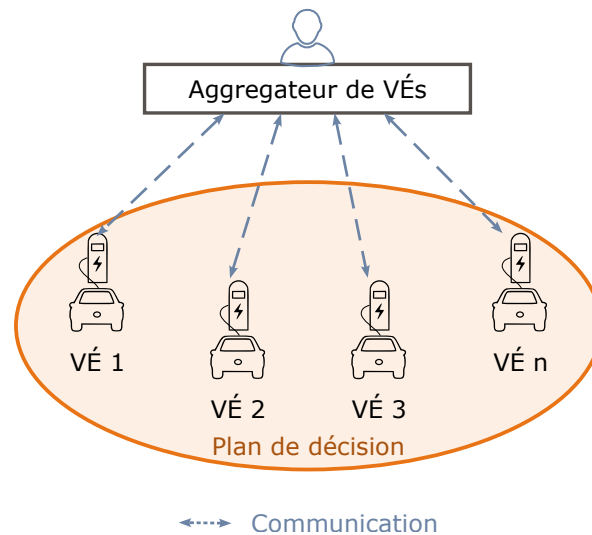


FIGURE 2-4 Architecture de contrôle décentralisé de la recharge de plusieurs VÉs. [5].

2.3 Algorithmes de planification de la recharge des VÉs

La littérature fournit une variété d'études sur la planification de la charge des VÉs dans le contexte des REIs. La planification de la recharge des VÉs est habituellement formulée comme un problème d'optimisation avec un schéma de contrôle composé essentiellement des trois étapes suivantes : **modélisation**, **optimisation**, **exécution**. La modélisation concerne principalement la variable d'état qui est l'état de charge ou d'énergie de la batterie ; ce modèle est représenté par une équation d'état modélisant la dynamique du système (processus de charge) ; cette étape est une partie essentielle de tout problème de contrôle optimal [62]. En outre, la modélisation peut concerner d'autres paramètres susceptibles d'influencer la stratégie de planification lorsque ces informations ne sont pas connues a priori, comme par exemple les informations sur les heures d'arrivée et de départ, le besoin énergétique de la charge (état de charge initial et état de charge final préféré ou souhaité), et le profil de puissance de la charge. Dans ce cas, il s'agit essentiellement d'un modèle d'estimation du paramètre en question. L'optimisation consiste à rechercher les actions de contrôle optimales qui satisfont la fonction objectif ainsi que toutes les contraintes du système. Ces actions de contrôle peuvent être soit la modulation de l'amplitude de la puissance de recharge (choix entre plusieurs valeurs discrètes), soit l'interruption (et la connexion) de la recharge pour déplacer la période de recharge, soit la mise à disposition d'une partie de l'énergie stockée dans le VÉ pour optimiser les intérêts du client (par exemple en vendant une partie de cette énergie au réseau à certains moments). Ce concept est communément appelé : véhicule-vers-réseau (*vehicle-to-grid* ou *V2G* en anglais), d'autres concepts existent également lorsque le gestionnaire de réseau n'accepte pas le service de rachat pour les clients résidentiels. Il s'agit de véhicule-vers-maison/bâtiment (ou *vehicle-to-house/building* en anglais). Dans ce cas le contrôleur peut charger le VÉ pendant les heures creuses où l'électricité coûte moins chère pour l'utiliser pendant les heures de pointe lorsque le prix de l'électricité est plus élevé. Enfin, après la phase de planification de la recharge (résolution du problème d'optimisation), le contrôleur de charge exécute les actions de contrôle à chaque pas de temps.

Par ailleurs, le contrôle peut être adaptatif et prédictif en présence d'incertitudes dans les paramètres. Dans ce cas, un modèle d'estimation ou de prédiction en temps réel est nécessaire.

Ainsi, en fonction des nouvelles observations à chaque pas de temps, l'estimation du paramètre incertain et la résolution du problème d'optimisation sont répétées. Dans la problématique de la planification de la charge des VÉ, le contrôleur de charge est un élément externe au VÉ, il doit donc communiquer avec ce dernier pour avoir l'information de l'état de charge de la batterie. Comme il n'a pas accès à toutes les informations pertinentes pour modéliser l'état de charge de la batterie avec une bonne précision (tension, courant et température de chaque cellule), le modèle le plus utilisé dans la littérature est basé sur la méthode non intrusive du comptage de coulomb (*coulomb counting method* en anglais).

2.3.1 *Techniques d'optimisation*

Plusieurs techniques d'optimisation ont été utilisées dans la littérature, pour la recherche de plans optimaux de charge. Les techniques les plus populaires sont les techniques d'optimisation mathématique (programmation linéaire [63], [64], programmation linéaire en nombres entiers mixtes [65], programmation dynamique [66], etc.), les techniques d'intelligence informatique (Méthodes heuristiques [67], optimisation par essaims de particules (PSO) [68], algorithmes génétiques (GA) [69], [70], théorie des jeux [71]. Toutefois, compte tenu de la nature des problèmes mathématiques formulés, les techniques d'optimisation mathématique sont les plus utilisées, notamment la programmation linéaire en nombres entiers mixtes. En effet, ces techniques sont bien adaptées au problème de la planification de la recharge des VÉ et permettent de trouver la solution exacte. L'utilisation d'autres techniques est souvent due à la difficulté de trouver une solution optimale (convergence) en utilisant les techniques d'optimisation mathématique en raison de la présence de non linéarité, problème non convexe, complexité.

2.3.2 *Approche de contrôle des VÉs*

Par ailleurs, les schémas existantes de contrôle peuvent être classées en approches déterministes et stochastiques [72], [73]. La première suppose un accès complet et précis aux paramètres critiques des VÉs tandis que la deuxième approche prend en compte ces facteurs ainsi que leurs incertitudes tel que illustré sur la Figure 2-5.

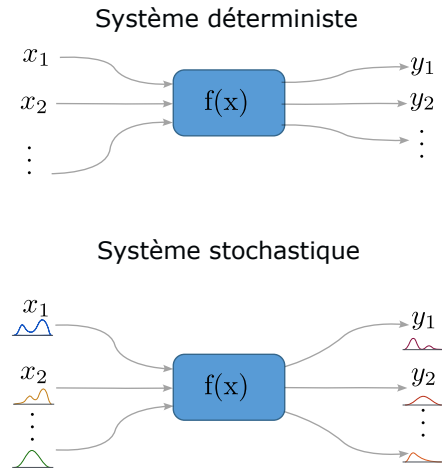


FIGURE 2-5 Modélisation des systèmes déterministes et stochastiques [73].

2.3.2.1 Approche déterministe

La plupart des études pertinentes dans la littérature adoptent cette approche [73]. Les contrôleurs basés sur cette approche déterministe supposent un accès direct et complet aux paramètres critiques des VÉs, tels que le niveau de charge de la batterie (SOC), les heures d'arrivée et de départ, les préférences des utilisateurs en terme de l'état de charge à l'heure de départ, le profil de puissance de charge, etc., pour planifier la recharge [73]. Cette approche, en raison de ses hypothèses simplificatrices, conduit à une conception de contrôleur moins complexe. De plus, en exploitant une information complète, le schéma déterministe permet une meilleure performance de contrôle. Cependant, l'approche déterministe peut être considérée comme idéaliste en pratique, car elle présuppose que le contrôleur de charge intelligent possède une connaissance parfaite de tous les paramètres essentiels des VÉs et du signal de demande de réponse (DR) comme principales entrées du modèle. Dans la réalité, la conception d'un contrôleur basé sur cette approche peut se heurter à deux défis majeurs. Le premier défi concerne la fourniture d'informations complètes et précises nécessaires à la planification de la recharge des VÉs, notamment le rôle des utilisateurs dans la fourniture d'informations. Le second défi réside dans l'incertitude inhérente associée à certaines informations. Les informations du VÉ, telles que l'état de charge de la batterie, peuvent être communiquées au contrôleur de charge externe via une communication directe ou indirecte par l'intermédiaire de

l'utilisateur à travers une application mobile ou web. Les informations relatives aux utilisateurs, telles que les heures d'arrivée et de départ et ses préférences de niveau de charge au départ, doivent être fournies par les utilisateurs. Cette approche, où l'utilisateur joue un rôle plus actif, peut être mise en œuvre dans des contextes spécifiques. Par exemple, pour les utilisateurs occasionnels utilisant des parkings partagés dans des centres commerciaux ou des parkings publics. En revanche, pour les applications où l'utilisateur recharge fréquemment son véhicule, comme la recharge à domicile (l'option la plus adoptée par les propriétaires de VÉs), les contrôles basés sur l'approche déterministe présentent l'inconvénient d'exiger une intervention humaine au début de chaque session de recharge, ce qui pourrait freiner l'adoption de ces technologies nouvelles [74]. En ce qui concerne le deuxième défi majeur, à savoir l'incertitude liée aux informations clés pour la planification de la recharge, on peut citer par exemple les incertitudes concernant la durée exacte de la recharge, qui dépend de facteurs tels que la température pouvant affecter le profil de puissance de charge, la capacité de la batterie, ainsi que les incertitudes sur les heures exactes d'arrivée et de départ, qui sont des variables aléatoires en raison du comportement stochastique des utilisateurs, et enfin les incertitudes liées à l'état de charge réel de la batterie. Ignorer ces incertitudes peut conduire en pratique à une insatisfaction de l'utilisateur concernant la stratégie de charge mise en œuvre jusqu'au moment du départ, que ce soit en termes de niveau de charge final ou de la réduction du coût énergétique. Dans l'ensemble, ces hypothèses inhérentes à l'approche déterministe peuvent entraver les mises en œuvre réussies dans les applications de recharge à domicile en raison de la nécessité accrue d'interventions humaines dans la prise de décision et des incertitudes associées à l'absence de paramètres de charge essentiels.

Parmi les travaux basés sur la conception déterministe de contrôle de la charge, nous pouvons citer les travaux [1], [59], [64], [75], [76]. La référence [75] a proposé un algorithme de planification de la recharge d'un VÉ dans une résidence, ainsi que le contrôle de plusieurs appareils domestiques pour minimiser la facture d'électricité du client. L'algorithme de décision proposé se base sur la logique floue et exige des informations précises de l'ensemble des informations d'entrée. Un contrôleur intelligent de la charge des VÉs à domicile a été proposé dans [64]. Les auteurs ont évalué différents modes de contrôle, notamment les modes V2G et V2H, sous différentes structures tarifaires d'électricité pour minimiser les coûts

énergétiques des clients. Là encore, le contrôleur de charge exploite des valeurs précises de l'ensemble des informations d'entrée. Un cadre coordonné et centralisé de contrôle de la recharge de plusieurs VÉs et du système de chauffage, de la ventilation et de la climatisation a été proposé dans [59]. La recharge des VÉs a été modélisée à l'aide des informations sur les trajets des utilisateurs, qui doivent être communiquées à l'agrégateur un jour en avance. Sur la base de ces informations, l'agrégateur estime les besoins de charge des VÉs pour planifier leur période de charge. La référence [1] a évalué le potentiel des VÉs et de quatre autres charges domestiques pour l'écrêtement des pointes. Contrairement à [59], les auteurs ont proposé un système de contrôle décentralisé et un schéma de contrôle déterministe, dont les performances ont été évaluées sur des données de 100 ménages et différents signaux de prix de l'électricité. Les études mentionnées ci-dessus n'ont pas pris en compte les aspects pratiques de leurs propositions. En effet, dans des situations réelles, le contrôleur de charge doit prendre en compte diverses sources d'incertitude liées aux paramètres clés, au comportement non linéaire de la puissance de charge des VÉs et au rôle des utilisateurs dans la fourniture régulière d'informations essentielles au contrôleur de charge pour la planification de la recharge des VÉs. En fin de compte, le coût de l'incorporation de l'incertitude est généralement inférieur au coût potentiel des risques d'une décision stratégique basée sur les résultats d'un modèle déterministe, comme mentionné ci-dessus.

2.3.2.2 *Approche stochastiques*

Les avancées technologiques et les progrès en matière d'intelligence artificielle ont ouvert la voie à une réduction significative du rôle des utilisateurs dans la fourniture d'informations essentielles. De plus, les méthodes d'apprentissage sont de plus en plus utilisées dans la prise de décisions dans le monde réel. Face aux multiples sources d'incertitude, les approches stochastiques sont reconnues comme une approche prometteuse pour la conception de contrôleurs de charge intelligents plus réalistes et efficaces. Plusieurs approches ont été proposées dans la littérature pour tenir compte de l'incertitude liée au comportement stochastique des paramètres dans le processus de prise de décision. Les approches les plus courantes pour la planification de la recharge des véhicules électriques sont la commande prédictive (MPC, *model predictive control*) en anglais) et l'optimisation stochastique. La MPC repose sur une optimisation en

ligne¹ basée sur la prédiction de l'état futur des paramètres incertains et l'ajustement des actions de commande² en fonction de ces prédictions. Cependant, la performance de la CP dépend largement de la précision du modèle prédictif. D'autre part, l'optimisation stochastique évalue les actions de contrôle sur tous les scénarios possibles des paramètres incertains, ce qui la rend plus complexe mais plus théoriquement optimale. La modélisation des distributions des paramètres stochastiques est essentielle pour cette approche.

La référence [76] a présenté un algorithme de contrôle de la recharge des VÉs ainsi que d'autres dispositifs électriques dans une résidence. Cette approche repose sur l'optimisation stochastique et utilise la technique de Lyapunov pour gérer les incertitudes liées à divers facteurs tels que le prix de l'électricité, la température extérieure, la production d'énergie renouvelable, la demande d'électricité de la maison, le confort des occupants et le statut d'occupation de la maison. Cependant, cette étude n'a pas pris en compte les paramètres incertains liés à la demande de recharge du véhicules. En effet, le système de contrôle proposé suppose que toutes les informations détaillées sur la demande de charge du VÉ, y compris l'heure d'arrivée, l'heure de départ, les besoins en énergie et les préférences de charge de l'utilisateur, sont fournies pour planifier la recharge du VÉ. Une autre référence [77] a proposé une stratégie de planification de la recharge des VÉ, y compris le mode de fonctionnement "vehicle-to-grid" (V2G), ainsi que le contrôle d'autres appareils domestiques, basée sur la commande prédictive (MPC). Ce schéma de contrôle tient compte de certaines incertitudes liées à la demande de recharge du VÉ, notamment l'état de stationnement du véhicule (disponible pour la recharge ou en déplacement), dont l'état futur est prédit et mis à jour à chaque pas de temps. Une approche centralisée de contrôle a été présentée dans la référence [55], où un ensemble de VÉs et de panneaux solaires dans un bâtiment commercial est géré dans un contexte d'énergie transactionnelle. Le gestionnaire d'énergie domestique (CR) permet aux propriétaires de VÉ de rejoindre un marché transactif en offrant leur flexibilité de charge. En échange, les propriétaires de VÉ acceptent que le CR réduise la puissance de charge de leurs VÉ en fonction de la demande, moyennant une incitation monétaire. Le niveau de réduction de la puissance est décidé dans chaque intervalle de temps en fonction de la

1. optimisation en temps réel pendant le processus de chargement en utilisant les données observées (mesurées) en temps réel

2. actions de commande typiquement ON/OFF de l'alimentation de la charge à chaque pas de temps

limite de charge et de la courbe de réponse que les propriétaires doivent renseigner lorsqu'ils rejoignent le marché. Pour faire face aux circonstances stochastiques associées à l'arrivée aléatoire des VÉ sur le marché, le système s'appuie sur la MPC qui est exécuté à chaque intervalle pour tenir compte des nouvelles informations et aussi gérer la recharge des VÉs selon les prévisions des surplus d'énergie liés à la production des PVs.

Des recherches récentes ont exploré l'application de l'optimisation stochastique pour gérer les sources d'incertitude dans la planification de la recharge des VÉs [44], [73], [78], [79]. Momber et al. (2015) [80] ont élaboré un modèle de programmation linéaire stochastique en deux étapes pour la recharge des VÉs, en considérant l'aversion au risque et les incertitudes liées aux prix de l'électricité et à la mobilité des VÉs. Wu et al. (2017) [34] ont proposé un modèle d'optimisation stochastique en deux étapes qui prend en compte la limite de la capacité du transformateur de distribution local, tout en optimisant le profit de l'agrégateur. Seddig et al. (2019) [81] ont développé un schéma de contrôle basé sur l'optimisation stochastique à deux étapes pour la recharge des VÉs. Ils ont utilisé l'approximation de la moyenne des échantillons (SAA) et modélisé la mobilité des VÉs à l'aide d'une fonction de densité de probabilité non paramétrique. Wu et al. (2018) [82] ont introduit une approche basée sur la programmation dynamique stochastique pour la planification de la recharge des VÉs et d'autres appareils domestiques. Leur modèle incorpore les incertitudes liées aux heures d'arrivée et de départ des VÉs, en utilisant un modèle stochastique basé sur les chaînes de Markov. Ils ont également pris en compte l'incertitude associée à la demande d'énergie en se basant sur l'état de charge initial et les préférences de l'utilisateur en termes de l'état de charge final.

En synthèse, les études examinées ont apporté des contributions significatives à la compréhension des stratégies de planification de la recharge des VÉs en prenant en compte les incertitudes. Elles ont exploré divers paramètres incertains tels que les heures d'arrivée et de départ des VÉs, la demande d'énergie et l'état de charge initial. Cependant, des limitations ont été identifiées, telles que l'absence de prise en compte de l'incertitude liée à la demande d'énergie dans certaines approches et la focalisation sur certains paramètres incertains dans d'autres. De plus, la nécessité d'une modélisation précise des distributions de paramètres incertains et la complexité des calculs pour résoudre les problèmes d'optimisation stochastique

constituent des défis persistants. Malgré les avancées réalisées, des lacunes demeurent, notamment en matière de modèles prédictifs plus précis, d'une prise en compte plus exhaustive des sources d'incertitude et d'une gestion plus efficace de la complexité des calculs. Ainsi, des recherches plus approfondies sont nécessaires pour surmonter ces défis et permettre des applications concrètes dans divers contextes.

2.4 Caractérisation et modélisation de la demande de recharge des VÉs

Le comportement de charge des VÉs est principalement influencé par la mobilité des utilisateurs et des facteurs stochastiques, ainsi que par l'infrastructure de charge disponible [18]. Une caractérisation précise du comportement de charge des VÉs permettrait au contrôleur de réduire les interventions humaines répétitives dans le processus de décision et de prendre des actions de contrôle moins susceptibles de compromettre la satisfaction des utilisateurs. Cependant, une lecture directe des paramètres clés n'est pas toujours possible en raison de la stochasticité et des sources d'incertitudes associées à certains paramètres liés au comportement des utilisateurs (heures de départ et d'arrivée, préférences de charge) ainsi qu'à l'incertitude inhérente à certains paramètres du VÉ (profil de puissance de charge, état de charge de la batterie, capacité de la batterie, etc.), qui dépendent de divers facteurs tels que la température ambiante et la dégradation. Afin de mieux saisir et modéliser le comportement stochastique de la demande de recharge des VÉs, le contrôleur peut recourir à des approches basées sur l'apprentissage automatique et les statistiques.

2.4.1 Heures d'arrivée et de départ

Les heures d'arrivée et de départ jouent un rôle crucial dans la planification de la recharge des VÉs, déterminant l'horizon de contrôle et la flexibilité de la demande de recharge. En tant que variables aléatoires, elles demeurent inconnues pour le contrôleur jusqu'à leur occurrence, à moins d'une spécification préalable par le propriétaire du VÉ. La littérature offre diverses approches pour modéliser ces paramètres. Les techniques couramment utilisées incluent les modèles basés sur les chaînes de Markov [82]-[84], les modèles semi-Markov [18], [77], les modèles non paramétriques basés sur l'estimation des densités de probabilité par noyaux

(*Kernel Density Estimation*) [81], [85], et les modèles de prédiction basés sur l'apprentissage automatique [86], [87].

Les modèles basés sur les chaînes de Markov modélisent l'état de disponibilité du VÉ à la borne de recharge sous forme d'une variable aléatoire à deux états (disponible ou non disponible). Les transitions entre ces états se produisent lors du branchement et du débranchement du VÉ. Cette approche offre une représentation détaillée de la dynamique temporelle de la disponibilité du VÉ à la borne de recharge, mais peut entraîner une complexité de décision en raison de la matrice de transition d'état dans l'optimisation stochastique [44], [82]. Les méthodes semi-Markov modélisent le temps de disponibilité du VÉ en tant que variable aléatoire, offrant une modélisation moins complexe que les chaînes de Markov tout en conservant la dynamique temporelle. Cependant, elles peuvent également conduire à un espace de décision complexe en capturant la durée possible de chaque déplacement du VÉ à chaque pas de temps [77], [78]. Les modèles basés sur les statistiques estiment la distribution de probabilité en utilisant des données historiques pour capturer le comportement stochastique. L'estimation par noyau (*Kernel Density Estimation*) est couramment utilisée pour modéliser la distribution des paramètres stochastiques du VÉ en utilisant différents types de noyaux. Cette approche offre une quantification de l'incertitude, mais peut ne pas capturer directement la séquence temporelle entre les variables aléatoires [79]. Les modèles prédictifs reposent sur l'apprentissage automatique pour prédire la variable aléatoire. Cependant, la précision de ces prédictions face au comportement stochastique demeure un défi majeur, tout comme la quantification des incertitudes associées aux prédictions[86].

En somme, diverses approches de modélisation existent pour caractériser les heures d'arrivée et de départ des VÉs. Chacune présente des avantages et des défis en termes de complexité de décision, représentation temporelle et prise en compte des incertitudes.

2.4.2 Demande d'énergie pour la recharge

L'état de charge initial de la batterie au moment du branchement à la borne de recharge revêt une importance cruciale dans la planification de la recharge des VÉs. Il influence directement le besoin énergétique de recharge et est un paramètre clé pour assurer la satisfaction de l'utilisateur en termes de préférences de charge pour ses déplacements futurs. Par conséquent,

l'état de charge de la batterie est utilisé comme une variable d'état dans le processus de contrôle, permettant de tenir compte des contraintes liées à cette variable. Prévoir les besoins énergétiques des VÉs peut faciliter une meilleure coordination de leur recharge, que ce soit avec d'autres VÉs ou charges électriques, dans un cadre de contrôle centralisé et coordonné, ou encore pour tirer parti de la flexibilité de la recharge dans un marché de l'énergie transactionnelle. Certaines études ont utilisé les données historiques des trajets des VÉs pour anticiper leur flexibilité de recharge en fonction de leurs besoins en énergie [20].

Pour garantir des contrôleurs de charge intelligents et autonomes, l'accès automatisé aux informations pertinentes est essentiel. Les avancées technologiques et les coûts réduits des composants électroniques ont permis le développement de solutions abordables pour les utilisateurs finaux. Les VÉs sont de plus en plus équipés de fonctionnalités offrant des opportunités pour des solutions de recharge intelligentes, telles que l'estimation précise de l'état de charge de la batterie, des distances parcourues et des données historiques. Cependant, actuellement, de nombreuses informations cruciales pour la planification de la recharge des VÉs, disponibles dans les véhicules, ne sont pas accessibles via l'infrastructure de recharge résidentielle ou les contrôleurs de charge tiers. Les protocoles de communication, tels que la communication véhicule-infrastructure (V2I) et d'autres, ont été proposés pour faciliter le partage d'informations, mais ne sont pas encore largement mis en œuvre par les fabricants de VÉs existants [78], [88]. Ceci pose un défi majeur, compte tenu du nombre croissant de VÉs sur les routes.

Certaines solutions ont été explorées dans la littérature, notamment l'utilisation du bus CAN de l'OBD pour accéder aux données SOC de la batterie et l'utilisation de données GPS. Cependant, ces solutions peuvent présenter des inconvénients tels que la complexité, le manque d'interopérabilité entre différents modèles de VÉs et la dépendance à une communication fiable [18], [20], [89], [90].

En somme, malgré les tentatives pour estimer les besoins énergétiques des VÉs pour la recharge, les solutions actuelles présentent des limitations qui entravent une gestion efficace et autonome de la recharge, nécessitant des améliorations pour une optimisation plus précise et satisfaisante.

2.4.3 *Flexibilité de la demande d'énergie et préférences de l'utilisateur*

La flexibilité des VÉs découle du fait qu'ils demeurent branchés à la borne de recharge pendant une durée excédant celle nécessaire pour une charge complète de la batterie [34]. Dans la plupart des algorithmes de planification de la recharge des VÉs décrits dans la littérature, la contrainte relative à l'état final de la batterie est traitée en fonction d'une valeur de référence souhaitée, définie par les utilisateurs comme préférence de recharge. La valeur la plus courante est de 80%. Cependant, des analyses statistiques menées dans plusieurs pays ont révélé que la distance moyenne parcourue quotidiennement par la plupart des véhicules personnels est inférieure à 50 km [91], [92], tandis que les VÉs les plus populaires sur le marché ont une autonomie allant de 200 km à 500 km pour les modèles tout électriques [92], [93]. Dans cette optique, de nombreux utilisateurs n'ont pas systématiquement besoin d'une batterie entièrement chargée pour une recharge quotidienne (semblable à la pratique des véhicules à combustion interne où les utilisateurs ne font pas le plein d'essence tous les jours).

Cette flexibilité peut être exploitée par le contrôleur pour des prises de décision plus optimales à long terme, comme la minimisation des coûts de recharge à long terme ou l'amélioration des performances du réseau électrique. Ainsi, certains travaux ont suggéré de relâcher la contrainte liée à l'état final de la batterie afin de mieux exploiter la flexibilité de la demande de recharge des VÉs. Par exemple, dans l'étude [94], une fonction d'utilité basée sur une fonction sigmoïde a été intégrée à la fonction objectif pour caractériser les préférences de recharge des utilisateurs. Cette fonction reflète la préférence de charge de telle sorte que l'ajout d'énergie dans la batterie (à partir du début de la charge) accroît la satisfaction de l'utilisateur, proportionnellement à la valeur de la fonction d'utilité. Cette valeur présente une croissance marquée jusqu'à un certain seuil où l'ajout d'énergie supplémentaire est supposé contribuer marginalement à l'utilité.

Une autre approche de relaxation des besoins énergétiques repose sur la prédiction des distances des trajets à venir jusqu'à la prochaine recharge, comme évoqué dans l'étude [20].

2.4.4 Dynamisme des paramètres du modèle d'état

Le modèle d'état, exprimé sous forme d'équation de la dynamique de l'état de charge (SOC), permet au contrôleur de charge d'évaluer diverses stratégies de contrôle et de choisir celle qui optimise les objectifs tout en respectant les contraintes du problème d'optimisation. En conséquence, la précision de ce modèle joue un rôle crucial dans le processus décisionnel. Cependant, le modèle d'état basé sur le comptage des coulombs, bien qu'il soit largement utilisé, souffre d'une moindre fidélité, principalement en raison de sa linéarité. Dans de nombreux travaux de planification de la recharge des VÉs, les principaux paramètres du modèle sont souvent supposés constants. Cependant, plusieurs facteurs induisent des comportements non linéaires dans la dynamique réelle du SOC.

Des phénomènes externes, tels que les conditions météorologiques, peuvent avoir un impact sur le comportement de charge des véhicules [95]. Par exemple, il a été démontré que les températures froides peuvent influencer les performances des batteries des véhicules, en raison des pertes de polarisation d'activation et de la réduction de la capacité utilisable de la batterie. De plus, les études tendent souvent à simplifier le processus de charge en supposant un taux de charge constant, alors que la réalité implique deux modes de fonctionnement distincts : le mode à courant constant et le mode à tension constante. Ignorer cette non-linéarité de la puissance de charge peut engendrer une mauvaise évaluation de la durée de charge réelle, ce qui peut à son tour affecter la satisfaction de l'utilisateur concernant la valeur finale réelle du SOC au moment du départ.

En outre, la dégradation de la batterie peut également impacter la fidélité du modèle sur le long terme. Malgré l'importance de ces facteurs dans des situations concrètes, ils n'ont pas toujours été suffisamment pris en compte dans la littérature concernant la planification intelligente de la recharge des VÉs.

2.5 Synthèse du chapitre

Ce chapitre réalise une analyse approfondie des diverses approches et méthodologies abordant la recharge intelligente des VÉs dans la littérature. Il met en évidence les forces et les limitations des méthodes existantes, ainsi que les problèmes et difficultés qu'elles rencontrent.

En outre, il explore les concepts fondamentaux de la planification de la recharge des VÉs. Avec l'émergence des VÉs comme nouvelle source de charge électrique dans le réseau de distribution, la communauté scientifique s'est fortement penchée sur cette question au cours de la dernière décennie. Cela a conduit à de nombreuses études sur les impacts potentiels de la recharge non coordonnée des VÉs sur la stabilité et la fiabilité du réseau. De plus, plusieurs travaux ont proposé des stratégies de gestion de la recharge des VÉs et développé des algorithmes de planification et de contrôle intelligent de la recharge, visant à minimiser les coûts énergétiques pour les utilisateurs tout en exploitant la flexibilité potentielle de la demande pour améliorer les performances du réseau.

Cependant, la majorité des travaux en matière de planification de la recharge des VÉs ont été axés sur la démonstration du potentiel de contrôle pour réduire les pics de consommation et minimiser les coûts énergétiques. Malheureusement, l'aspect de l'applicabilité dans le monde réel a souvent été négligé. Ces travaux ont souvent supposé une connaissance parfaite des paramètres clés du VÉ, ce qui ne correspond pas à la réalité. Le contrôleur peut faire face à des défis majeurs en matière d'accès aux informations pertinentes. Les utilisateurs peuvent hésiter à fournir régulièrement des informations telles que les heures d'arrivée et de départ ainsi que l'état de charge de la batterie. De plus, l'incertitude est inhérente à des informations telles que les heures d'arrivée et de départ, qui sont liées au comportement stochastique des utilisateurs. Les modèles déterministes, qui sont largement utilisés dans ces travaux, ne prennent pas suffisamment en compte ces incertitudes.

Cependant, certains travaux ont abordé ces problèmes en utilisant la commande prédictive et l'optimisation stochastique pour tenir compte des incertitudes liées aux paramètres clés. Néanmoins, des défis subsistent, tels que la nécessité de développer des modèles prédictifs précis et fiables pour être efficace dans la planification de la recharge. De plus, l'impact des décisions non fiables sur la satisfaction de l'utilisateur, en particulier en ce qui concerne l'état de charge final, n'a pas été suffisamment étudié. Les recherches pertinentes ont également une portée limitée, car elles se concentrent souvent sur des aspects spécifiques sans prendre en compte l'ensemble des circonstances interconnectées, notamment le manque d'informations sur les paramètres essentiels.

En résumé, ce chapitre met en évidence les opportunités et les défis associés à la recharge

intelligente des VÉs. Les avancées technologiques, les méthodes d'intelligence artificielle et les techniques de prise de décision mathématiques offrent des perspectives prometteuses pour aborder ces défis et permettre des applications concrètes répondant aux besoins complexes de la recharge intelligente des VÉs.

Chapitre 3 - Caractérisation et planification de la demande de recharge des VÉs

3.1 Introduction

Le défi principal dans le développement d'un algorithme intelligent et efficace pour la planification de la recharge des véhicules électriques résidentiels réside dans la mise en place de stratégies de contrôle minimisant l'intervention humaine et robustes aux incertitudes associées à des paramètres clés variables dans le temps, tels que les habitudes de recharge, la dégradation de la batterie et la température ambiante. Pour relever ce défi, il est essentiel d'équiper le contrôleur de charge de modèles prédictifs capables d'anticiper la demande énergétique des véhicules avec une intervention minimale de l'utilisateur. Compte tenu des principales limites des approches proposées dans la littérature, le principal intérêt de cette thèse est de développer des modèles statistiques et prédictifs capables de capturer et de caractériser les habitudes et les tendances de recharge des VÉs à partir des informations reliées à leurs activités de recharges dans les bornes de recharge à domicile. Cette stratégie vise essentiellement à exploiter efficacement les sources d'information disponibles et facilement accessibles, même en cas de défaillance de la communication entre un VÉ et la borne de recharge, et aussi à minimiser l'intervention de l'utilisateur dans la fourniture des informations. Dans ce contexte, un intérêt particulier a été porté aux mesures électriques et autres systèmes de mesure à la borne de recharge pour saisir les comportements stochastiques de recharge des différents véhicules (demande d'énergie pour la recharge, heure de connexion et de déconnexion, etc.) Cependant, ceci amène un défi important qui est de développer un mécanisme de détection, d'identification, d'anticipation de leur demande d'énergie et de planification de leur charge à partir de ces informations partielles en tenant compte des défaillances de communication

entre le contrôleur et les VÉ et des informations stochastiques liées au comportement des utilisateurs (durée de stationnement, besoin énergétique, etc.) et des incertitudes associées aux informations clés. Pour relever ce défi, la première partie de cette thèse s'est concentrée sur la mise en œuvre d'un modèle de détection et d'identification des VÉs au moment de leur branchement. Ensuite, par le biais d'analyses statistiques, nous avons développé des modèles stochastiques du comportement de recharge des utilisateurs en termes d'habitudes de branchement et de débranchement des VÉs aux bornes de recharge. Par la suite, nous avons développé et proposé un modèle prédictif pour anticiper la demande énergétique pour la charge. En outre, un modèle de caractérisation du profil de puissance de charge basé sur des données historiques et la sortie des modèles stochastiques a été introduit dans le but de minimiser les incertitudes sur la durée de charge, notamment celles liées à la température ambiante et à la dégradation de la batterie, en plus de la demande en énergie. Enfin, un algorithme de planification de la recharge des VÉs a été proposé sur la base de modèles stochastiques des différents paramètres influençant la demande de recharge des VÉs. L'algorithme développé tire profit de l'optimisation stochastique comme outil efficace pour la prise de décision en présence d'incertitudes sur les paramètres clés. La figure 3-1 illustre le diagramme du processus de planification de la recharge des VÉ proposé.

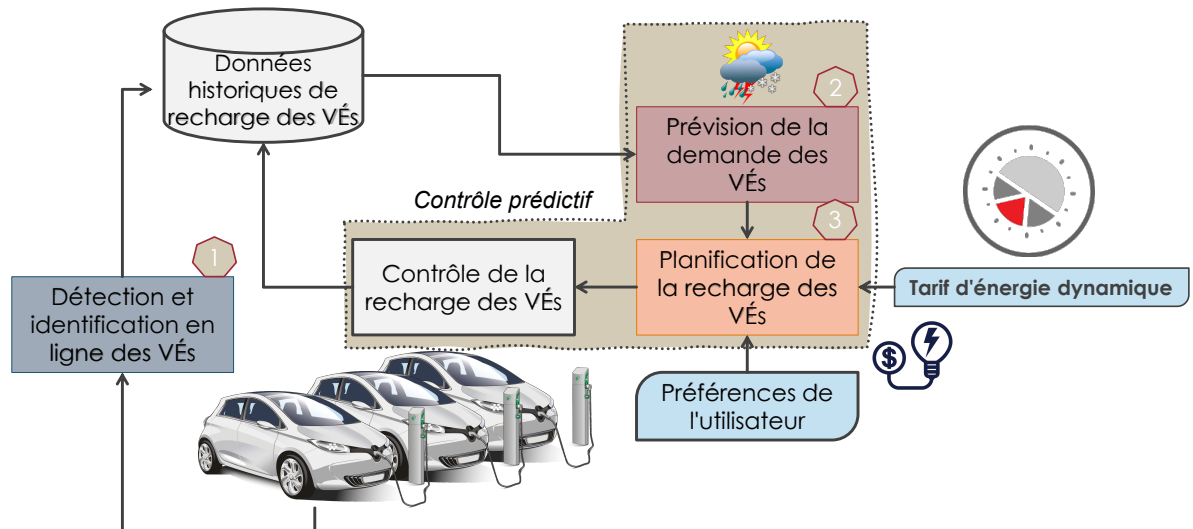


FIGURE 3-1 Schéma du processus de planification de la recharge des VÉs proposé.

3.2 Détection et identification en ligne des VÉs

Ce travail introduit une solution d'identification et de reconnaissance des VÉs au niveau de la borne à partir du courant/puissance de charge. Cette proposition a été présentée dans un article de journal publié en 2017 [96]. Le contrôleur à travers cette technique d'identification efficace des VÉs peut ensuite utiliser une reconnaissance effective des activités individuelles des VÉs pour une pratique d'anticipation fructueuse de leur demande d'énergie et leur potentiel de flexibilité. En effet, l'identification des VÉs individuels au fil du temps permet au contrôleur de charge de construire des modèles statistiques de leurs habitudes de recharge, afin de prendre des décisions plus personnalisées qui respectent à la fois les préférences de chaque utilisateur et maximisent les objectifs collectifs en termes de gestion des demandes de puissance et des ressources matérielles (infrastructure de recharge) dans le contexte d'un contrôle centralisé de plusieurs VÉs partageant les bornes de recharge. Cependant, l'identification des VÉs à partir de la mesure du courant électrique constitue un défi majeur en raison d'une similitude marquée entre les amplitudes de charge des VÉs de même capacité de batterie, comme le montre la Figure 4-3a. Une autre complication est que l'intensité du courant de charge varie légèrement d'une session de charge à l'autre pour un même véhicule.

Le processus de reconnaissance des formes et de classification des données en conséquence a gagné beaucoup d'intérêt dans divers domaines au cours des dernières décennies [97] - [98] - [99]. Dans ce travail de recherche, le problème d'identification des VÉs dans le contexte de bornes de recharge partagées consiste à classer les profils de charge des VÉs en utilisant un petit échantillon des mesures du courant. Cette approche de reconnaissance des VÉs est souhaitable car elle est applicable à tout type de borne de recharge résidentiel et tout type de VÉs et ne nécessite qu'une installation à faible coût de mesure de courant. Cependant, cette approche présente un défi important en raison d'une similitude marquée entre les amplitudes de charge de charge des VÉs de même catégorie (capacité de batterie). Par conséquent, des caractéristiques discriminatoires appropriées et une méthode de classification efficace sont nécessaires pour obtenir une bonne identification des différents VÉs. La méthodologie utilisée pour la reconnaissance des VÉs est illustrée à la Figure 3-3. La première étape consiste à détecter le moment de connexion à partir de la mesure du courant au niveau de la borne

lorsque le VÉ ensuite de prélever un échantillon de mesure pour la phase d'identification du VÉ. La phase d'identification du VÉ consiste à extraire des caractéristiques discriminatoires et pertinentes dans l'échantillon de mesure. C'est étape est très importante et a pour but de fournir au classificateur des caractéristiques discriminantes lui permettant une meilleur classification [100]. La deuxième étape consiste à classifier l'échantillon analysé dans une des classes de VÉs candidats.

FIGURE 3-2 Profils de charge typiques de 5 VÉs pendant plusieurs sessions de charge

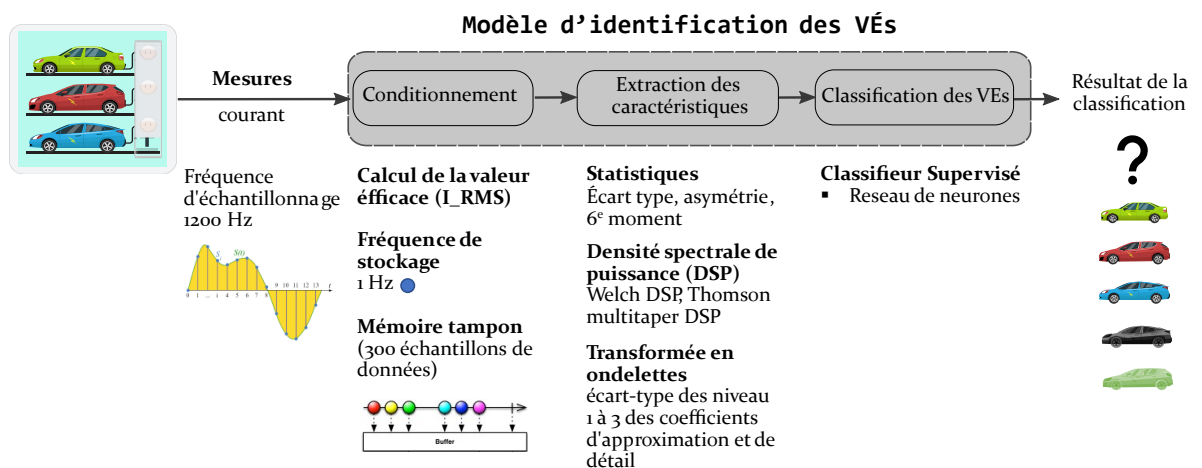


FIGURE 3-3 Processus complet de reconnaissance des VÉs après l'entraînement du modèle.

3.2.1 Extraction de caractéristiques discriminatoires

Le principal défi dans la construction du modèle d'identification des VÉs est de le rendre aussi fiable que possible afin d'éviter les confusions entre les différentes voitures partageant les bornes de charge. La phase d'extraction de caractéristiques discriminatoires pertinentes à partir de mesures du courant de charge est donc nécessaire d'extraire afin d'avoir une bonne performance dans l'identification des différents VÉs. Différentes caractéristiques ont été utilisées pour la reconnaissance et la classification des formes dans la littérature. Ces caractéristiques peuvent être de différents types selon le domaine d'application et la nature physique du signal d'entrée. Dans le domaine temporel, les caractéristiques les plus populaires sont les variables statistiques calculées à partir de l'échantillon de mesure [97], [101], [102]. Dans le domaine fréquentiel, les caractéristiques les plus utilisées sont les coefficients d'ondelettes, la

transformation de Fourier rapide (« *Fast Fourier Transform (FFT)* ») et la densité spectrale de puissance [103]. Lors qu'il y a une similitude entre le signal de différents VÉs, l'enjeu principal consiste à choisir des caractéristiques qui compte pour des informations "riches" pour le classificateur. À cet égard, notre stratégie a été dans ce travail de recherche d'examiner un large éventail de caractéristiques parmi lesquelles les plus efficaces sont sélectionnées en appliquant la méthode de sélection séquentielle (*Sequential Forward Selection (SFS)*) [104]. Cette méthode consiste, à partir de l'ensemble vide, à ajouter successivement la caractéristique qui maximise une fonction critère, c'est-à-dire celle associée aux meilleures performances du classificateur lorsqu'elle est combinée au sous-ensemble de caractéristiques déjà sélectionnées (les détails de la méthode SFS sont présentés dans la sous-section 3.2.3).

L'espace de caractéristiques initial considéré contient un ensemble de 12 vecteurs de sous-ensembles. Il s'agit d'un ensemble de données l'échantillon de mesure brut, noté F_1 , d'un ensemble de données de la densité spectrale de puissance estimatée par la méthode de Welch [105], noté F_2 , d'un ensemble de données de la densité spectrale de la densité multicouche standard de Thomson [106], noté F_3 , l'écart-type, noté F_4 , l'asymétrie, noté F_5 , le sixième moment central, noté F_6 de l'échantillon brut et l'écart-type de six signaux issus des trois premières résolutions extraits de l'échantillon de mesure à l'aide de la transformation discrète en ondelettes [107], noté respectivement F_7 , F_8 , F_9 , F_{10} , F_{11} et F_{12} . Dans cette étude, les ondelettes mères Haar ont été choisies en tant qu'ondelettes mères les plus utilisées.

$$\begin{aligned}
F_1 = Rwdata &= [f_1^1, f_2^1, \dots, f_{N^{rw}}^1] \\
F_2 = \text{PSD}_{\text{Welch}} &= [f_1^2, f_2^2, \dots, f_{N^{\text{welch}}}^2] \\
F_3 = \text{PSD}_{\text{Thomson}} &= [f_1^3, f_2^3, \dots, f_{N^{\text{th}}}^3] \\
F_4 = \sigma^{rw} &= f_4 \\
F_5 = \text{Skews} &= f_5 \\
F_6 = 6^{\text{e}} \text{moment} &= f_6 \\
F_7 = \sigma_{a_1}^{WT} &= f_7 \\
F_8 = \sigma_{d_1}^{WT} &= f_8 \\
F_9 = \sigma_{a_2}^{WT} &= f_9 \\
F_{10} = \sigma_{d_2}^{WT} &= f_{10} \\
F_{11} = \sigma_{a_3}^{WT} &= f_{11} \\
F_{12} = \sigma_{d_3}^{WT} &= f_{12}
\end{aligned} \tag{3.1}$$

$$F^{\text{init}} = [f_1, f_2, \dots, f_{N_f}]^T \tag{3.2}$$

Le deuxième défi, après l'extraction et la sélection des meilleures caractéristiques, est de définir un classificateur performant capable d'identifier le VE à partir du signal d'alimentation électrique de la borne partagée.

3.2.2 Classification des profils de charge

La tâche du classificateur consiste à utiliser le vecteur de caractéristiques extrait dans l'étape précédente pour affecter le VÉ à une catégorie. Plusieurs techniques de classification ont été proposées dans la littérature dans plusieurs domaines notamment dans le domaine du traitement automatique des données, de la reconnaissance des formes (images, écriture, etc.). Ces techniques de classification sont catégorisées en deux grandes familles : les techniques de classification basées sur l'apprentissage *supervisé* et les techniques de classification basées sur l'apprentissage *non supervisé* [108]. Pour la première famille, un superviseur (connaissance externe préalable des véhicules) est nécessaire pour étiqueter correctement les données d'apprentissage. Cela permet à ces classifieurs de montrer plus de sensibilité et d'efficacité dans la pratique de classification. Dans la deuxième famille, le classifieur agit sur des informations

non étiquetées, c'est-à-dire sans l'aide d'un superviseur. La tâche du classifieur est alors de regrouper des informations non triées sur la base de similarités, de motifs et de différences, sans entraînement préalable des données. Toutefois, pour cette famille, le classifieur est limitée dans la recherche de la structure cachée dans les données non étiquetées. Dans ce travail de recherche, les classifieurs basés sur l'apprentissage supervisé ont été prioriser pour les pratiques de l'identification des VÉs en raison de la sensibilité des décisions de contrôle face aux circonstances de mauvaises classifications. Une étude comparative a été mené en utilisant deux techniques parmi les plus populaires dans cette famille de classifieurs, à savoir le Réseau de neurones à propagation avant « *feed-forward neural network* » [109] et les machines à vecteur de support (« *support vector machine (SVM)* » [110]. La topologie du réseau de neurones utilisé est présentée dans la Figure 3-4.

3.2.2.1 Réseau de neurones à propagation avant

Le réseau de neurones à propagation avant est la famille de réseaux neuronaux la plus couramment utilisée pour les tâches de classification de formes [109]. La topologie du réseau utilisé dans ce travail est un réseau de neurones à propagation avant à deux couches, comme le montre la figure 3-4.

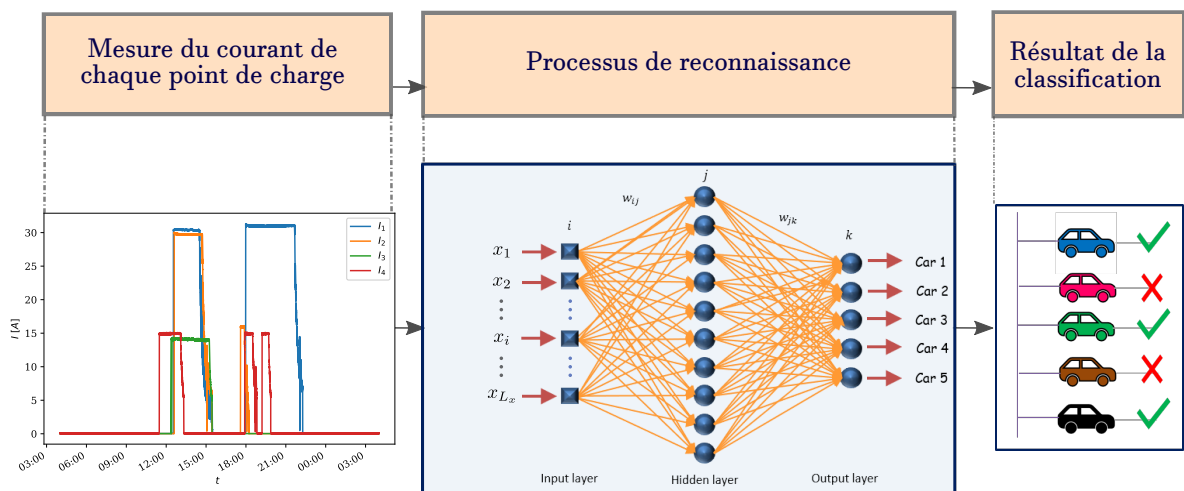


FIGURE 3-4 Topologie du réseau de neurones utilisé

Dans la couche cachée, les activations Z_j et la fonction d'activation non linéaire σ_j sont définies respectivement par (3.3) et (3.4). La fonction d'activation non linéaire utilisée est la

fonction sigmoïde.

$$Z_j = \sum_{i=1}^{L_x} w_{ij} \cdot x_i + p_j \quad (3.3)$$

$$\sigma_j(Z_j) = \frac{1}{1 + e^{-Z_j}} \quad (3.4)$$

où les paramètres w_{ij} et p_j sont les poids et les biais de la couche cachée. x_i sont les caractéristiques d'entrée ; et L_x définissent le nombre de neurones dans la couche d'entrée.

Dans la couche de sortie, les activations Z_k et la fonction d'activation non linéaire σ_k sont respectivement définies par (3.5) et (3.6). La fonction d'activation non linéaire utilisée est la fonction de transfert softmax.

$$Z_k = \sum_{j=1}^{L_h} w_{jk} \cdot \sigma_j(Z_j) + p_k \quad (3.5)$$

$$y_k = \sigma_k(Z_k) = \frac{e^{Z_k}}{\sum_{j=1}^{L_h} e^{(\sigma_j(Z_j))}} \quad (3.6)$$

où w_{jk} et p_k représentent les poids et les biais de la couche de sortie ; et L_h définissent le nombre de neurones dans la couche cachée.

L'algorithme d'apprentissage utilisé pour mettre à jour les paramètres du réseau est l'algorithme du gradient conjugué mis à l'échelle (*Scaled Conjugate Gradient algorithm* en anglais) [111].

En fait, le réseau de neurones développé favorise une procédure d'apprentissage supervisé. Les entrées et les cibles présentées au réseau sont disposées comme indiqué sur la Fig. 3-5. Chaque colonne $\bar{x}_{s_m}^m$ de la matrice d'entrée contient les caractéristiques x_{i,s_m}^m extraites de la fenêtre d'échantillonnage s_m^{th} du courant de charge alternatif au niveau de la borne de recharge pour le véhicule correspondant m , exprimé par (3.7).

$$\bar{x}_{s_m}^m = \bar{F}^{s_m} \quad (3.7)$$

où, \bar{F}^{s_m} contient les caractéristiques sélectionnées.

Matrice d'entrée	
$\xrightarrow{n_{data}}$	
$x_{1,1}^1$	$x_{1,2}^1 \dots x_{1,1}^m \ x_{1,2}^m \dots x_{1,1}^M \ x_{1,2}^M$
$x_{2,1}^1$	$x_{2,2}^1 \dots x_{2,1}^m \ x_{2,2}^m \dots x_{2,1}^M \ x_{2,2}^M$
\vdots	\vdots
$x_{Lx,1}^1$	$x_{Lx,2}^1 \dots x_{Lx,1}^m \ x_{Lx,2}^m \dots x_{Lx,1}^M \ x_{Lx,2}^M$

Matrice cible	
$\xrightarrow{n_{data}}$	
$y_{t,1}$	1 1 0 0 0 0
\vdots	\vdots
$y_{t,m}$	\vdots \vdots 1 1 \vdots \vdots
\vdots	\vdots
$y_{t,M}$	0 0 0 0 1 1

FIGURE 3-5 Construction de matrices d'entrée et de cible

Pour la matrice cible, chaque colonne est construite selon (3.8) [98].

$$y_t = \begin{cases} \begin{bmatrix} 1 & 0 & \dots & 0 \end{bmatrix}^T & , \text{ pour la première voiture} \\ \begin{bmatrix} 0 & 1 & \dots & 0 \end{bmatrix}^T & , \text{ pour la deuxième voiture} \\ \vdots & \vdots \\ \begin{bmatrix} 0 & 0 & \dots & 1 \end{bmatrix}^T & , \text{ pour la } M^e \text{ voiture} \end{cases} \quad (3.8)$$

3.2.2.2 Machines à vecteurs de support

Les machines à vecteurs de support (SVM) sont un autre type de classificateurs supervisés qui ont montré de bonnes performances dans la classification et la reconnaissance de modèles ces dernières années. Ils ont été conçus à l'origine pour la classification binaire avec l'idée de base de trouver l'hyperplan optimal pour les modèles linéairement séparables afin de minimiser les erreurs de classification pour les nouvelles observations. L'hyperplan de séparation optimal sera celui qui présente la plus grande marge, définie comme la distance minimale d'une donnée à la surface de décision (cela correspond à l'hyperplan noir sur la Fig. 3-6). Les données d'apprentissage qui tombent exactement sur les limites de la marge sont appelées vecteurs de

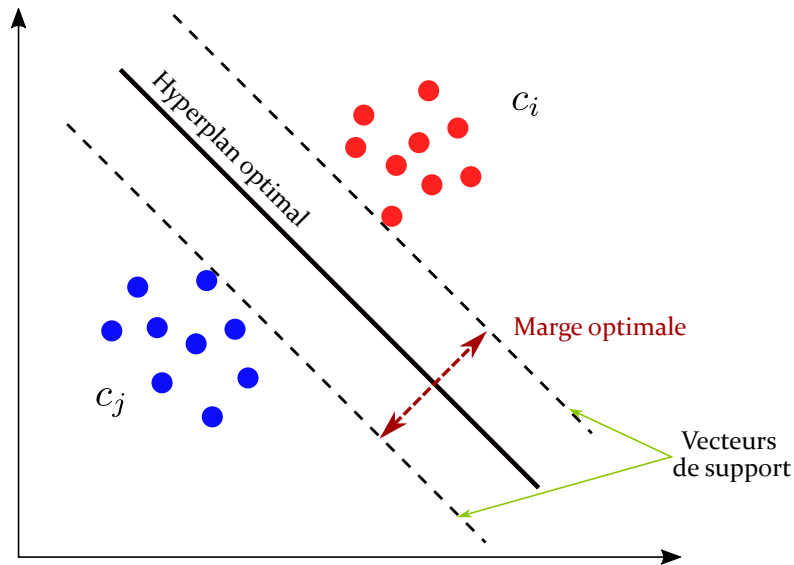


FIGURE 3-6 Exemple d'hyperplan et de marges maximales pour un SVM entraîné avec des échantillons de deux classes c_i et c_j .

support, car ils supportent l'hyperplan de marge maximale.

Différentes méthodes ont été proposées pour la classification multi-classes, ici c'est la méthode multi-classes un vs un qui a été utilisée. Elle consiste à construire des classificateurs $n_{class}(n_{class} - 1)$, où n_{class} est le nombre de classes et à entraîner chacun d'eux avec des données de deux classes différentes [110]. Étant donné les données d'apprentissage $(x_1, y_1), \dots, (x_{n_{ij}}, y_{n_{ij}})$ des classes c_i et c_j , nous résolvons le problème de classification binaire suivant sous forme d'optimisation quadratique convexe :

$$\min \left(\underbrace{\frac{1}{2} (w^{c_i c_j})^T w^{c_i c_j}}_{\text{Max. margin}} + C \underbrace{\sum_{t=1}^{n_{ij}} \zeta_t^{c_i c_j} (w^{c_i c_j})^T}_{\text{Min. error}} \right) \quad (3.9)$$

$$(w^{c_i c_j})^T x_t + b^{c_i c_j} \geq 1 - \zeta_t^{c_i c_j}, \text{ if } y_t = c_i$$

$$(w^{c_i c_j})^T x_t + b^{c_i c_j} \leq -1 + \zeta_t^{c_i c_j}, \text{ if } y_t = c_j$$

Où $w^{c_i c_j}$ représentent les paramètres de l'hyperplan optimal dans l'espace des caractéristiques ; x_t sont les échantillons utilisés pour l'entraînement du modèle. $b^{c_i c_j}$ est appelé un biais. $\zeta_t^{c_i c_j}$ est une variable muette et C est un paramètre de régularisation.

Une fois que tous les $n_{class} (n_{class} - 1)$ classificateurs sont construits, la stratégie "maximum de victoire" (ou "*Max Wins*" en anglais) [112] a été appliquée pour les tests futurs. En considérant une classe c_m , cette approche consiste à augmenter le vote pour la classe c_m d'une unité chaque fois qu'un des classifieurs indique que x est dans la classe c_m en utilisant la fonction de décision $sgn \left((w^{c_i c_m})^T x_t + b^{c_i c_m} \right)$. x est finalement classé dans la classe avec le plus grand nombre de votes.

3.2.3 Méthode SFS pour la sélection des caractéristiques les plus utiles

L'espace initial de caractéristiques utilisé dans cette étude contient un ensemble de 12 sous-ensembles vecteurs, présentés dans (3.1). Le défi ici est de choisir un espace de caractéristiques qui compte pour des informations «riches». À cet égard, la stratégie adoptée vise à examiner un large éventail de caractéristiques parmi lesquelles les plus efficaces sont sélectionnées en appliquant la méthode de sélection séquentielle (SS) [104]. Cette stratégie consiste à partir d'une définir et ajouter séquentiellement la caractéristique f_i^+ qui maximise la fonction critère $J(F_{subset,k} + f_i)$. Cela correspond à la caractéristique associée à la meilleure performance de classificateur lorsqu'elle est combinée aux caractéristiques déjà sélectionnées $F_{subset,k}$. L'algorithme SS est décrite dans le tableau 3-2.

TABLEAU 3-1 Méthode de sélection séquentielle (SFS)

Étapes	Faire pour $k = 0 : L_{st}$, (où k est la taille du sous-ensemble).
1.	Commencer avec un ensemble vide $F_{subset,0} = \{\emptyset\}$
2.	Sélectionner la prochaine meilleure caractéristique $f_i^+ = \underset{f_i \notin F_{subset,k}}{\operatorname{argmax}} J(F_{subset,k} + f_i)$
3.	Mettre à jour $F_{subset,k+1} = F_{subset,k} + f_i^+$
4.	Aller à 2

3.3 Modélisation des habitudes de recharge

La détection et l'identification réussies des profils de charge des différents VÉs et des moments de branchement et de débranchement permettent de bâtir de manière automatique des modèles stochastiques individuels de leurs habitudes qui peuvent être utilisés par le contrôleur de charge pour prendre des décisions intelligentes en matière de planification de leur période de recharge. L'exploitation de modèles comportementaux permet d'une part de réduire le rôle

des utilisateurs dans la fourniture des informations essentielles et d'autre part de fournir au contrôleur des moyens pour faire face aux incertitudes inhérentes à certains paramètres (durée de stationnement, modification du comportement de charge en fonction de la température ambiante, dégradation de la batterie, etc.). Les différentes propositions de cette thèse pour caractériser la demande de recharge des VÉs ont été présentées dans un article de revue publié en 2022 [113].

3.3.1 Modélisation des heures d'arrivée et de départ

Les informations sur les heures d'arrivée et de départ sont parmi les plus importantes en raison de leur incidence sur la programmation de la recharge des VE. En effet, ces paramètres influencent directement la décision relative à l'horizon de contrôle et le potentiel de flexibilité de la demande de recharge. De plus, en tant que variables aléatoires, ces informations sont inconnues du contrôleur avant leur occurrence, à moins que le propriétaire du VE les spécifie à l'avance. Néanmoins, cette dernière situation est peu pratique en raison de l'ignorance des utilisateurs des heures réelles d'arrivée et de départ ou de leur réticence à partager ces informations sur une base régulière. Aussi, l'incertitude sur ces paramètres peut conduire à une charge insuffisante au moment du départ et, par conséquent, à l'insatisfaction de l'utilisateur. Par conséquent, les conceptions de contrôleur visant une application pratique doivent tenir compte de l'incertitude des heures d'arrivée et de départ, car il s'agit d'une composante inhérente à la pratique de programmation de la recharge des VE.

Les chaînes de Markov [82] et les chaînes semi-markov [77] sont les techniques les plus populaires dans la littérature pour modéliser l'état du stationnement des VE. Ces techniques modélisent l'état du stationnement des VE comme une machine à deux états où les heures d'arrivée et de départ représentent les moments de transition. Les modèles basés sur la chaîne de Markov et les modèles semi-markoviens sont des techniques avancées pour modéliser l'état de stationnement des VÉs aux bornes de recharge. Cependant, ces méthodes sont confrontées à des difficultés liées au temps de calcul et à la convergence, car les solutions proposées peuvent devenir très volumineuses et difficiles à gérer. En effet, les modèles basés sur la chaîne de Markov évaluent la probabilité de changement d'état de stationnement par le biais d'une matrice de transition d'état à chaque pas de temps. Par conséquent, leur intégration dans

le processus d'optimisation stochastique peut conduire à un espace de décision complexe, en particulier lorsque le CR gère plusieurs VÉs, ce qui rend le problème d'optimisation compliqué à résoudre [44]. Les modèles semi-markoviens, qui utilisent une procédure similaire, sont également complexes. En effet, ils caractérisent l'état de disponibilité du véhicule en modélisant la durée de chaque état sous forme d'une distribution de probabilité à chaque pas de temps (durée de toutes les transitions (déplacements/arrivées) probable du VE) [77]. Ainsi, l'intégration de ces modèles dans un processus de décision stochastique peut entraîner une très grande complexité du modèle. En effet, la prise de décision en tenant compte des probabilités de transition à chaque pas de temps, mène généralement à un problème de d'optimisation basée sur la programmation dynamique stochastique pour évaluer les conséquences de toutes les transitions possibles sur la prise de décision optimale. De plus, la résolution de ces types de problème peut nécessiter un coût de calcul très élevé et des problèmes de convergence du problème d'optimisation [44], [77]. Ces problèmes peuvent poser de véritables défis dans la conception (logicielle et matérielle) des contrôleurs VE pour des applications pratiques. Par exemple, ils peuvent simplement augmenter le coût de l'équipement et éviter l'adoption par les clients. Puisque la gestion de ces circonstances est la première étape vers la faisabilité, l'utilisation de méthodes simples et efficaces dans le processus analytique est encouragée. À cet égard, l'utilisation de distributions de probabilité de variables aléatoires est définie comme une technique efficace pour modéliser leur comportement [114]. Compte tenu des limites des approches mentionnées, dans ce travail de recherche l'attention a été portée essentiellement vers une autre approche à travers un approche moins complexe et facilement praticabilité . L'approche proposée discrimine les différentes sessions à l'aide de l'information de l'heure de branchement et crée des groupes de similarité en conséquence. Dans un deuxième temps, elle utilise une méthode prometteuse d'estimation de la densité du noyau (KDE) [115] pour modéliser la distribution des heures de départ selon l'heure de branchement. En tant que modèle non paramétrique, la méthode KDE est bien adaptée pour modéliser les modèles de temps d'arrivée et de départ en estimant leurs densités. Cette méthode est en effet très utilisées dans la littérature peut décrire efficacement des séries temporelles dont les distributions sous-jacentes sont inconnues [116]. Par conséquent, ce schéma est un choix fiable pour les mises en œuvre dans le monde réel, comme le suggèrent les résultats finaux de l'étude. Cette approche

simplifie ainsi la modélisation de l'état du stationnement des VEs tout en conservant leur importance pour la programmation de la recharge. Une analyse préliminaire a été effectuée sur des données réelles collectées sur des bornes de recharge locales a prouvé que la durée de stationnement peut effectivement être décidée en fonction de l'heure de branchement.

Notons N_s le nombre d'observations (occurrences) de session de recharge dans la base de données et $c = \{m, a, e\}$ la catégorie des session de recharge de classe, où m est la catégorie des recharge du matin (VÉ branché avant midi), a la catégorie des recharge de l'après midi et e la catégorie des recharge de en fin de journée et soirée. Les différents groupes de données forment donc des cluster comme illustré sur la Figure 3-7




FIGURE 3-7 Catégorisation des différentes sessions de recharge selon l'heure de branchement.

Vise versa, on peut catégoriser les heures d'arrivée selon les heures de départ historiques. Ainsi pour chaque cluster, nous modélisons la densité de probabilité de la distribution à l'aide de la technique Kernel Density Estimation (KDE).

$$\hat{f}(x) = \frac{1}{N_s h} \sum_{j=1}^{N_s} K\left(\frac{x - T(j)}{h}\right) \quad (3.10)$$

où N_s est le nombre total d'échantillons, $h > 0$ est un paramètre de réglage définissant la largeur de bande, $T(j)$ est la donnée d'observation j^e , et K est la fonction Kernel gaussienne. En tant que méthode non paramétrique, la KDE est parfaitement adaptée à la modélisation des modèles de temps de départ par l'estimation de leurs densités. C'est un choix fiable pour

les conditions incertaines puisqu'il peut décrire efficacement des séries temporelles avec des distributions sous-jacentes inconnues.

3.3.2 *Modélisation des demandes d'énergie pour la recharge*

De la même manière que pour les heures d'arrivée et de départ, le contrôleur peut construire des modèles de consommation énergétique individuelle pour améliorer sa prise de décision. Dans le même temps, ces modèles visent à doter le CR de la capacité d'anticiper les besoins en énergie de recharge des VE sur la base de données historiques, d'apprendre de leurs habitudes de charge et de proposer des plans de charge optimaux tout en étant plus robuste aux défaillances de communication, sans compromettre la satisfaction des utilisateurs. Enfin, une meilleure caractérisation de la demande à partir des données historiques permet de minimiser le rôle de l'utilisateur dans la fourniture de certaines informations telles que les préférences de charge à travers les données historiques des préférences, le SOC de la batterie .

3.3.2.1 *Modèles non paramétriques*

Puisque la distribution de la densité de probabilité de la demande d'énergie pour la recharge des VE n'est pas connue a priori, comme pour les heures d'arrivée et de départ, l'estimateur de densité à noyau (« KDE ») [117] peut être utilisé pour caractériser cette densité. Cette fonction de densité de probabilité de la demande d'énergie peut exploiter par le système EMS pour définir la priorité de charge de chaque VÉ, pendant les périodes de pointe par exemple.

Mais aussi, le système EMS peut utiliser les distributions de densité de probabilité de la demande d'énergie pour anticiper les besoins énergétiques pour la recharge des VÉs. À cet égard, il peut réduire la variance des distributions en construisant des distributions conditionnelles basées sur d'autres informations telles que le moment du branchement, les variables météorologiques (température, précipitations, etc.). Néanmoins, la prise de décision basée sur une deuxième distribution de densité de probabilité implique de traiter le problème d'optimisation comme une optimisation stochastique avec deux variables incertaines, ce qui augmente la complexité de calcul du problème. De plus, cette approche est peu sensible aux changements d'habitudes à court terme en raison de l'évolution lente des paramètres des

distributions, ce qui signifie, par exemple, que les estimations des besoins énergétiques de chaque lundi seront très similaires sur une très longue période de temps.

3.3.2.2 *Modélisation des habitudes de recharge*

Cette section présente les résultats de la modélisation statistique des habitudes de recharge des différents VÉs. Les données utilisées pour cette analyse ont été collectées entre janvier 2013 et janvier 2018. Les distributions de consommation pour les cinq VÉs sont présentées dans la Figure 4-13. Il est important de noter que les quantités de données par classe (VÉ) sont disproportionnées en fonction de l'historique de recharge de chaque VÉ ainsi que la date initiale d'utilisation des bornes de recharge locales. Cependant, les distributions statistiques montrent que les habitudes de recharge sont très différentes pour les cinq VÉs. En effet, les distributions des VÉs 2, 3 et 4 sont plus étroites. Par conséquent, leurs besoins énergétiques pour la recharge peuvent être prédits plus facilement avec une erreur de prévision relativement faible en utilisant un bon modèle prédictif. En revanche, la consommation des VÉs 1 et 5 est mieux répartie sur l'axe des abscisses avec certains comportements non stationnaires. Dans ce cas de figure, la corrélation entre la demande d'énergie pour la recharge et d'autres variables indépendantes telles que l'heure de branchement, les variables calendaires et météorologiques pourrait aider à anticiper les besoins de charge.

3.3.3 *Modèle d'anticipation des besoins de recharge des VÉs*

Cette section présente les travaux sur le développement d'un modèle prédictif et adaptatif, plus sensible aux changements d'habitudes que les modèles de caractérisation de la demande énergétique basés sur des distributions de densité de probabilité. Les différentes parties de ce travail de recherche supposent que le contrôleur de charge externe EMS ne dispose pas d'un accès direct aux informations sur le niveau de charge de la batterie provenant du véhicule en temps réel. Cela découle du fait que les fabricants de VE n'ont pas encore mis en œuvre de protocoles de communication pour faciliter ce type d'échange d'informations entre des systèmes tiers tels que le EMS et le contrôleur embarqué du véhicule électrique personnel. Par conséquent, le EMS n'utilise que l'échange d'informations entre le véhicule et la station de charge, en particulier les mesures de la puissance de charge. En effet, ces informations, fournies

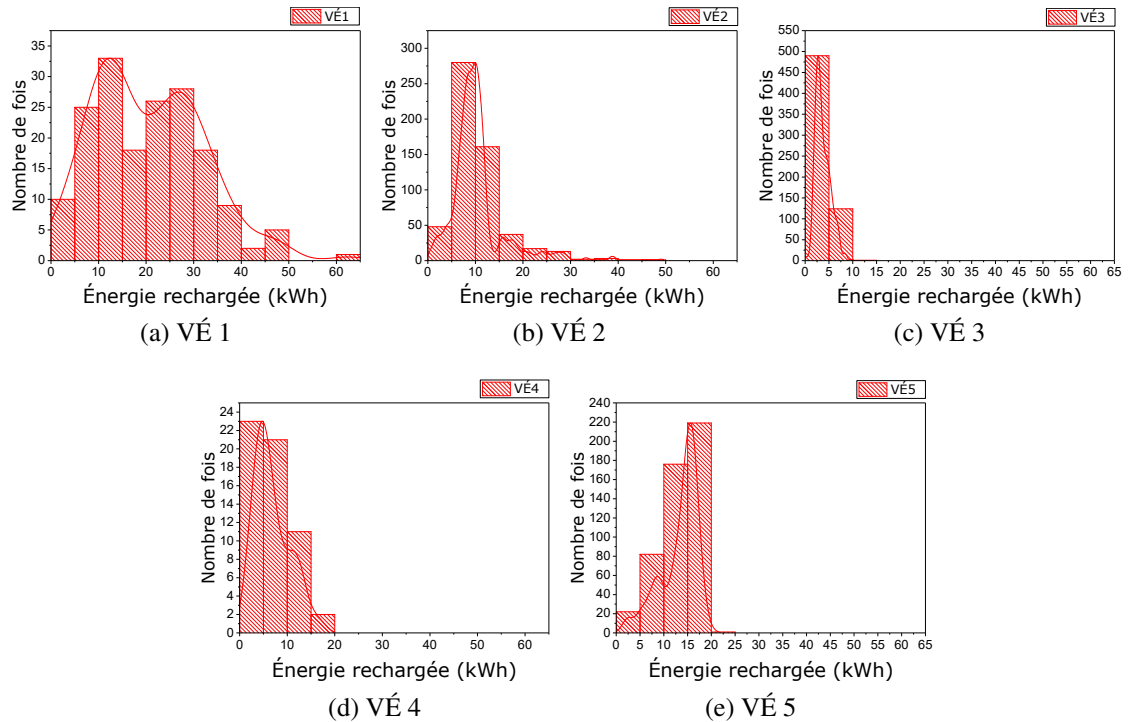


FIGURE 3-8 Densités de probabilité de la demande d'énergie des 5 VÉs (estimation de densité par noyau et histogramme).

par le contrôleur, permettent au EMS de gérer efficacement la charge du véhicule électrique personnel en l'absence de communication directe entre eux. De plus, les données de mesure de la station de charge sont accessibles au contrôleur PEV sans protocole de communication spécifique. De plus, ces données de charge sont les informations les plus riches qui peuvent être utilisées pour saisir le comportement du véhicule électrique personnel, en particulier la nature non linéaire du profil de puissance de charge. En effet, ces statistiques, collectées à la station de charge, sont plus précises que les informations sur la distance parcourue, qui sont affectées par les sessions de charge, effectuées à l'extérieur de la maison [96].

Les différentes composantes de ce travail de recherches supposent que le système contrôleur de charge externe EMS n'a pas un accès direct à l'information sur le niveau de charge de la batterie à partir du véhicule en temps réel. Cela est dû à la non mise en oeuvre jusqu'à présent par les constructeurs des VÉs de protocole de communication pour faciliter ce type d'échange d'information entre les systèmes tiers tels que le système EMS et le contrôleur embarqué du véhicule électrique personnel. Par conséquent, le EMS n'utilise que l'échange

d'informations entre le véhicule et la station de charge, en particulier les mesures de la puissance de charge. En fait, ces informations, fournies par le contrôleur, permettent au EMS de gérer efficacement la charge du véhicule électrique personnel en l'absence de communication directe entre eux. De plus, les données de mesure de la station de charge sont accessibles au contrôleur du PEV sans protocole de communication spécifique. Aussi, ces données de charge sont les informations les plus riches qui peuvent être utilisées pour saisir le comportement du véhicule électrique personnel, en particulier la nature non linéaire du profil de puissance de charge. En effet, de telles statistiques, collectées au niveau de la borne de recharge, sont plus précises que les informations sur la distance parcourue, qui sont affectées par les sessions de recharge, effectuées à l'extérieur de la maison [96]. Le principal intérêt pour ce travail de thèse est de développer des modèles prédictifs pour les VÉs en se basant sur des informations stochastiques des activités de charges des VÉs aux terminaux de charge domestiques.

L'objectif ultime est de fournir un outil efficace efficace qui assiste le système EMS dans la gestion de la demande même dans les situation où la communication *EMS/Infrastructure-VÉ* est très minime ou peu fiable, c'est-à-dire que le système EMS ne connaît pas le SOC des VE a priori, à moins que cela ne soit spécifié par l'utilisateur. Cet outil peut également permettre aux propriétaires de VÉ de participer au marché transactionnel de l'énergie en vue de minimiser le coût de la recharge de leur VE dans ce type de marché. En effet, ces marchés sont généralement négociés un jour à l'avance, les utilisateurs doivent donc anticiper leurs besoins de charge pour le lendemain et leur plan de charge. Par ailleurs, les performances d'un système de gestion de la charge des VÉs dépendent en grande partie de la précision des prévisions de la demande individuelle pour chaque VÉ. De ce fait, des méthodes de prévision assez performantes sont nécessaires pour une meilleure anticipation des besoins de recharge des VÉs. Plusieurs méthodes de prévision ont été proposées dans la littérature à cet effet [117] - [118] - [119]. Compte tenu de l'objectif de conception du contrôleur de charge visé dans ce travail, un modèle de prédiction est développé dans le but non seulement d'estimer la demande d'énergie pour la recharge mais aussi de quantifier l'incertitude associée à cette prédiction. Ce mécanisme de contrôle examine le comportement stochastique de la demande énergétique du VE au début de chaque session de charge pour planifier sa charge.

Soit \hat{y}_s la demande d'énergie estimée pour la recharge du VE lors de la s^e session de

recharge, et x_s et y_s les vecteurs d'entrée des variables exogènes et endogènes historiques, respectivement. L'objectif est de définir le modèle de prévision, f , qui prédit \hat{y}_s avec le moins d'erreur possible. La formulation mathématique générale de ce modèle est décrite par (3.11),

$$\hat{y}_s = f(x_s, y_s, \theta_x, \theta_y) \quad (3.11)$$

où θ_x et θ_y sont les paramètres du modèle associés à x_s et y_s , respectivement. Le vecteur des variables exogènes, x_s , est composé des facteurs calendrier et météorologique comme prédicteurs. Le facteur calendrier contient l'heure de branchement en heures décimales, t_s^{pi} , le jour de la semaine, wd_s , et le numéro de la semaine, wk_s . Le facteur météorologique comprend la température moyenne, \bar{T}_s , en °C, l'ensoleillement moyen, $\bar{S}l_s$, en kJ/m^2 , la vitesse moyenne du vent, \bar{v}_s^v , en m/s , et les précipitations, Pr_s , en mm pendant le jour de la session de charge. Le vecteur de variables autorégressives, y_s , englobe l'historique des besoins en énergie de charge au cours des l dernières sessions de charge à la station de recharge.

Dans cette partie, la stratégie adoptée a été de prendre en compte tous les prédicteurs et ensuite d'utiliser la méthode de *sélection séquentielle en avant* (Sequential Forward Selection method) pour sélectionner les meilleurs en fonction de leurs performances de prévision [96]. Différents modèles prédictifs peuvent être utilisés pour créer la fonction f . Ici, une approche de modélisation linéaire est utilisée comme suit,

$$\hat{y}_s = x_s \theta_x + y_s \theta_y \quad (3.12)$$

Étant donné un nombre d'observations de n (sessions de recharge déjà réalisées), l'objectif est d'estimer les paramètres $\{\theta_x; \theta_y\}$ permettant une prédiction générale efficace les données observées afin d'obtenir une meilleure de la demande actuelle/future de recharge du VE. Dans ce travail, le choix a été porté sur l'inférence bayésienne pour estimer les paramètres du modèle. L'inférence bayésienne exprime les paramètres de régression en termes de distributions de probabilité [39]. Elle utilise le théorème de Bayes pour fournir la distribution postérieure des paramètres du modèle au lieu d'une unique meilleure estimation de ces paramètre comme pour les méthodes fréquentistes [120]. En ce sens, cette approche fournit un moyen de quantifier

les incertitudes du modèle.

Le processus d'apprentissage bayésien commence par la définition de la distribution de probabilité antérieure (*prior distribution*) des paramètres du modèle, en tant que croyance initiale (*initial believe*), avant l'observation de toute donnée. La distribution antérieure est ensuite mise à jour en utilisant des données observées et le théorème de Bayes pour construire la distribution postérieure [120], comme suit,

$$P(\theta, \sigma | X, Y) \propto P(Y | \theta, X, \sigma) P(\theta) P(\sigma) \quad (3.13)$$

où $\theta = [\theta_x, \theta_y]^T$ et σ représentent les paramètres du modèle, et X et Y sont les observations historiques des prédicteurs (entrées) et la demande de d'énergie (sortie), respectivement. $P(Y | \theta, X, \sigma)$ est la vraisemblance de l'observation, et $P(\theta)$ et $P(\sigma)$ sont les distributions antérieures sur θ et σ , respectivement. La vraisemblance $P(Y | \theta, X)$ peut être calculée par ,

$$P(Y | \theta, X, \sigma) = \prod_{i=1}^n P(y_i | \theta, x_i, y_i, \sigma) \quad (3.14)$$

Du point de vue bayésien, on peut supposer que y_i est une variable aléatoire univariée qui suit une distribution gaussienne basée sur [121],

$$P(y_i | \theta, x_i, y_i, \sigma) = \mathcal{N}(y_i; f(x_i, y_i, \theta), \sigma^2) \quad (3.15)$$

où \mathcal{N} représente la fonction gaussienne, $f(x_i, y_i, \theta)$, comme prédiction du modèle, est la moyenne de la gaussienne, et σ^2 la variance. En raison de sa valeur inconnue, on peut supposer que σ peut être expliqué par une distribution antérieure de type Gama inverse selon,

$$P(\sigma) = \text{Inv-Gamma}(\alpha, \beta) \quad (3.16)$$

où α et β sont les paramètres de forme et d'échelle, respectivement.

De même, la distribution de probabilité antérieure de θ peut également être considérée comme une distribution gaussienne, expliquée par [120],

$$P(\theta) = \frac{1}{Z(\nu)} \exp\left(-\frac{\nu}{2} \|\theta\|^2\right) \quad (3.17)$$

où ν est un hyperparamètre et $Z(\nu)$ désigne une constante de normalisation. Les équations (3.15)-(3.17) sont utilisées pour dériver les distributions postérieures des paramètres du modèle dans (3.13). Par la suite, la demande de charge de la session de recharge en cours peut être estimée en calculant l'espérance de la distribution postérieure du modèle prédictif, définie par [122],

$$\hat{y}_s = \mathbb{E}(y_s | \mathbf{x}_s, \theta) \approx f(\mathbf{x}_s, y_s, \hat{\theta}_{\text{MAP}}) \quad (3.18)$$

où $\hat{\theta}_{\text{MAP}}$ est l'estimation maximale a posteriori (MAP) de θ donnée par $\hat{\theta}_{\text{MAP}} = \arg \max_{\theta} (P(Y|\theta, X) P(\theta))$. Plus précisément, l'espérance dans (3.18) est estimée par échantillonnage de la distribution postérieure de θ selon la technique de Monte Carlo par chaîne de Markov (MCMC) [122]. Ensuite, la valeur de l'espérance est utilisée pour quantifier le besoin minimal en énergie pour la recharge du VÉ à la s^e session de charge en considérant le niveau de satisfaction de l'utilisateur de η , \hat{y}_s^{\min} ,

$$\hat{y}_s^{\min} = \hat{y}_s + \delta_{\eta} \sigma \quad (3.19)$$

où δ_{η} est une constante positive. Cette valeur est choisie de manière à ce que le côté droit de (3.19) offre la limite supérieure du niveau de confiance égale à η .

3.3.4 Estimation du profil de charge

La puissance de charge est un paramètre important dans le modèle dynamique de la batterie. Une estimation précise du profil de puissance permet une meilleure estimation de la durée de recharge qui dépend de plusieurs facteurs dont le SOC initial et la température. L'estimation de la durée de recharge est en fait très essentiel pour une meilleure planification de la de recharge . Toutefois, l'information du profil de puissance de charge est lié à la réalisation des actions

future de contrôle de la charge qui ne sont pas disponible par le contrôleur au moment du branchement. Toutefois, l'information du profil de puissance de charge est lié à la réalisation des actions future de contrôle de la charge qui ne sont pas disponible par le contrôleur au moment du branchement.

Le mode de charge " courant constant (CC) - tension constante (CV), CCCV ", qui est une technique très courante dans la conception des systèmes de gestion des batteries ou BMS (*Battery Management System* en anglais), entraîne un comportement non linéaire de la puissance de charge du VE qui a souvent été négligé dans divers travaux similaires dans la littérature. Cependant, la technique de contrôle de charge CCCV fait que le profil de la puissance de charge du VÉ a un comportement non linéaire. Le contrôleur proposé, contrairement aux travaux similaires, estime le profil de puissance de charge du VE en utilisant à la fois son besoin énergétique estimé au moment de la connexion et son historique de charge. En particulier, il exploite les informations sur la durée des phases de tension constante (CV) et de courant constant (CC) pour établir ce profil. Ces informations sont obtenues à partir du comportement de la demande de charge dans ces phases. La durée et les besoins en énergie de la phase CV sont tirés d'une session de charge historique complète, car le comportement de la batterie du VE dans cette phase est similaire d'une session de charge à une autre [123]. Par la suite, le besoin de charge de l'étape CC peut être calculé comme suit,

$$\hat{y}_s^{CC} = \hat{y}_s^{\min} - y_l^{CV} \quad (3.20)$$

où dans la session courante s , y_s^{CC} et y_l^{CV} sont la demande d'énergie dans les phases CC et CV. De plus, la durée de cette phase, \hat{t}_{CC} , c'est-à-dire le temps de commutation comme indiqué sur la Fig. 3-9, peut être estimée par ,

$$\hat{t}_{CC} = \frac{\hat{y}_s^{CC}}{p_0^{ev}} \frac{60}{\Delta t} \quad (3.21)$$

que p_0^{ev} est la mesure de la puissance de charge réelle au moment du branchement. Ensuite, le profil de charge peut être créé par ,

$$\hat{p}_k^{ev,s} = \begin{cases} p_0^{ev,s} & \text{for } k \in [t_{pi}, \hat{t}_{CC}] \\ p_j^{ev,l} & \text{for } k \in [\hat{t}_{CC} : \hat{t}_{CC} + t_{CV}^l] \end{cases} \quad (3.22)$$

où $p_j^{ev,l}$ est la puissance de charge réelle de la phase CV pendant la dernière charge complète. Par conséquent, la moyenne du profil de puissance construit fournit \bar{p}^{ev} dans (3.33b) afin de faciliter la fourniture d'une solution optimale par le problème d'optimisation proposé, comme mentionné.

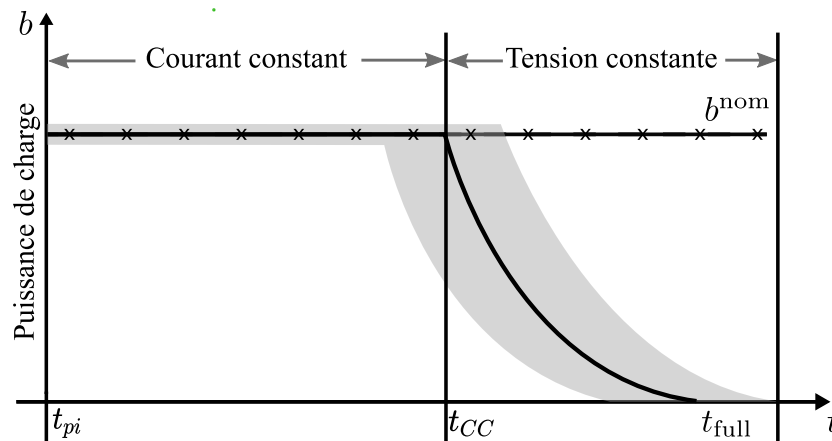


FIGURE 3-9 Profil typique de la puissance de charge non contrôlée pour une batterie Li-ion.

3.4 Planification de la recharge des VÉs : Approche déterministe

Sur la base de modèles prédictifs des différents paramètres stochastiques influents la demande de recharge des VÉs, la stratégie de la commande prédictive, adaptative et basée sur l'optimisation stochastique a été privilégiée en raison de sa capacité à gérer les incertitudes des paramètres du VÉ [59], [77].

La question de la programmation intelligente de la recharge des VÉs est généralement formulée comme un problème d'optimisation à court terme en considérant les besoins du contrôleur EMS. L'objectif principal du CR est de minimiser le coût de la recharge du VÉ tout en satisfaisant les contraintes du système et les préférences de l'utilisateur. Ces objectifs sont

influencés d'une part par le profil du signal RD, sa dynamique, sa forme et son amplitude, et d'autre part par la demande d'énergie et de puissance pour la recharge ainsi que la durée de stationnement.

3.4.1 Formulation du problème d'optimisation

Soit λ le signal de RD, $\bar{P}^{ev,n}$ la puissance de charge du VÉ, g le coût de la recharge dans un scénario de recharge non contrôlée peut être exprimée comme suit,

$$g(\lambda, \bar{P}^{ev,n}) = \sum_{k=0}^{N-1} g_k \quad (3.23)$$

$$g_k = \lambda_k p_k^{ev} \Delta t \quad (3.24)$$

où N l'horizon de prédiction ou de contrôle couvrant la durée de stationnement, k est le pas de temps discret de contrôle, g_k , λ_k et p_k^{ev} représente respectivement le coût de charge instantané, le signal de DR (prix de l'électricité ou signal d'incitatif) et la puissance de charge instantanée à l'instant k et Δt est l'intervalle de temps.

Dans le cadre d'une programmation intelligente de la charge, le rôle du CR est de contrôler la décision de charge dans chaque intervalle de temps en fonction du signal DR. La modulation du profil de la puissance de charge étant gérée par le chargeur embarqué dans le cadre de recharges de faible puissance (station de charge de niveau 1 et 2), le CR externe peut cependant contrôler le processus de charge soit par le biais du signal pilote de contrôle, soit par le contrôle de l'alimentation électrique de la station de charge à travers des commandes ON/OFF pour laisser le véhicule charger ou d'interrompre sa charge. En effet, le port pilote de contrôle série permet à la borne de recharge ou un contrôleur tierce de contrôler de la puissance maximale que la borne peut délivrer et le chargeur embarqué EV gère en conséquence la modulation de la puissance de charge en tenant compte de cette puissance maximale et autres paramètres du pack de batterie (l'état de charge de charge, tension, température, état de santé, etc.). La fonction principale du chargeur intégré au véhicule est d'assurer la charge du pack de batterie dans de meilleures conditions. Ainsi, le CR externe peut jouer sur ces commandes externes pour planifier la charge du véhicule en tenant compte des externes (signal de RD, préférences

de l'utilisateur, etc.,). La stratégie la plus répandue dans les pratiques de programmation de la recharge des VÉs individuels consiste à permettre à la borne de fournir sa puissance maximale afin de minimiser le temps de recharge, qui est un critère important pour les utilisateurs, et à programmer les périodes de recharge de manière à éviter la recharge pendant les heures de pointe grâce au contrôle de la puissance. D'autre part, dans les applications de charge coordonnée de plusieurs VÉ en présence de contraintes physiques sur la capacité maximale de l'infrastructure de recharge, la puissance maximale que la borne de charge peut allouer pour la charge peut être relaxée pendant les périodes de fortes contraintes. Dans le cadre des recharges individuelles présenté dans ce chapitre nous considérons seulement la commande de l'alimentation électrique entre la borne et le véhicule.

Soit u une variable binaire représentant la variable de décision de contrôle de l'alimentation de charge du VÉ (ON/OFF). L'objectif principal du CR est définir des actions de contrôle optimales, u_k^* , qui minimisent le coût de la charge tout en satisfaisant les contraintes du système à chaque intervalle de temps k . Le coût optimisé de la charge peut être noter comme $g^*(\lambda, \bar{P}^{ev,n})$:

$$g^*(\lambda, \bar{P}^{ev,n}) = \sum_{k=0}^{N-1} g_k u_k^* \quad (3.25)$$

Les actions de contrôle optimales, u_k , doivent tenir compte des contraintes physiques du système (véhicule, batterie) et ainsi que les préférences des utilisateurs. Ces contraintes sont liées à l'état de charge de la batterie qui est la variable d'état du système de contrôle. Les contraintes initiales tiennent compte de l'état du système à l'heure du branchement et les contraintes finales sont définit par les préférences de charge de l'utilisateur et enfin le contrôleur est responsable de maintenir un niveau de charge dans le plage de fonctionnement fiable du pack de batterie par exemple dans le cadre de recharge bidirectionnelle (véhicule-vers-infrastructure ou véhicule-vers-réseau).

Les principales contraintes étant liés à l'état de charge du pack de batterie du VÉ. La modélisation de sa dynamique est donc une pratique essentielle dans le processus de programmation intelligente de la recharge du VÉ. L'approche la plus populaire pour modéliser la dynamique de l'état de charge du pack de batteries du VÉ dans ses pratiques de planification de sa charge

est le modèle linéaire basé sur le comptage de coulomb comme suit :

$$\frac{d \text{SOC}}{dt} = \frac{\eta}{Q_b} p^{\text{ev}} \quad (3.26)$$

L'équation (3.26) peut s'écrire sous la forme discrète suivante :

$$\text{SOC}_{k+1} = \text{SOC}_k + \frac{\eta}{Q_b} p_k^{\text{ev}} \Delta t \quad (3.27)$$

où SOC_k est l'état de charge du pack de batterie au pas de temps k , η représente l'efficacité de conversion d'énergie, p_k^{ev} est la puissance de charge ou décharge en kW, Q_b est la capacité nominale de la batterie en kWh.

Dans l'équation dynamique (3.27) la variable de contrôle est la puissance de charge. Cependant, étant donné que pour les recharge avec les bornes de type 1 et 2 le contrôle de la charge est réellement géré par le chargeur intégré qui tient compte de l'aspect sécurité et l'état de santé de la batterie. L'équation de la dynamique est donc modifier pour intégrer la variable de contrôle binaire comme suit,

$$\text{SOC}_{k+1} = \text{SOC}_k + \frac{\eta}{Q_b} p_k^{\text{ev}} \Delta t u_k \quad (3.28)$$

Grâce à l'information des conditions initiales, le contrôleur CIPR peut alors estimer à chaque étape l'évolution du SOC en fonction des actions de contrôle u_k pour assurer les contraintes finales tout en minimisant la fonction de coût.

p_k^{ev} étant un paramètre variable dans le temps, l'équation (3.28) a un comportement linéaire variable dans le temps. À cet égard, la solution optimale est difficile à trouver par les approches d'optimisation classiques. Par conséquent, le paramètre p_k^{ev} est généralement représenté dans la littérature par une constant, égal à la puissance nominale, P^{ev} . Finalement, le problème d'optimisation est formulé comme suit,

$$\underset{u_0, \dots, u_{T-1}}{\text{minimize}} \quad \sum_{k=0}^{T-1} \lambda_k \bar{P}^{\text{ev},n} \Delta t u_k \quad (3.29a)$$

$$\text{subject to} \quad 0 \leq u_k \leq 1, \quad (3.29b)$$

$$SOC_{k+1} = SOC_k + \frac{\eta \bar{P}^{\text{ev},n} \Delta t}{Q_b} u_k, \quad (3.29c)$$

$$SOC_0 = SOC_{\text{pi}}, \quad (3.29d)$$

$$SOC_T^{\min} \leq SOC_T \leq SOC_T^{\max} \quad (3.29e)$$

où SOC_{pi} est l'état de charge initial du pack de batterie à l'instant du branchement, t_{pi} . SOC_T^{\min} et SOC_T^{\max} représentent l'état de charge minimum et maximum de la batterie, requis au moment du départ pour les prochains déplacements du propriétaire et T l'heure de départ.

Le modèle dynamique de la batterie permet au contrôleur de charge de tester différentes stratégies de contrôle et sélectionner la stratégie optimale qui respectent les différentes contraintes du problème d'optimisation. Par conséquent, la fidélité du modèle est un facteur important, car les performances ou encore l'optimalité du contrôleur dépend en grande partie de la fidélité du modèle utilisé en termes de sa capacité à reproduire adéquatement la réponse du système physique. Le modèle in (3.29c), quand bien qu'il soit le plus populaire, n'est pas le plus fidèle à son état en raison principalement de sa linéarité et le comportement non linéaire de la puissance de charge. En effet, les principales paramètres du modèle ont le plus souvent été considéré constants. Mais en réalité, la plupart de ces paramètres varient de le temps avec des dynamiques différents. Par exemple, la durée de la charge est un paramètres incertain qui dépend de plusieurs facteurs dont la température en plus de l'état de charge initiale du pack de batterie, la capacité disponible ainsi que la puissance réel de charge. Dans la vie réelle, la capacité du pack de batterie en temps que paramètre physique a une dynamique de variation lente qui est liée essentiellement à la dégradation de la batterie. Cette dégradation de la capacité peut avoir un impact sur la fidélité du modèle qui doit être considérée. D'autres part, l'énergie réelle chargée dans le pack de batterie est plus faible à très basse température en raison de la part élevée des pertes de polarisation d'activation tandis que la capacité disponible augmente légèrement avec la température. En dehors, de ces facteurs, les études supposent

généralement le processus de charge des VÉs avec un taux de charge constant ce qui n'est pas le cas réel. En particulier, cette approche néglige le comportement non linéaire de la puissance de charge des VPE, qui est régie par deux modes de fonctionnement, à savoir le mode à courant constant et le mode à tension constante (CCCV). Cela a été démontré dans la figure 3-9 qui présente une session de charge de PEV basée sur les modes CCCV, commutés à t_{CC} . Dans cette figure, la variance du profil de charge (limite grise) est attribuée à l'incertitude de la durée de charge due à des facteurs externes tels que la température ambiante et la précision de l'estimation du SOC de la batterie. Ces facteurs quand bien importants n'ont pas fait l'objet de beaucoup d'études dans la proposition de stratégie de contrôle intelligent de la recharge des VÉs dans la littérature.

Pour conclure, l'approche déterministe suppose que tous les paramètres de modélisation sont parfaitement connus et accessibles par le contrôleur de manière automatisée au cours de chaque session de charge. Cependant, dans la pratique la programmation de la charge des VÉs peut être sujette à plusieurs sources d'incertitudes dont celle liées à l'absence de paramètres de charge critiques tels que l'information sur l'heure de départ et d'arrivée qui sont par nature des paramètres incertains, le SOC de la batterie qui n'est pas souvent facilement accessible depuis la borne pour la plupart des modèles de VÉs existants. En plus, les informations non accessibles par le CR doivent être renseignées par les utilisateurs sur une base régulière (à chaque session de recharge). En définitive, ces hypothèses de l'approche déterministe peuvent entraver la mise en œuvre réelle des différents schémas de contrôle proposés dans la littérature sur la base cette base. Compte tenu de ces limites de l'approche déterministe, ce travail de recherche s'est tourné vers une approche stochastique pour aborder le problème de l'ordonnement intelligent de la recharge des VE.

3.5 Planification de la recharge des VÉs : Formulation stochastique

Cette étude suppose que les informations sur les heures d'arrivée et de départ sont incertaines et peuvent être indisponibles pour le CR avant leurs occurrences. En ce qui concerne la fourniture d'informations critiques au CR, cette étude présume que le moment de la connexion peut être identifié par le biais des données de mesure de la puissance de l'alimentation entre la borne de recharge et le VÉ une fois que ce dernier est branché. De même, le CR est en mesure

de détecter les moments de déconnexion (départ) à l'aide d'un capteur dédié. Ce travail de recherche examine en particulier la situation de l'indisponibilité d'un port de communication physique entre la borne (ou le CR) et le véhicule pour obtenir des informations sur l'état de charge de la batterie directement auprès du contrôleur interne du véhicule. Le cadre du contrôleur de charge intelligent développé a été présenté dans l'article de journal [113].

Le CR s'appuie ainsi, essentiellement sur l'échange d'informations accessibles entre le véhicule et la borne de charge, en particulier les mesures de la puissance de charge pour gérer efficacement la charge du VÉ en l'absence de communication directe avec le VÉ ou de la fourniture des informations par les utilisateurs. En outre, les données collectées à la borne de recharge sont pertinentes et riches en informations car elles peuvent être utilisées pour capturer d'une part le comportement non linéaire du processus de recharge, en particulier la demande de puissance, et d'autre part pour mieux caractériser le profil de recharge en tenant compte des incertitudes sur la durée réelle de la recharge du VÉ liées à des facteurs externes tels que la température ambiante. En effet, de telles informations, collectées au niveau de la borne de recharge, sont plus précises que les informations sur la distance parcourue (très utilisée dans la littérature), qui peuvent être affectées par les sessions de recharge effectuées à l'extérieur de la maison. Ces sources d'information ouvrent la voie à des solutions alternatives permettant de minimiser l'intervention récurrente des utilisateurs dans la fourniture des informations essentielles mais aussi de mieux prendre en compte les incertitudes liées à certains facteurs externes tels que la température sur le comportement de la charge (durée, profil de puissance, etc.). En outre, les technologies qui nécessitent que les utilisateurs fournissent régulièrement des informations essentielles sont susceptibles de les décourager d'adopter ces technologies dans la vie réelle. La caractéristique recherchée ainsi pour le CR ciblé est d'être capable d'exécuter sa fonction de planification de la charge du véhicule même en l'absence d'un accès à certaines informations critiques (heure d'arrivée et de départ) ou lors de défaillances de communication (SOC), qui constituent de véritables défis dans la mise en œuvre de nouvelles technologies. Par exemple, ce travail suppose que l'utilisateur peut oublier de communiquer au CR l'information précise de l'heure de son prochain départ ou que lui-même n'a pas une connaissance précise de cette information. Dans cette situation, le contrôleur doit toutefois être à mesure d'assurer sa fonction de planification de la recharge des véhicules de manière à

minimiser le coût tout en assurant un certain niveau de satisfaction de l'utilisateur en terme SOC final de la batterie au moment de la déconnexion pour son prochain déplacement. Pour atteindre cet objectif, le contrôleur doit gérer l'incertitude relative à l'heure de départ, à la durée de la charge et aux informations sur les besoins en énergie qui peut compromettre certains de ses objectifs, notamment la satisfaction de l'utilisateur quant à la quantité d'énergie disponible dans le VÉ au moment du débranchement pour les futurs déplacements. Le schéma du contrôleur proposé s'appuie sur des modèles statistiques sur les données historiques de charge et de préférences des utilisateurs pour prendre des décisions de programmation de la recharge des VÉs même en absence d'informations critiques pour la charge (par exemple SOC, t_{dep}). Ces modèles permettent d'une part de minimiser les interventions et les sollicitations régulières des utilisateurs. D'autre part, ils permettent au contrôleur d'être plus robuste aux défaillances de communication, qui constituent un défi majeur dans la vie réelle.

3.5.1 Modélisation stochastique du problème de la recharge des VÉs

Compte tenu de l'information indirecte utilisée qui est la mesure de puissance, la méthode du comptage de Coulomb (CC), utilisée pour calculer cette variable dans (3.29c), peut être reformulée en considérant l'énergie comme la variable d'état du problème de contrôle comme suit [90],

$$y_{k+1} = y_k + \gamma^E p_k^{\text{ev}} \Delta t u_k \quad (3.30)$$

où, à l'instant discret, k , Y désigne l'énergie de charge accumulée dans la batterie, avec une valeur initiale de zéro au moment du branchement, et p^{ev} la puissance de charge réelle.

Il convient de noter que les études précédentes ont principalement utilisé la puissance de charge nominale pour estimer la dynamique du SOC. Cependant, cette information ne permet pas de tenir compte de la durée réelle de la charge qui est plus long en raison du mode de charge CCCV de la batterie du PEV, comme le montre la Figure 3-9. D'autre part, les modèles existants, qui sont généralement basés sur la puissance nominale, ne tiennent pas compte des incertitudes du comportement de charge dues à des facteurs externes tels que la température,

l'état de vieillissement du pack de batteries. Compte tenu de l'incertitude relative à l'heure de départ, à la durée de la charge et aux informations sur les besoins énergétiques, le problème de la planification de la recharge des VÉs peut être formulée en termes de problème stochastique : [82], [124] à travers,

$$\underset{T}{\text{minimize}} \quad \mathbb{E} [Q(y_T, \xi)] \quad (3.31a)$$

$$\text{subject to} \quad \text{Prob}(y_T \geq y^{\text{pref}}) \geq \eta \quad (3.31b)$$

où T représente l'heure de départ, $Q(y_T, \xi)$ est le coût total de l'énergie à recharger jusqu'à l'heure de départ, y_T , en tenant compte de l'incertitude sur l'heure de départ représenté par le paramètre, ξ . Le sujet du problème est une contrainte de chance (*chance constraint problem*) pour satisfaire la préférence de l'utilisateur avec la quantité d'énergie, y^{pref} . η est la probabilité de satisfaction de l'utilisateur en lien avec l'état final de l'énergie y_T ayant normalement une grande valeur. Par conséquent, une valeur de η plus proche de un signifie que l'utilisateur tolère $y_T < y^{\text{pref}}$ avec une probabilité moindre $(1 - \eta)$. La fonction objectif dans (3.31a) est déterminée par,

$$Q(y_T, \xi) = C(y_T, \xi) + D(y_T, \xi) \quad (3.32)$$

où, à l'heure de départ incertaine, $C(y_T, \xi)$ et $D(y_T, \xi)$ sont des fonctions de coût de la recharge et de niveau d'insatisfaction liées à l'état final de l'énergie chargée à la batterie. Ainsi, les actions de contrôle optimales, u_k^* doivent minimiser à la fois $C(y_T, \xi)$ et $D(y_T, \xi)$ en considérant ξ . Dans le problème stochastique développé, l'heure de départ, T et les actions de contrôle, u_k sont les variables de décision.

Le problème formulé peut être résolu par la simulation de Monte Carlo et l'approximation par moyenne d'échantillon (*Sample Average Approximation (SAA)*), décrite par l'algorithme du tableau 3-2. [125]. Dans cet algorithme, l'espace de décision pour sélectionner l'heure de départ, T est défini en fonction de sa distribution. Plus précisément, la décision est prise sur la base d'un nombre limité d'échantillons en divisant la distribution de l'heure de départ en N intervalles plus grands, comme l'illustre la figure 3-10. Cela est dû au fait que la recherche de

la distribution principale peut être coûteuse en termes de calcul pour des pas de temps plus courts, k . La méthode permettant de capturer la distribution du temps de départ est détaillée dans la sous-section 3.3.1.

TABLEAU 3-2 Simulation de Monte Carlo

Étape	Description
1.	Définir l'espace de décision $T \in \Omega_T$ à partir de la distribution ;
2.	Faire pour chaque $T \in \Omega_T$ step (3)-(6) ;
3.	Résoudre le problème d'optimisation déterministe ((3.33a)-(3.33e)) en utilisant l'horizon T ;
4.	Générer S échantillons $\{\xi^1; \dots; \xi^S\}$ à partir de la distribution de l'heure de départ ;
5.	Évaluer le coût de la recharge (3.34) et l'insatisfaction (3.35) pour chaque scénario ξ^s ($s \in \{1, S\}$) ;
6.	Stockez la valeur espérée de $Q(y_T, \xi)$ en utilisant la méthode SAA dans (3.36) ;
7.	Sélectionnez la décision T qui conduit à la valeur minimale du coût total $Q(y_T, \xi)$.

Ensuite, le contrôleur résout le problème d'optimisation pour une durée déterminée de T correspondant à l'heure du départ t_s^{dep} ,

$$\arg \min_{\{u_k\}_{k=0}^{T-1}} \sum_{k=0}^{T-1} \lambda_k \bar{P}^{\text{ev}} \Delta t u_k \quad (3.33a)$$

$$\text{subject to } y_{k+1} = y_k + \gamma^E \bar{P}^{\text{ev}} \Delta t u_k, \quad (3.33b)$$

$$y_{t_{\text{pi}}} = 0, \quad (3.33c)$$

$$y_T \geq \hat{y}^{\text{min}}, \quad (3.33d)$$

$$0 \leq u_k \leq 1 \quad (3.33e)$$

où \bar{P}^{ev} est la puissance moyenne de charge. La contrainte de chance dans (3.31b) est réalisée par (3.33d) où \hat{y}^{min} est l'énergie minimale estimée, requise par la session de charge pour satisfaire la préférence de l'utilisateur avec le niveau de satisfaction de η . Cette contrainte vise à garantir que l'état énergétique final au moment du départ satisfait les besoins énergétiques de l'utilisateur. On peut en déduire que la puissance nominale, $\bar{P}^{\text{ev},n}$, n'est pas un choix pratique pour la charge des VÉs en raison de son comportement variable dans le temps, présenté dans la figure 3-9. En effet, l'utilisation de cette valeur peut conduire à une durée de charge beaucoup plus courte que la durée réelle de la recharge. Néanmoins, la littérature pertinente a principalement utilisé la valeur nominale pour la programmation de la charge. Afin de résoudre ce problème, le problème formulé dans (3.33a) a pris en compte la puissance moyenne, \bar{P}^{ev} ,

qui est plus raisonnable. De plus, cette décision aboutit à une approximation de l'équation de la dynamique de l'état de charge, (3.33b) par équation de type linéaire invariable dans le temps, qui facilite donc la résolution du problème d'optimisation classique. Le processus de détermination de y^{min} et de \bar{P}^{ev} est expliqué dans les sous-sections 3.3.3 et 3.3.4.

Ensuite, la solution du problème d'optimisation déterministe, dans (3.33a-3.33e), est évaluée dans différents scénarios de départ par le contrôleur. Ces cas sont fournis par l'échantillonnage de la distribution de probabilité conditionnelle sur l'heure de départ, saisie en fonction de l'heure de branchement. La figure 3-10 illustre une telle distribution où T_{min} et T_{max} sont respectivement l'heure de départ la plus précoce et la plus tardive, selon les données historiques. ξ^s est un échantillon de cette plage. Par conséquent, l'examen de la solution y_T est effectué en calculant les coûts de tarification et d'insatisfaction par (3.34) et (3.35), respectivement, en considérant le scénario de départ, ξ^s ,

$$C(y_T, \xi^s) = \sum_{k=0}^{\xi^s} \lambda_k \bar{P}^{ev} \Delta t u_k^* \quad (3.34)$$

$$D(y_T, \xi^s) = \kappa_1 \left(1 - \frac{1}{1 + e^{\kappa_2 (y_{\xi^s} - \hat{y}^{min})}} \right) \quad (3.35)$$

où κ_1 et κ_2 sont les paramètres d'amplitude et de forme de la fonction d'insatisfaction, respectivement, et y_{ξ^s} est l'état d'énergie, défini par $y_{\xi^s} = \sum_{k=0}^{\xi^s} \gamma^E \bar{P}^{ev} \Delta t u_k^*$. Cette fonction a été illustrée dans la figure 3-11. Dans cette figure, on peut distinguer deux régions séparées par une ligne pointillée grise. La zone difficilement tolérable présente le niveau le plus élevé d'insatisfaction de l'utilisateur au scénario de départ, ξ^s , en raison de la faible quantité d'énergie rechargée à ξ^s . D'autre part, la zone hautement tolérable correspond aux quantités d'énergie où le niveau de satisfaction de l'utilisateur au scénario de départ ξ^s commence à augmenter proportionnellement. Les paramètres de la fonction d'insatisfaction sont définis de manière à réaliser un compromis entre les deux types de coûts. Plus précisément, l'amplitude de la fonction d'insatisfaction est décidée en fonction du prix de l'énergie afin d'éviter la prédominance du coût de la recharge. L'importance du désir de l'utilisateur peut être justifiée par les valeurs de κ_1 pour lesquelles l'énergie finale pour la charge est sélectionnée dans la zone tolérable. En outre, κ_2 permet de manipuler la forte diminution de la courbe d'insatisfaction.

Pour choisir le paramètre de forme, il faut une source d'information supplémentaire liée au comportement/préférence de l'utilisateur, ce qui n'entre pas dans le cadre de cette étude. Par conséquent, une valeur qui assure un taux de décroissance régulier de la courbe est considérée. En effet, les propriétés de la fonction d'insatisfaction devraient être étudiées à l'aide d'informations adéquates afin d'améliorer la commodité du CR.




FIGURE 3-10 Exemple de distribution de probabilité conditionnelle de l'heure de départ par rapport à l'heure de branchement.

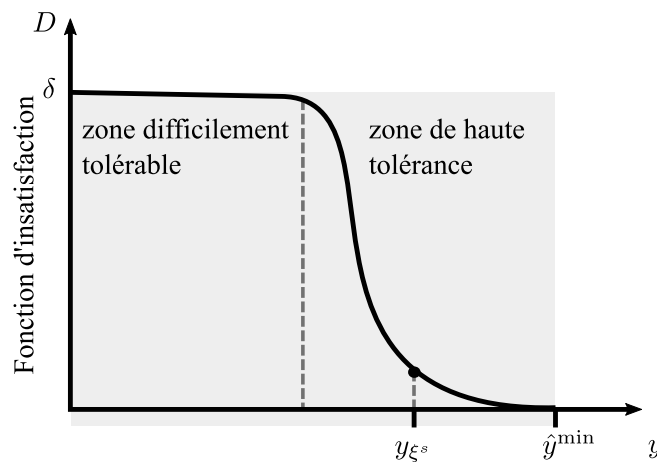


FIGURE 3-11 Exemple typique du profil d'insatisfaction de l'utilisateur.

Enfin, la valeur espérée du coût total peut être calculée par SAA sur la base de,

$$\mathbb{E} [Q(y_T, \xi)] \approx \frac{1}{S} \sum_{i=1}^S Q(y_T, \xi^s) \quad (3.36)$$

Le processus ci-dessus est exécuté pour tous les horizons, T , sélectionnés dans Ω_T . Par la suite, la solution de l'optimisation stochastique proposée, appliquée à la session de recharge en cours, est l'horizon dont l'action de contrôle correspondante entraîne le coût global minimum.

3.5.2 Mise en œuvre du contrôleur de charge de VE proposé

La proposition actuelle relative à la conception du contrôleur de charge des VÉs se fonde principalement sur les données d'interaction entre la borne de recharge et les véhicules, ainsi que sur les données historiques des périodes de connexion et de déconnexion du chargeur, comme explicitement défini dans la section 3.5. De manière plus précise, elle tire profit des données historiques de mesure de puissance pour anticiper les besoins énergétiques et planifier les séquences des opérations de recharge. Au début de chaque session de recharge, le contrôleur, tel qu'illustré dans la Figure 3-1, exécute les trois étapes suivantes lors du branchement du véhicule à la borne.

1. **Prévision** : Le contrôleur exploite un modèle prédictif pour estimer la demande d'énergie destinée à la recharge, notée \hat{y}_s , en fonction des variables prédictives x_s . Cette estimation de la demande d'énergie, \hat{y}_s , est ensuite utilisée pour modéliser le profil de puissance de charge non contrôlé sur l'horizon de prédiction, noté T .
2. **Optimisation** : Le contrôleur résout un problème d'optimisation stochastique en vue d'établir la politique de charge optimale en se basant sur le signal de prix de l'électricité et la demande d'énergie estimée sur la période T . À ce stade, il est présumé que les estimations de la demande d'énergie ainsi que de l'heure de départ sont précises.
3. **Exécution** : Le contrôleur de charge EMS met en œuvre les actions de contrôle émanant de l'étape précédente.

Chapitre 4 - Évaluation de la méthode

Ce chapitre présente en détail les résultats des travaux réalisés au cours de cette thèse sur la planification de la recharge des VÉs. Afin de mieux évaluer les performances des modèles développés et décrits dans le chapitre précédent, une étude comparative a été menée pour mettre en exergue les performances des modèles et stratégies proposés par rapport à d'autres modèles et approches compétitifs issus de l'état de l'art. À cet égard, différents scénarios de recharge ont été élaborés à partir des données réelles de sessions de recharge de plusieurs VÉs recueillies pendant plusieurs mois sur des bornes de recharge situées sur le campus de l'Université du Québec à Trois-Rivières. Enfin une analyse détaillée des performances du contrôleur sur l'ensemble des sessions de recharge a été conduite pour démontrer en simulation l'efficacité des différentes méthodes mises en œuvre. Dans un premier temps, les résultats d'évaluation des techniques de détection et de l'identification automatique des VÉs sont présentés. Ensuite, les modèles comportementaux des habitudes de recharge sont évalués en comparant leurs performances par rapport à d'autres techniques populaires dans la littérature. Enfin, l'efficacité de la conception finale du contrôleur comprenant les modèles de détection et d'identification des VÉ, les modèles stochastiques d'anticipation de la demande et de la durée de stationnement, le modèle de caractérisation du profil de puissance de la charge et l'optimisation stochastique sont validés.

4.1 Système de mesure des données pour la validation du modèle et la stratégie de contrôle

Pour la validation des différentes composantes de l'algorithme de planification de la recharge des VÉs proposés nous avons procédé à un collecte de données de recharge réelles de plusieurs VÉs. Ces données ont été collectées sur quelques bornes de charge (EVSE) locales

de niveau 2 (240V) situées sur le campus de l'université (UQTR) à Trois-Rivières, comme le montre la Figure 4-1. Le système de mesurage est composé d'un système d'acquisition de National Instruments (NI USB 6003), de plusieurs capteurs de courant (LEM TT-50 SD), d'un transformateur de tension 240V/10V, et d'un ordinateur avec le logiciel LabVIEW (Figure 4-2). Le système d'acquisition NI dispose de plusieurs entrées de signaux analogiques en mode différentiel (positif et négatif) qui sont connectées à l'entrée de chacun des quatre EVSEs et les quantités mesurées sont la tension et le courant de charge. Les données sont échantillonnées à une fréquence de 1200 Hz. Ensuite, l'amplitude du courant et de la tension est calculée à partir des données échantillonnées et stockée toutes les secondes (fréquence de stockage de 1 Hz).



(a) Ancienne version (2017)



(b) Nouvelle version avec l'ajout de deux bornes de recharge rapide en courant continu (2022).

FIGURE 4-1 La borne de recharge institutionnelle locale comme fournisseur de données.

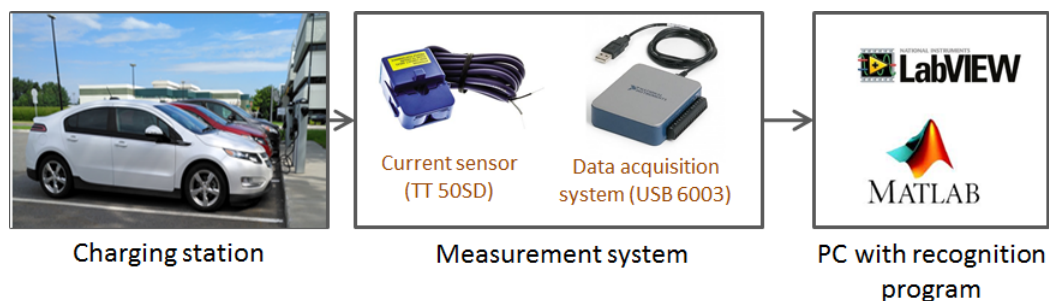


FIGURE 4-2 Banc d'essai expérimental.

4.2 Validation de l'algorithme de détection et d'identification des VÉs

Dans cette section, nous présentons les résultats de l'évaluation de la performance du modèle de détection et d'identification des VÉs proposés. Pour ce faire, nous avons considéré un scénario d'étude dans lequel cinq VÉs partagent les bornes de recharge locales. De scénarios similaires peuvent être rencontrés dans le milieu résidentiel où les bornes peuvent être partagées entre plusieurs VÉs utilisateurs de la résidence/immeuble/maison. Pour évaluer les performances des deux modèles, nous avons testé les performances des modèles dans l'identification en ligne des cinq VÉs qui venaient se recharger régulièrement au niveau de bornes de recharge partagées sur le campus de l'université. Les caractéristiques des cinq VÉs sont présentées dans le Tableau 4-1. Les données utilisées pour la validation de l'algorithme d'identification des VÉs ont été collectées du 21 mars au 5 mai 2017. La totalité de la base de données a été divisée en deux groupes selon la chronologie de l'acquisition des données (voir le Tableau 4-2). La première base de données appelée «Base de données1» contient 83 profils de charge comprenant 18 pour le VÉ 1, 16 pour le VÉ 2, 19 pour le VÉ 3, 11 pour le VÉ 4 et 19 pour le VÉ 5. Ces données ont été collectées entre le 21 mars 2017 au 20 avril 2017. La deuxième base de données appelée «Base de données2» contient 49 profils de charge collectés entre la période du 21 avril 2017 au 5 mai 2017. Elle contient 11 pour le VÉ 1, 8 pour le VÉ 2, 13 pour le VÉ 3, 5 pour le VÉ 4 et 12 pour le VÉ 5.

TABLEAU 4-1 Caractéristique des VÉs considérés

VÉ ref	Modèle	Type	Taille de la batterie (kWh)	Puissance de charge (kW) sur une borne de niveau 2
VÉ 1	Bolt	Tout électrique	60	7.2
VÉ 2	Volt	Hybride	16.5	3.3
VÉ 3	Ford C-Max	Hybride	7.6	3.3
VÉ 4	Volt	Hybride	16.5	3.3
VÉ 5	Nissan Leaf	Tout électrique	30	6.6

4.2.1 Utilisation de toutes les caractéristiques d'entrée

Le modèle d'identification des VÉs a été entraîné sur les données de la «Base de données1» dans un premier temps. Ensuite, après la phase de construction "hors ligne" du modèle d'identification, nous avons testé les performances du modèle construit, en ligne, sur les nouvelles données collectées, présentées dans la «Base de données2». Les détails de la

TABLEAU 4-2 Nombre de profils de charge des VÉs pour le processus de reconnaissance.

	VÉ1	VÉ2	VÉ3	VÉ4	VÉ5	Données totales
Base de données1 (données recueillies du 21 mars au 20 avril 2017)	18	16	19	11	19	83
Base de données2 (données recueillies du 21 avril 2017 au 5 mai 2017)	11	8	13	5	12	49

configuration du réseau de neurone utilisé sont présentés dans le tableau (4-3). Le module "neural network pattern recognition" de MATLAB a été utilisée pour la validation de la proposition (en tant que classificateur de motif).

TABLEAU 4-3 Description du réseau de neurones utilisé


Type	Réseau de neurones « feed-forward »
Méthode d'estimation des paramètres	Gradient conjugué (trainscg)
Performance	Entropie croisée (crossentropy)
Ratio pour la phase entraînement	0,70 Base de données1
Ratio pour la phase validation	0,15 Base de données1
Ratio pour la phase test	0,15 Base de données1

Dans cette première phase, toutes les caractéristiques extraites de l'échantillon de mesure ont été utilisées, générant une taille de 695 variables à l'entrée du réseau (couche d'entrée). Les différentes caractéristiques (vecteurs) sont présentées dans le tableau 4-4. Plusieurs simulations ont été effectuées en modifiant le nombre de neurones dans la couche cachée, et finalement une couche de 10 neurones a été choisie compte tenue de ses performances. La figure 4-3 illustre plusieurs profils de courant de charge typiques des cinq VÉs. On peut constater une grande similitude entre les profils de charge de plusieurs VÉ, notamment ceux de même modèle et de même marque ou dont la taille de la batterie est similaire.

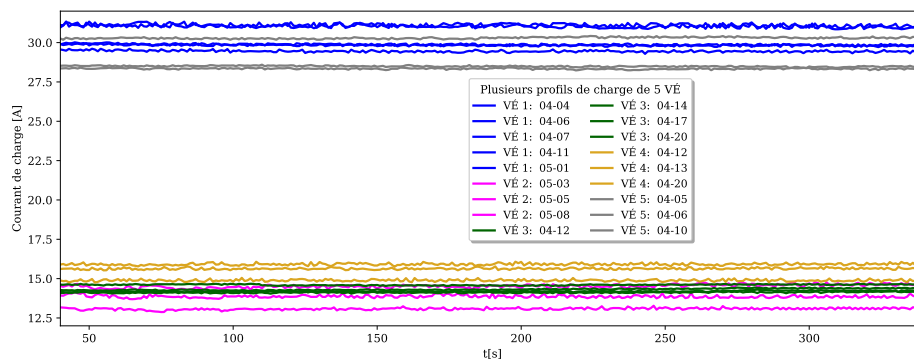
TABLEAU 4-4 Caractéristiques utilisées dans la couche d'entrée du réseau de neurones « feed-forward »

Espace de caractéristique	F_1	F_2	F_3	F_4	F_5	F_6	F_7	F_8	F_9	F_{10}	F_{11}	F_{12}
Dimension	(300,1)	(129,1)	(257,1)	(1,1)	(1,1)	(1,1)	(1,1)	(1,1)	(1,1)	(1,1)	(1,1)	(1,1)

Les résultats de la classification sont présentés à la Figure 4-4. Bien que les amplitudes de courant de charge soient très similaires pour les différents véhicules, la méthode proposée montre une performance satisfaisante dans la classification des cinq VÉs avec une précision de 100% pour la phase de validation et de test (base de données pour la construction du modèle).



(a) Profils du courant de charge types des cinq VÉs



(b) Zoom sur les profils pendant la phase de charge à courant constant


FIGURE 4-3 Plusieurs profils du courant de charge types des cinq VÉs.

Après avoir effectué la construction hors ligne, le modèle résultant a été testé en ligne sur 49 nouveaux échantillons de mesure de courant de charge collectés après la détection de connexion sur les différents EVSEs, contenus dans la base de données². Le résultat de ces tests sont présentés sur la Figure 4-5a). Parmi les 49 profils de charge, le modèle d'identification a pu identifier correctement les VÉs détectés (à partir de l'échantillon de mesure) pour 47 des cas et a eu une confusion dans l'identification de deux véhicules lors d'une session de charge de ces VÉs. Compte tenu de la similarité des profils de charge des différents VÉs, ce taux de réussite de 96% montre que la méthode d'identification proposée est assez performante. Dans la pratique de planification de la charge des VÉs une confusion dans l'identification d'un VÉ peut avoir une conséquence sur le schéma de planification qui est fait selon les profils historiques du VÉ dans la classe prédite. Cependant, lors de l'exécution des actions de contrôle de la charge, le contrôleur adapte les actions de contrôle selon le profil de charge du VÉ, la demande énergétique et aussi la détection des autres VÉs. En outre, l'augmentation de la




FIGURE 4-4 Résultats de la classification du réseau de neurones « feed-forward ».

taille de la base de données sur la formation pourrait améliorer le processus d'identification des VÉs. De même, une validation avec l'utilisateur par le biais d'une notification similaire aux validations effectuées par Google pour s'assurer que les contenus correspondent aux centres d'intérêt des utilisateurs de leurs services peut également améliorer les performances du modèle d'identification, en particulier lorsque le taux de confiance de la classification du profil de charge est inférieur à une valeur seuil. Il convient de rappeler que le nombre de classes (VÉs) utilisées pour la reconnaissance dans cette étude de validation est de cinq. Cependant, ce nombre peut être inférieur ou supérieur dans la pratique dans une zone résidentielle. Par ailleurs, en ce qui concerne l'entraînement du modèle de classification, l'insuffisance de données ne permet pas tout le temps la division de la base de données en trois parties utilisées dans ce travail (entraînement - validation - test) et que le sur-apprentissage constituerait un problème majeur du réseau de neurones à propagation avant. En revanche, cette limite peut



(a) Validation en ligne du modèle construit sur la base de données 2.



(b) Matrice de confusion

FIGURE 4-5 Résultats de la classification des performances du réseau de neurones à propagation avant sur les données de profils de charge de la base de données 2.

être surmontée en utilisant certaines méthodes de rééchantillonnage des données au détriment de coûts de calcul plus élevés, telles que les techniques de validation croisée «K-fold» et de validation croisée de type échappatoire (en anglais Leave-One-Out Cross-Validation), [126] ou de la technique d'abandon (en anglais dropout technique) [127].

4.2.2 Sélection des caractéristiques et étude de la sensibilité du modèle

Le modèle d'identification présenté dans la sous-section précédente n'était pas bien optimisé au niveau de l'architecture en raison de la grande taille de la couche d'entrée. Pour réduire la complexité du modèle liée à la taille du réseau, nous avons procédé à une étude de sensibilité pour sélectionner les caractéristiques les plus utiles. Dans cette perspective, nous avons employé la méthode de sélection SFS (détaillée dans la section 3.2.3) sur un ensemble initial de 695 entités, dans le but de choisir les sous-ensembles les plus "riches" pour l'identification des VÉs. De plus, nous avons utilisé différentes tailles de données pour évaluer

la contribution respective des différentes caractéristiques dans le processus d'identification, comme illustré dans la Figure 4-6. La dimension des caractéristiques du modèle "réduit" est déterminée par le critère d'arrêt basé sur la performance globale de la reconnaissance des VÉs.

L'étude de sensibilité a été réalisée avec la méthode SFS et le classificateur SVM. Le SVM a été choisi en raison du faible nombre de paramètres de réglage par rapport au réseau de neurones à propagation avant. Différentes topologies du classificateur SVM ont été évaluées en changeant les fonctions du noyau en simulation, afin de sélectionner le classificateur le plus performant. Finalement, la topologie avec une fonction noyau linéaire a été sélectionnée en fonction du critère de performance qui est basé sur la précision. Dans cette étude, nous avons évalué les performances de deux modèles réduits du classificateur SVM. Le premier modèle a une dimension des caractéristiques d'entrée de 3 et le second de 10. Ensuite, les performances de ces deux modèles sont comparées à celles obtenues en utilisant tout l'espace des caractéristiques initiales. Afin de mieux sélectionner les caractéristiques selon leur capacité de "généralisation", nous avons définis quatre scénarios en fonction de la taille de la base de données utilisée pour entraîner le classifieur SVM. Dans le premier scénario, seulement 25% de la base de données 1 est utilisée pour entraîner le classifieur, contre respectivement 50%, 75% et 100% pour les deuxième, troisième et quatrième scénarios. Les sous-ensembles de caractéristiques sélectionnés dans cette base de données sont ensuite utilisés pour tester la capacité de généralisation du modèle d'identification des VÉs en utilisant le même pourcentage de la base de données 1 pour l'entraînement du modèle et la sélection des caractéristiques pour chaque scénario et la base de données 2 pour la phase de test. Les résultats de la SFS sont présentés dans le Tableau 4-5 et la Figure 4-7 qui indique la précision obtenue avec les sous ensembles de caractéristiques optimales locales sélectionnées.

TABLEAU 4-5 Performances de la SFS utilisant le classificateur SVM en fonction de la taille de la base de données.

Dimension	Caractéristiques sélectionnées en utilisant différentes tailles de bases de données							
	F_{local}^1		F_{local}^2		F_{local}^3		F_{local}^4	
	25% base de donnée1	50% base de donnée1	75% base de donnée1	100% base de donnée1				
	F_1	F_2	F_1	F_3	F_1	F_2	F_1	F_2
10	(1-8)	(343, 363)	(1-9)	(599)	(1-5)	(308, 311, 312, 332, 334)	(1-6)	(165, 309, 336, 363)

Les résultats obtenus à partir de différents scénarios montrent que les caractéristiques riches en informations pertinentes pour l'identification des VÉs sont plus concentrées dans le signal brut et dans la densité spectrale de puissance estimée avec les méthodes de Welch et de Thomson. L'étude de sensibilité met également en évidence l'importance de la taille de la base de données dans la sélection du sous-ensemble de caractéristiques, ainsi que la qualité des données contenues dans la base de données (bonne représentativité de chaque classe). Les résultats présentés dans la Figure 4-7 montrent que plus on utilise de données pour sélectionner les caractéristiques, plus l'algorithme SFS converge vers des caractéristiques optimales "globales". L'étude révèle également que l'utilisation de seulement 10 caractéristiques, obtenues à partir du sous-ensemble optimal de caractéristiques de taille 10, donne presque les mêmes performances que lors que tout l'espace des caractéristiques initiales est utilisé tel que illustré à la Figure 4-7.

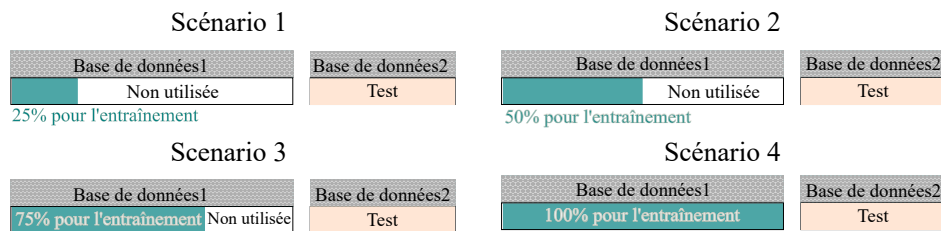



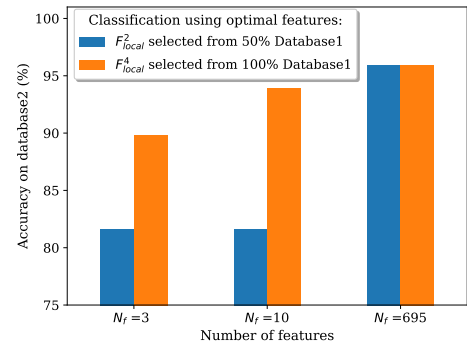
FIGURE 4-6 Description de la base de données pour les 4 scénarios (entraînement et test).

4.2.3 Comparaison de la performance des deux classificateurs basés sur le SVM et le réseau de neurones


Cette section présente les résultats d'une analyse comparative entre les performances du classificateur SVM à celles du classificateur basé sur le réseau de neurones à propagation avant. Dans cette étude, les mêmes caractéristiques sont appliquées aux entrées des deux classificateurs et la même base de données est utilisée pour l'entraînement des deux modèles. Les caractéristiques utilisées sont les caractéristiques optimales "globales" F_{local}^4 . La base de données d'apprentissage représente 75 % de la base de données 1 générée aléatoirement, tandis que la base de données 2 est utilisée pour la phase de test. Pour le classificateur SVM, le noyau linéaire est utilisé et pour le réseau de neurones, la couche cachée à 13 neurones est choisie après avoir effectué plusieurs simulations en changeant le nombre de neurones



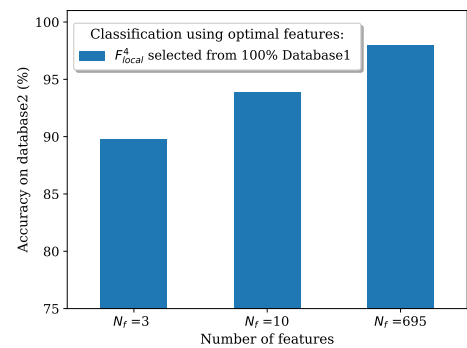
(a) Comparaison en utilisant 25 % de la base de données 1 pour l'apprentissage et la sélection des caractéristiques et la base de données 2 pour le test.



(b) Comparaison en utilisant 50 % de la base de données 1 pour l'apprentissage et la sélection des caractéristiques et la base de données 2 pour le test.



(c) Comparaison en utilisant 75 % de la base de données 1 pour l'apprentissage et la sélection des caractéristiques et la base de données 2 pour le test.



(d) Comparaison en utilisant 100 % de la base de données 1 pour l'apprentissage et la sélection des caractéristiques et la base de données 2 pour le test.

FIGURE 4-7 Comparaison de la capacité de généralisation du modèle de reconnaissance des VE en utilisant les différents sous-ensembles de caractéristiques sélectionnés à partir de bases de données de différentes tailles en utilisant le classificateur SVM, la base de données 2 a été utilisée pour la phase de test.

dans la couche cachée. Les taux de réussite dans l'identification des profils de charge dans la base de données test sont indiqués sur la Figure 4-9. Les résultats montrent que le SVM et le réseau de neurones à propagation avant, en tant que classificateurs supervisés très populaires dans la littérature, ont des performances très proches. Ce qui indique que les deux méthodes sont adaptées à la mise en œuvre pratique de l'identification des VÉs. Cependant, en ce qui concerne une application en ligne, qui est l'ambition principale de ce document, le SVM est une méthode un peu coûteuse en termes de calcul par rapport au réseau de neurones. En effet, le SVM est composé de plusieurs classificateurs qui peut augmenter le temps de calcul en




FIGURE 4-8 Comparaison de la capacité de généralisation du modèle de reconnaissance des VÉ en utilisant différentes tailles de bases de données et les caractéristiques optimales F_{local}^4 (sélectionnées à partir de toute la base de données 1) en utilisant le classificateur SVM.

fonction de leur nombre. En revanche, le réseau de neurones à anticipation peut être mis en œuvre en utilisant un seul classificateur. Cependant, cela peut ne pas être problématique dans la plupart des cas puisque l'identification du VÉ est effectuée en quelques secondes seulement. Cependant, au niveau matériel, la complexité algorithmique du SVM mérite d'être analysée davantage.

4.2.4 Détection d'une nouvelle classe

Il est important de noter que si, dans le futur, un nouveau type de profil de charge (VÉ) émerge, il sera nécessaire de réentraîner les méthodes de classification supervisée proposées. En effet, un des inconvénients des classifieurs supervisés est qu'ils doivent connaître à l'avance le nombre de classes. Dans l'état actuel, ces classifieurs associeront tout nouveau type de profil de charge de VÉ à la classe la plus proche. En revanche, plusieurs méthodes non supervisées ont été proposées dans la littérature pour lesquelles le nombre de classes pourrait être modifié au cours du temps par le modèle, comme les méthodes de clustering soustractif [128], qui pourraient faire l'objet de travaux futurs. Par ailleurs, l'analyse des signaux électriques sur l'ensemble des bornes de recharge peut être une autre piste à explorer pour la détection d'une




FIGURE 4-9 Comparaison des performances du classificateur SVM et du classificateur de réseau de neurones à propagation avant utilisant les caractéristiques optimales F_{local}^4 (sélectionnées dans 100 % de la base de données 1) et 75 % de la base de données 1 pour la formation et la base de données 2 pour la phase de test.

nouvelle classe. En effet, grâce à l'analyse des signaux électriques, le contrôleur peut détecter le nombre de sessions de charge effectuées chaque jour et les périodes de charge, comme indiqué sur la Figure 4-10. Une analyse statistique de ces informations peut être effectuée ensuite pour détecter toute variation de tendance de ces deux variables et la persistance de la variation. Finalement, certaines règles peuvent être formulées : un type de profil de charge rencontré à deux points de charge différents ne peut pas correspondre au même véhicule, ou un véhicule électrique qui vient d'être chargé ne peut pas être chargé avec une grande quantité d'énergie quelques minutes plus tard. Dans le contexte des recharges au niveau résidentiel, certaines études ont montré que les propriétaires de VÉs ont tendance à brancher leur VÉ très souvent une fois par jour (en fin de journée pour les débrancher le matin) [39], [129]. Dans ce cas, l'émergence d'un nouveau type de recharge peut être détectée en analysant les signaux électriques.




FIGURE 4-10 Reconnaissance des VÉs effectuée sur les bornes de recharge au cours d'une journée type.

4.3 Modélisation statistique des heures d'arrivée et de départ

La procédure de clustering, expliquée dans 3.3.1, est appliquée aux données collectées sur les bornes de recharge locale. Dans un premier temps, ce processus permet d'obtenir trois groupes d'heures d'arrivée différents. Ces groupes représentent le soir et la nuit (de 17 h à 4h59), l'après-midi (de 13 h à 16 :59 h), ainsi que le matin (de 5 h à 12h59). Cette classification se manifeste par la distribution globale des heures de branchement, présentée dans la Figure 4-11. Dans un deuxième temps, la méthode d'estimation non paramétrique de densité de probabilité est appliqué sur les données de chacune des classes fournies par la modèle de clustering. Cette procédure fournit au contrôleur trois distributions différentes des heures de départ correspondant à différentes classes d'heures de branchement, comme le montre la figure 4-12. Enfin, les distributions des heures de départ sont mises à jour sur la base de nouvelles observations après chaque session de chargement. En fait, la base de données des sessions de recharge est progressivement enrichie par de nouvelles mesures. Cette extension des données offre la possibilité au contrôleur de saisir les différentes saisonnalités dans les données (jour de la semaine, mois, saisons, etc..) et d'améliorer les inférences sur les heures d'arrivée et de départ. Il est à noter que l'efficacité de la modélisation proposée de l'heure de départ résulte de la différenciation des sessions de recharge en fonction de leur heure de branchement. Une telle approche peut être utile pour d'autres lieux de recharge tels que le milieu institutionnel avec les utilisateurs réguliers. Dans la suite des études ces distributions sont utilisées lors de la

planification de la charge des VÉs connectés et fournissent un moyen au contrôleur de tenir compte des incertitudes sur la durée de recharge selon l'heure du branchement.




FIGURE 4-11 Distribution de l'heure d'arrivée et de départ.




FIGURE 4-12 Différentes distributions des heures de départ, résultant de la phase de clustering.

4.4 Prédiction des demandes individuelles des VÉs

Cette section présente les résultats de l'analyse des performances du modèle d'anticipation de la demande d'énergie pour la recharge des VÉs. La figure 4-13 présente l'histogramme et l'estimation par noyau de la densité de probabilité de la demande quotidienne en énergie pour la recharge sur la période de janvier 2013 à janvier 2018 pour les VÉs 1, 2, 3, 4 et 5. Ces modèles statistiques montrent des habitudes de recharge très différents pour les cinq VÉs. Les distributions des VÉs 2, 3 et 4 sont étroites avec une faible largeur de bande. Par

conséquent, leurs besoins énergétiques peuvent être prédits plus facilement. En revanche, la consommation des VÉs 1 et 5 est plus uniformément distribuée avec un comportement non stationnaire. Pour ces cas, la modélisation statistique ne permettant pas, à elle seule, une meilleure anticipation des besoins de recharge, en raison d'une grande variance de la demande d'énergie qui est lié aux habitudes de trajet et de recharge des utilisateurs de ces véhicules. Dans ce cas, l'exploitation de la corrélation entre la demande d'énergie pour la recharge et d'autres variables telles que l'heure du branchement, les variables météorologiques pourrait aider à anticiper les besoins en charge. Compte tenu de l'impact potentiel des incertitudes de prédiction sur les objectifs du contrôleur, comme présenté dans la section 3.3.3, les modèles de régression sont privilégiés.




FIGURE 4-13 Histogramme et Kernel lissé de la demande d'énergies de charge historiques pour les 5 VÉs (1,2,3,4 et 5).

Pour illustrer les performances du modèle prédictif construit, une étude comparative a été réalisée en mettant en exergue les performances du modèle prédictif proposé par rapport à un autre modèle basé sur la régression de crête (Rigde Regression : RR). Les résultats présentés dans cette étude concernent la prévision de la demande énergétique de la VÉ 5.

Plus précisément, la RR utilise les moindres carrés ordinaires pour estimer les paramètres du modèle, tandis que la méthode bayésienne déduit la distribution de probabilité postérieure de ces paramètres en utilisant un ensemble de priors. Avant de comparer les performances des deux modèles, une analyse de sensibilité est effectuée afin d'évaluer les variables prédictives les plus importantes.

4.4.1 Analyse de sensibilité

Bien que les prédicteurs, x_s , définis dans la sous-section 3.3.3, soient des éléments typiques utilisés dans les méthodes de prévision des séries chronologiques, certains d'entre eux peuvent ne pas être significatifs pour la prédiction des besoins énergétiques des VÉs. Il est donc important d'effectuer une analyse de sensibilité pour examiner le degré de prévisibilité de chaque prédicteur et, par conséquent, sélectionner les plus pertinents. Dans cette étude, cette procédure est effectuée en utilisant le modèle de régression Ridge afin d'éviter la complexité de calcul de l'algorithme bayésien pour la sélection des caractéristiques. À cette fin, une partie des données est utilisée pour l'entraînement du modèle prédictif et une partie pour le test. La base de données d'entraînement comprend 56 échantillons de données dont 28 sessions de recharge tandis que la base de données de test contient 100 échantillons de données dont 56 sessions de recharge. Le résultat de l'analyse de sensibilité est présenté dans la figure 4-14 qui présente le score du coefficient de détermination, R^2 , pour différentes combinaisons des prédicteurs les plus efficaces, qui ont été sélectionnés séquentiellement en commençant par le meilleur d'entre eux. On peut observer que le prédicteur le plus important est l'heure du branchement, t_{pi} , qui est responsable d'environ 50% de R^2 à lui seul. Ensuite, la précision du résultat augmente à environ 64 % pour la combinaison des cinq meilleurs prédicteurs, x_{1-5} . Par la suite, la valeur de R^2 augmente légèrement en ajoutant de nouveaux prédicteurs.

4.4.2 Étude comparative

Pour avoir une même base de comparaison, les deux modèles prédictifs sont entraînés avec les mêmes données collectées entre le 27 mars et le 30 mai 2017. Le nombre total de sessions de charge est de 29 durant cette période. Ensuite, ils sont testés individuellement en ligne en exploitant les données du 31 mai au 8 janvier 2018. Il convient de mentionner que la phase




FIGURE 4-14 Analyse de sensibilité des entrées du modèle prédictif.

d'entraînement est traitée sur une fenêtre qui s'élargit avec l'arrivée de nouvelles données de session de charge. L'inférence bayésienne est réalisée en utilisant le package Python PyMC3. Une distribution Gamma avec des paramètres de forme et d'échelle égaux à 3 est considérée comme distribution à priori pour le paramètre σ selon (3.16). Une distribution normale dont la moyenne et la variance sont égales à zéro et 20 est utilisée comme distribution à priori pour les paramètres θ conformément à (3.17). Ces priors ont fourni les meilleurs résultats sur la base d'un grand nombre de tests.

Le Tableau 4-6 et la Figure 4-15 montrent les résultats des deux modèles, appliqués aux données de test. Les résultats sont évalués en se basant sur le coefficient de détermination R^2 , l'erreur quadratique moyenne (RMSE) et l'erreur absolue moyenne (MAE) comme mesures de précision. En ce qui concerne la précision des prévisions, l'approche bayésienne fonctionne efficacement, et ses performances sont relativement plus élevées que celles de la technique RR pour un nombre différent de prédicteurs, comme le montre le Tableau 4-6. Plus important encore, l'inférence bayésienne est supérieure à la technique RR en raison de sa capacité à offrir un moyen de quantifier l'incertitude du modèle, comme le montre la Figure 4-15 (régions claires-orangées). Cet avantage peut se traduire par un contrôle robuste de la recharge des VÉs visant à diminuer le risque de manquer d'énergie pour les besoins de déplacement de l'utilisateur, essentiel pour la satisfaction de ce dernier. En fait, la limite supérieure d'une telle incertitude est exploitée par le contrôleur pour caractériser y^{min} dans (3.19). Ce processus de

décision établit une forme de contrôle robuste visant à satisfaire les préférences ou exigences de charge de l'utilisateur. Cependant, un RR qui n'estime que la valeur espérée de la demande d'énergie pour la recharge ne permet pas un tel type de contrôle, et ne garantit donc pas la satisfaction des préférences de charge de l'utilisateur.

Étant donné la performance similaire des modèles prédictifs lorsque seuls les cinq premiers prédicteurs sont utilisés ou lorsque les huit ou même tous les prédicteurs sont utilisés, comme l'illustre le Tableau 4-6, la configuration basée sur les cinq premiers prédicteurs comprenant t_{pi} , y_{s-7} , \bar{T}_s , w_s^k et y_{s-6} est choisie dans la suite de cette étude. En guise de rappel, y_{s-l} fait référence à la l^e session de charge précédente.

TABLEAU 4-6 Résultats de l'étude comparative entre les méthodes de prévision

Nombre de variables sélectionnées	Métriques	Regression Ridge	Inférence Bayésienne
Les cinq meilleures variables sélectionnées	R^2	73.2	85.0
	RMSE	3.8	2.8
	MAE	2.4	1.6
Les huit variables les mieux sélectionnées	R^2	77.7	85.2
	RMSE	3.5	2.8
	MAE	2.2	1.6
Toutes les variables sélectionnées	R^2	79.6	83.2
	RMSE	3.3	3
	MAE	2.0	1.7




FIGURE 4-15 Résultats de l'estimation du besoin de la charge du VÉ par les modèles prédictifs basés sur l'inférence bayésienne et la régression Ridge.

4.5 Planification de la recharge des VÉs

La performance du contrôleur en ligne proposé pour la recharge des VÉs est analysée et discutée en détail dans cette section. Afin de mieux évaluer le gain potentiel en termes de réduction des coûts énergétiques et la capacité du contrôleur à satisfaire les préférences de charge de l'utilisateur compte tenu des sources d'incertitude inhérentes et des informations partielles, nous avons préparé un scénario d'étude considérant plusieurs sessions de recharge, et types de signaux de prix de l'électricité. Des données réelles de session de charge et de signaux de prix de l'électricité sont utilisés pour démontrer une perception réaliste de la performance du contrôleur.

4.5.1 Préparation de l'étude de cas

Le scénario d'étude exploite des données réelles de sessions de recharge de VÉ recueillies localement au niveau de quatre bornes de recharge de niveau 2 (240 V) de l'UQTR, dont le détail est présenté dans la section 4.1. Le VÉ, considéré dans cette étude de cas, est une Nissan Leaf 2016 dont les spécifications sont détaillées dans le Tableau 4-7. Les données de charge pour ce VÉ ont été collectées du 27 mars 2017 au 15 janvier 2018. Le nombre total de sessions de charge, effectuées par le VE, au cours de cette période est de 112.

TABLEAU 4-7 PEV specifications [130]

Model	Nissan Leaf 2016
Battery capacity (kWh)	24
Level 2 acceptance rate (kW)	6.6
Travel efficiency	30 kWh/100 mi
Charging time	220V ~5 hrs
	110V ~21 hrs

Le contrôleur étant destiné à des applications de recharge à domicile, une étape de pré-traitement est appliquée aux données collectées auprès des EVSE locaux afin de présenter un attribut pertinent. Cette étape est principalement exécutée en décalant l'indice de temps (moment de la charge) pour les différentes sessions de charge. Ainsi, l'heure d'arrivée (de départ) de la borne de recharge est interprétée comme l'heure de départ (d'arrivée) du domicile

avec un décalage lisse afin de se conformer aux statistiques de l'enquête nationale auprès des ménages (NHS) du Canada [131]. Néanmoins, dans le scénario d'étude construit, les valeurs du profil de puissance de charge du VÉ provenant des données de mesure restent inchangées. Il convient de mentionner que cette procédure a été réalisée en raison des difficultés à fournir des données adéquates provenant des maisons, qui peuvent permettre des investigations réalisables. La Figure 4-16 illustre les distributions de densité estimées avec la méthode KDE sur les données historiques des heures d'arrivée et de départ selon le scénario de charge à domicile, c'est-à-dire les profils décalés. On peut observer que les déconnexions du chargeur (heure de départ) se produisent normalement vers 7 h 40 et les connexions (heure d'arrivée) vers 18 h 40, ce qui est conforme aux informations du NHS. En outre, deux types de signaux de prix réels sont pris en compte, comme l'illustre la Figure 4-17. Les deux signaux sont basés sur des prix variant dans le temps. Le premier profil correspond à la tarification TOU utilisée dans la province de l'Ontario, au Canada. Le second est une version modifiée du premier signal qui présente presque la même valeur moyenne mais des variations plus importantes pour refléter d'autres dynamiques possibles.




FIGURE 4-16 Distribution de l'heure d'arrivée et de départ.

La procédure de clustering, expliquée dans 3.3.1, est appliquée aux données issues de la phase de préparation. Dans un premier temps, ce processus permet d'obtenir trois groupes d'heures d'arrivée différents. Ces groupes représentent les données des recharges effectuées le soir et la nuit (de 17 :00 à 4 :59), l'après-midi (de 13 :00 à 16 :59), ainsi que le matin (de 5 :00 à 12 :59) selon l'ordre décroissant de leurs valeurs de densité. Dans un deuxième temps,




FIGURE 4-17 Signaux de prix de l'électricité.

la méthode de clustering fournit au contrôleur trois distributions différentes des heures de départ selon la classe des heures de branchement correspondant, comme le montre la Figure 4-18. Ces distributions sont mises à jour sur la base de nouvelles observations après chaque session de recharge. En fait, la base de données des sessions de recharge est progressivement enrichie par de nouvelles mesures. Ceci permet aux modèles de prédiction et de caractérisation de mieux capturer la saisonnalité des données et d'améliorer les inférences des heures de départ/d'arrivée. Il convient de noter que l'efficacité de la modélisation conditionnelle de l'heure de départ résulte de la différenciation des sessions de recharge en fonction de leur heure de connexion. Une telle approche peut être utile dans la gestion de la recharge des VÉs dans d'autres lieux de recharge (exemple milieu institutionnel).




FIGURE 4-18 Différentes distributions des heures de départ, résultant de la phase de clustering.

4.5.2 *Processus de contrôle en ligne*

La performance du contrôleur proposé est évaluée en exploitant l'ensemble de la base de données (environ une année de données), qui contient les informations de presque tous les trajets quotidiens possibles pour ce VÉ. L'évaluation est réalisée dans les étapes suivantes en exploitant les données de D_{test} . Pour planifier la recharge du VÉ, le contrôleur exploite l'algorithme de détection et d'identification du VÉ, les modèles statistiques de son comportement de stationnement à la borne de recharge et le modèle prédictif de la demande d'énergie, l'optimisation stochastique et d'autres informations telles que le signal du prix de l'électricité et les préférences de l'utilisateur en matière de recharge.

4.5.2.1 *Fonctionnement du contrôleur proposé*

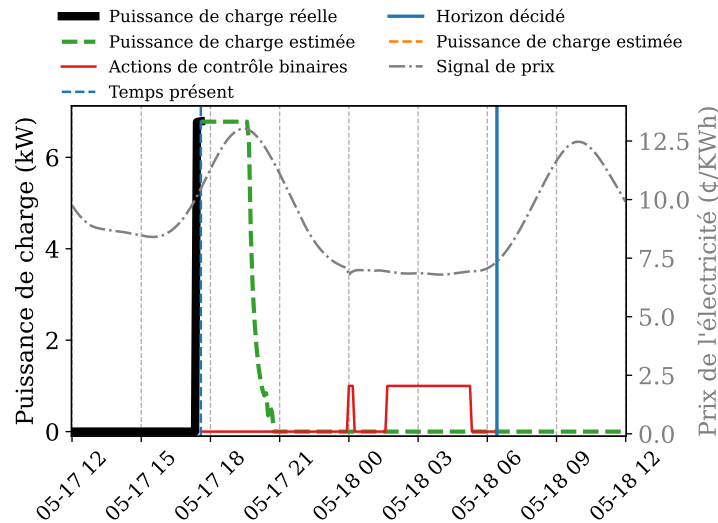
La Figure 4-19 illustre les étapes de la planification de la charge du VÉ s'effectue en deux phases principales. La série d'événements de la première phase est illustrée à la Figure 4-19.a. Au cours de cette étape, le contrôleur détecte l'instant de connexion du VÉ (ligne pointillée bleue) en analysant la mesure de puissance réelle, p_k^{ev} , et ensuite estime la quantité d'énergie nécessaire pour charger sa batterie, selon les préférences de charge de l'utilisateur y_s^{\min} , en utilisant le modèle de prévision décrit dans 3.3.3. Ensuite, il estime le profil de la puissance de charge en utilisant la demande énergétique estimée et l'historique des sessions de charge, comme décrit dans 3.3.4. Par la suite, le contrôleur résout le problème d'optimisation stochastique afin de définir les meilleures actions de contrôle en fonction du signal de prix et de l'horizon décidé en termes de durée de stationnement (ligne bleue) en tant que paramètre incertain du problème d'optimisation. À ce stade, le contrôleur peut notifier l'utilisateur de la politique de charge optimale qu'il planifie d'exécuter, en particulier de l'autonomie probable (RDR) qui sera ajoutée à la fin programmer de la politique de charge ainsi que le potentiel d'économie du coût de la recharge. Par exemple, la RDR correspondant au scénario de recharge du VÉ dans la Figure 4-19 est de 81 km additionnels. Dans la deuxième étape, le contrôleur met en oeuvre le processus de charge en ligne (temps réel) sur la base de l'action de contrôle décidée à chaque pas de temps, Δt , comme indiqué sur la figure 4-19.b. On peut observer que dans l'étape de mise en oeuvre des actions de contrôle, les besoins estimés en énergie et en

puissance pour la charge sont gérés par le signal de contrôle binaire. En effet, le contrôleur permet de charger la batterie uniquement à l'état ON selon ce signal (action de contrôle = 1). Cela peut conduire à des situations dans lesquelles la demande minimale n'est pas satisfaite en raison de l'absence d'une estimation précise du besoin énergétique initial. Comme l'illustre la Figure 4-19.b, ce cas est susceptible de se produire lorsque la valeur espérée de la demande énergétique estimée est exploitée (ligne pointillée orange). Une action de contrôle qui s'appuie sur la meilleure estimation unique (espérance exacte) en employant des méthodes non bayésiennes comme RR peut détériorer considérablement ce problème. Cependant, une conception qui intègre les incertitudes des paramètres dans la décision du contrôleur peut offrir un processus robuste. Par conséquent, elle peut soulager cette préoccupation en utilisant les distributions postérieures des paramètres pour satisfaire la préférence de l'utilisateur par un niveau de confiance η . La Figure 4-15 clarifie cette question en présentant les estimations à point unique et la distribution a posteriori de la demande de recharge des VÉs comme la principale différence entre les techniques RR et bayésienne, respectivement. Il convient de souligner que le processus de prise de décision en ligne peut être perçu à partir du profil de charge réel en suivant l'heure actuelle (ligne pointillée bleue) sur l'horizon décidé dans les figures 4-19.a et 4-19.b.

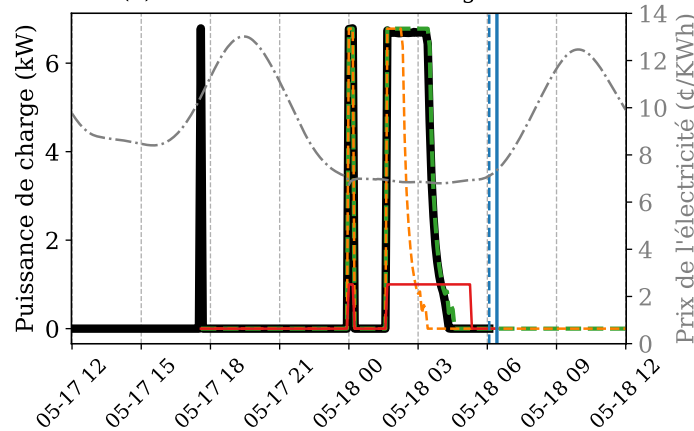
En termes de temps de fonctionnement (calcul et exécution des tâches), le contrôleur prend moins de 2 minutes pour prendre la décision dans la phase de planification de la charge au moment de la connexion. Ce temps correspond principalement au temps que prend le processus de prévision de la demande énergétique et à la résolution du problème d'optimisation stochastique, qui prennent généralement 40 secondes et 30 secondes, respectivement. Le contrôleur fonctionne toutes les 10 minutes (pas d'exécution des commandes de contrôle), et donc, ses besoins décisionnels ne sont pas violés par le temps de calcul. Il convient de noter que les simulations sont exécutées sur un processeur Intel i7-9700 CPU@3 GHz avec 16 Go de RAM.

4.5.2.2 Performance du contrôleur proposé

Cette section présente les performances du contrôleur proposé de manière plus exhaustive sur l'ensemble de données de test, D_{test} , qui contient des informations sur différents trajets



(a) Planification de la recharge du VÉ.



(b) Exécution de la charge du VÉ.

FIGURE 4-19 Fonctionnement en ligne du contrôleur proposé pendant les phases de planification et de mise en œuvre des signaux de commande.

quotidiens pendant environ un an. L'évaluation est réalisée par une étude comparative en utilisant deux autres scénarios. Le premier cas représente la charge non contrôlée où la charge du VÉ commence immédiatement après le branchement. Le deuxième cas représente la charge contrôlée basée sur l'approche déterministe. Un contrôleur basé sur cette méthode a un accès direct et complet aux paramètres critiques du VÉ comprenant l'heure exacte de départ, l'information du SOC réel (provenant du contrôleur embarqué), et la forme une connaissance à priori du profil de la puissance de charge pour effectuer la planification de la recharge du VÉ. En tant que méthode basée sur une information complète, le schéma déterministe conduit au meilleur résultat. Par conséquent, ce schéma est un choix parfait comme référence pour évaluer la performance de la technique stochastique, qui n'utilise pas l'information complète.

La Figure 4-20 présente le coût cumulé de la recharge du VÉ avec différentes stratégies de contrôle incluant le contrôleur proposé. Tout au long des sessions de charge, l'économie moyenne du contrôleur proposé est d'environ 29,1 % et 45,4 % supérieure à celle du cas non contrôlé, respectivement pour la tarification dynamique et la tarification horaire en fonction du temps (TOU). En outre, le contrôleur conçu est très compétitif vis-à-vis du schéma déterministe, qui tire parti de l'information complète pour fournir le programme de charge optimal. Pour être plus précis, la légère différence entre les deux méthodes peut être attribuée d'une part à la haute performance du processus stochastique proposé et d'autre part au taux d'influence des paramètres incertains. Néanmoins, ce dernier point ne justifie pas l'utilisation de l'approche déterministe puisque la modélisation basée sur l'information complète n'est pas un scénario réalisable en raison de l'incertitude inhérente aux heures de départ et d'arrivée, de la non-linéarité de la puissance de charge dont la forme exacte est inconnue avant sa réalisation et de l'inaccessibilité de l'information du SOC du contrôleur embarqué dans certaines circonstances, surtout à long terme. En d'autres termes, les circonstances du monde réel rendent inévitable une approche stochastique de l'ordonnement de la recharge des VÉs, ce qui est l'objet principal de cet travail de recherche. À cet égard, la méthode d'ordonnement de la recharge proposée atteint une efficacité remarquable malgré les incertitudes liées au modèle prédictif des besoins énergétiques et celles liées à l'information sur l'heure de départ. Elle réduit considérablement le coût de la recharge pour l'utilisateur tout en garantissant que la batterie du VÉ est suffisamment chargée à l'heure du départ.

Les résultats montrent que le contrôleur proposé est capable de gérer la recharge des VÉs sous les incertitudes des pratiques réelles. On peut en déduire que le mécanisme développé peut réduire considérablement l'intervention des utilisateurs dans le processus de décision et faciliter l'adoption par les propriétaires. En outre, l'approche proposée, basée sur les données, est capable d'apprendre différents schémas de charge si on lui présente suffisamment de données. Cela peut être reconnu à partir du modèle de prévision qui est appliqué aux observations historiques avec la diversité des périodes de charge (types de jours et de saisons) tel qu'illustré sur la Figure 4-15. En outre, l'algorithme de contrôle proposé tire parti d'un mécanisme de prise de décision stochastique basé sur l'optimisation robuste, qui peut aider à gérer le caractère aléatoire des circonstances du monde réel. En outre, l'ensemble des analyses présentées




FIGURE 4-20 Le coût de recharge cumulé de différentes stratégies de recharge incluant le contrôleur proposé.

fournit des éléments importants, en termes de données et de méthodes, qui peuvent faciliter le développement de systèmes de recharge efficaces pour les VÉs dans d'autres applications. Par ailleurs, elle met en évidence des remarques importantes en ce qui concerne les enquêtes futures. En ce qui concerne les conditions préalables à une pratique de modélisation utile, cette recherche suggère un ensemble de données complet qui comprend les informations liées aux heures de branchement/débranchement, le SOC réel du contrôleur embarqué du VÉ, et la puissance de charge de plusieurs sessions de charge. En outre, elle propose le développement d'une infrastructure appropriée pour fournir au contrôleur de charge du VÉ les données essentielles afin de construire des modèles pertinents pour l'analyse de la planification de la recharge des VÉs. En ce qui concerne le rôle des propriétaires de voitures dans la réalisation de systèmes de gestion de l'énergie utiles, cette enquête recommande d'explorer la volonté des utilisateurs de partager régulièrement leurs informations, en particulier l'heure de départ et les souhaits de charge (SOC final). Cette suggestion, à son tour, encourage l'étude des modèles de charge personnalisés basés sur les préférences des utilisateurs comme un sujet intéressant. Une telle analyse peut être menée dans le contexte des services de réseau électrique où le taux de satisfaction des utilisateurs, en termes de flexibilité, est examiné afin de leur faire bénéficier d'opportunités de réduction des coûts tout en maintenant l'intérêt de l'opérateur du système.

Chapitre 5 - Conclusions et recommandations

5.1 Conclusions

Les travaux réalisés dans le cadre de cette thèse se sont concentrés sur la planification de la recharge des véhicules électriques (VÉs), en mettant l'accent sur la recharge résidentielle. Une analyse approfondie des défis liés à la gestion de la recharge des VÉs dans des situations réelles a été entreprise en tant qu'étape cruciale. Les différentes étapes de la recherche ont été menées en prenant en compte les limites des approches existantes dans la littérature, dans le but de concevoir un algorithme de contrôle plus efficace capable de gérer la recharge des VÉs dans des conditions d'incertitude, telles que le manque d'accès à des informations clés comme les heures d'arrivée et de départ, les besoins en énergie et la non-linéarité du profil de puissance de la charge.

Pour relever ces défis, nous avons proposé un algorithme innovant pour la détection et l'identification automatique des VÉs au moment de leur branchement. Cette proposition vise à doter le contrôleur de charge intelligent d'un outil efficace pour caractériser le comportement de charge des VÉs, réduisant ainsi le besoin d'interventions humaines dans la fourniture d'informations pertinentes. Cette identification permet de créer des modèles stochastiques du comportement de charge des VÉs individuels, favorisant ainsi une planification anticipée de leur demande d'énergie et de leur flexibilité potentielle. De plus, dans le contexte de la recharge coordonnée de multiples VÉs partageant des bornes de recharge, l'identification individuelle des VÉs permet de faciliter la prise de décisions personnalisées qui respectent les préférences de chaque utilisateur tout en optimisant l'utilisation des ressources partagées, telles que les infrastructures de recharge. Cette optimisation peut être particulièrement bénéfique, par exemple, pour la gestion de la recharge des VÉs dans un immeuble d'appartements confronté à des contraintes de capacité du transformateur électrique qui l'alimente. Un élément clé de la

méthodologie de recherche adoptée réside dans l'utilisation de mesures électriques simples (courant et tension) au niveau de la borne de recharge, fournissant des informations riches pour caractériser les comportements de charge des VÉs. La première phase de cette étude s'est concentrée sur l'analyse du signal en vue d'extraire les caractéristiques pertinentes nécessaires pour différencier les VÉs et favoriser leur identification. Différentes caractéristiques, basées sur l'analyse du signal dans le domaine fréquentiel et des variables statistiques, ont été calculées à partir d'un échantillon de mesures de courant collectées lors connexion des VÉs à la borne de recharge. Une étude de sensibilité a ensuite été menée pour sélectionner les caractéristiques les plus pertinentes parmi l'ensemble initial de caractéristiques candidates. Le processus d'identification des VÉs consiste à classer l'échantillon de mesure de courant collecté lors de la connexion des VÉs dans l'une des classes candidates. Afin d'obtenir une identification plus précise, nous avons proposé et comparé deux algorithmes de classification supervisée. La première méthode repose sur un réseau de neurones à propagation avant, tandis que la deuxième utilise les machines à vecteurs de support. Les performances des méthodes proposées ont été évaluées sur des données réelles collectées lors d'une campagne de mesure sur des bornes de recharge de niveau 2 situées sur le campus de l'université du Québec à Trois-Rivières. Les résultats finaux confirment la faisabilité de la méthode proposée avec une précision satisfaisante. L'efficacité de la méthode a été démontrée au moyen d'une analyse comparative des performances de reconnaissance entre les deux classificateurs proposés. En tenant compte de leurs performances globales, le classificateur basé sur les réseaux de neurones a finalement été recommandé.

La deuxième partie de cette thèse se concentre sur le défi de la modélisation et de l'estimation des besoins énergétiques de recharge et la flexibilité de la demande en fonction du type de véhicule. Pour relever cette problématique, nous avons développé des modèles statistiques et prédictifs pour caractériser les paramètres stochastiques clés influant sur la demande de recharge des VÉs, afin de permettre une anticipation efficace de leurs besoins en énergie et de leur flexibilité potentielle. Nous avons introduit un modèle de prévision de la demande énergétique des véhicules fondé sur l'inférence bayésienne. Contrairement aux approches fréquentistes, ce modèle est capable de non seulement estimer la demande de recharge, mais aussi de fournir un moyen pour quantifier l'incertitude associée à la prédiction en exploitant

la distribution postérieure des paramètres du modèle. En ce qui concerne la précision de la prévision, l'approche bayésienne se révèle efficace, surpassant la performance de la méthode de référence (régression Ridge). Par la suite, la quantification de l'incertitude du modèle par l'approche bayésienne est utilisée dans le processus de planification de la recharge pour proposer un contrôle robuste qui diminue le risque de déviation par rapport aux préférences de charge des utilisateurs à la fin du processus.

Les paramètres liés au stationnement des VÉs jouent un rôle crucial dans la flexibilité de la recharge, mais leur modélisation est complexe en raison des incertitudes. Pour aborder cette problématique, nous avons proposé une nouvelle approche basée sur la différenciation des sessions de recharge en fonction de l'heure de la journée. Contrairement aux approches conventionnelles qui peuvent être confrontées à des problèmes de complexité et de convergence, notre approche repose sur l'utilisation de la méthode d'estimation de la densité du noyau (KDE) et le regroupement supervisé des sessions de recharge pour modéliser les habitudes de stationnement. Le KDE s'avère très efficace pour modéliser la distribution du temps de départ, une variable avec une distribution inconnue influencée par le comportement stochastique des utilisateurs.

Sur la base des différents modèles proposés pour l'anticipation et la caractérisation de la demande de recharge des VÉs, la dernière phase de cette thèse s'est focalisée sur le développement d'un algorithme de contrôle. Dans cette optique, nous avons conçu un algorithme de planification de la recharge des VÉs basé sur l'optimisation stochastique. Le processus décisionnel met en avant la satisfaction des préférences de charge des utilisateurs. Les performances de l'algorithme de contrôle proposé ont été évaluées en utilisant des données réelles et une étude de cas portant sur les sessions de recharge sur une période de presque une année. De plus, l'évaluation est réalisée au moyen d'une analyse comparative avec une conception de contrôle déterministe, comme cas idéal, qui exploite un accès complet à l'information précise. Les résultats indiquent que le cadre stochastique proposé assure une planification de la recharge des VÉs avec une efficacité remarquable, comparable à celle des scénarios déterministes disposant d'un accès complet à l'information. Il garantit une recharge appropriée de la batterie au moment du départ tout en réduisant les coûts énergétiques de la recharge. En outre, ce mécanisme de prise de décision stochastique et robuste gère avec succès les

incertitudes inhérentes aux circonstances réelles. Par conséquent, ce mécanisme peut considérablement réduire l'intervention des utilisateurs dans le processus de décision, sans nécessiter de ressources matérielles significatives, ce qui facilite son adoption par les utilisateurs.

En conclusion, cette thèse a contribué de manière significative à la planification de la recharge des VÉs dans le milieu résidentiel en proposant des méthodes novatrices pour identifier les VÉs, anticiper leurs besoins et caractériser leurs habitudes de charge. Les résultats obtenus ouvrent des perspectives prometteuses pour la gestion intelligente et efficace de la recharge des VÉs, contribuant ainsi à la transition vers une mobilité électrique plus durable et pratique.

5.2 Recommandations

Les propositions avancées dans cette thèse offrent des éléments clés en termes de données et de méthodes, qui peuvent faciliter le développement de systèmes de recharge efficaces pour les véhicules électriques dans le milieu résidentiel et d'autres contextes. De plus, cette recherche met en lumière des orientations importantes pour les futures investigations. Les résultats obtenus ainsi que les limites identifiées ouvrent la voie à plusieurs pistes prometteuses pour les travaux à venir dans les domaines liés à cette thèse :

- Exploitation d'un ensemble de données complet : Pour une modélisation plus précise, il est recommandé d'utiliser un ensemble de données exhaustif comprenant les données de plusieurs véhicules. Ces données devraient inclure des informations détaillées telles que le temps de branchement/débranchement, le SOC réel et la puissance de charge sur plusieurs sessions de recharge.
- Développement d'une infrastructure appropriée : Cette thèse recommande de mettre en place une infrastructure adéquate pour fournir au contrôleur de charge des VÉs toutes les données nécessaires en temps réel afin de construire des modèles pertinents et adaptatifs pour la planification de leur recharge.
- Exploration du rôle des utilisateurs : Examiner à travers une étude exhaustive la disposition des propriétaires de VÉs à partager régulièrement leurs informations, notamment les heures d'arrivée, de départ et les préférences de charge. Cette suggestion, à son

tour, encourage l'étude des modèles de charge personnalisés basés sur les préférences des utilisateurs comme un sujet intéressant. Une telle analyse peut être menée dans le contexte des services de réseau électrique où le taux de satisfaction des utilisateurs, en termes de flexibilité, est examiné afin de leur faire bénéficier d'opportunités de réduction des coûts tout en maintenant l'intérêt de l'opérateur du système.

- Étude du rôle des utilisateurs : Il est recommandé de mener une analyse approfondie pour évaluer la volonté des propriétaires de VÉs à partager régulièrement leurs informations, notamment les heures d'arrivée, de départ et les préférences de recharge. Cette étude pourrait également conduire à l'exploration de modèles de charge personnalisés basés sur les préférences des utilisateurs, offrant ainsi une meilleure caractérisation de leurs besoins et une plus grande flexibilité dans la planification. Cette approche permettrait de mieux tirer parti des opportunités de réduction des coûts pour les utilisateurs, tout en prenant en considération les impératifs du réseau électrique.
- Utilisation de techniques de clustering non supervisées : Dans cette thèse, la modélisation des habitudes de stationnement a été faite en différenciant les sessions de recharge selon le moment de la journée où le véhicule est branché. Plutôt que de définir des plages horaires fixes, l'exploitation de méthodes de regroupement basées sur la similarité naturelle des données pourrait mieux caractériser les habitudes de stationnement des véhicules.
- Amélioration des performances de l'algorithme d'identification des VÉs : Il convient de noter que la forme de la méthodologie présentée pour l'identification a été validé sur les données de recharge de cinq VÉs. Dans le cadre de travaux futurs, cette thèse recommande de tester et valider l'applicabilité de l'algorithme sur de grands parcs de stationnement en exploitant des outils de traitement du signal plus avancés afin d'ajouter de nouvelles caractéristiques dans l'espace caractéristique proposé, comme la transformée en S ou la décomposition en mode variationnel. D'autres règles de reconnaissance de véhicules peuvent également être explorées comme l'analyse soustractive : un type de profil de charge rencontré à deux points de charge différents ne peut pas être le même véhicule, ou un véhicule électrique qui vient de terminer sa charge ne peut pas être rechargé avec une grande quantité d'énergie quelques minutes plus tard, ou toute autre

règle non basée sur la reconnaissance de formes. Enfin, d'autres parties des profils de caractérisation, comme l'analyse de la phase de tension constante, peuvent être utilisées pour améliorer la méthode proposée de reconnaissance des VÉs.

- Amélioration des performances de l'algorithme d'identification des VÉs : Il est important de noter que la méthodologie présentée pour l'identification a été validée sur les données de recharge de cinq VÉs. Dans le cadre de travaux futurs, il est recommandé de tester et de valider l'applicabilité de l'algorithme sur de plus grands parcs de stationnement en utilisant des outils de traitement du signal plus avancés. Cela pourrait impliquer l'exploration de nouvelles caractéristiques dans l'espace caractéristique proposé, comme la transformée en S ou la décomposition en mode variationnel. Il est également envisageable d'explorer d'autres règles de reconnaissance, comme par exemple l'analyse soustractive : une configuration de profil de charge constatée à deux points de charge différents ne peut pas correspondre au même véhicule, ou encore qu'un véhicule qui vient de terminer sa charge ne peut pas être rechargé avec une grande quantité d'énergie quelques minutes plus tard. Enfin, l'exploitation d'autres parties du profil de la puissance de charge, telles que l'analyse de la phase de tension constante, pourrait contribuer à améliorer la méthode de reconnaissance des VÉs proposée.
- Coordination de la recharge d'une flotte de VÉs : En complément de la gestion de la recharge des VÉs individuels, cette thèse encourage le développement d'un mécanisme de coordination de la recharge pour une flotte de VÉs. Cette recherche est recommandée de s'inspirer des techniques de gestion décentralisée de la charge, telles que l'algorithme des directions alternées des multiplicateurs (*ADMM, Alternating Direction Method of Multipliers*), pour orchestrer efficacement la recharge des véhicules au sein de la flotte. Cette approche vise à améliorer les performances et les fonctions globales du réseau électrique.

Ces recommandations offrent un aperçu des opportunités futures pour enrichir et perfectionner les travaux menés dans cette thèse. Elles contribuent à une gestion plus efficace et intelligente de la recharge des véhicules électriques, tout en ouvrant de nouvelles perspectives de recherche dans ce domaine en constante évolution.

Bibliographie

- [1] A. BANDYOPADHYAY, B. D. LEIBOWICZ, E. A. BEAGLE et M. E. WEBBER, « As one falls, another rises? Residential peak load reduction through electricity rate structures, » *Sustainable Cities and Society*, t. 60, p. 102-191, sept. 2020. DOI : 10.1016/j.scs.2020.102191. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S2210670720301785>.
- [2] A. DUBEY et S. SANTOSO, « Electric Vehicle Charging on Residential Distribution Systems : Impacts and Mitigations, » *IEEE Access*, t. 3, p. 1871-1893, 2015. DOI : 10.1109/ACCESS.2015.2476996. adresse : <http://ieeexplore.ieee.org/document/7264982/>.
- [3] J. WHITMORE et P.-O. PINEAU, « État de l'énergie au Québec, » HEC Montréal, préparé pour le ministère de l'Énergie et des Ressources naturelles, rapp. tech., 2019. adresse : <http://energie.hec.ca/eeq/>.
- [4] V. S. K. MURTHY BALIJEPALLI, V. PRADHAN, S. A. KHAPARDE et R. M. SHEREEF, « Review of demand response under smart grid paradigm, » in *ISGT2011-India*, IEEE, IEEE, déc. 2011, p. 236-243. DOI : 10.1109/ISET-India.2011.6145388. adresse : <http://ieeexplore.ieee.org/document/6145388/>.
- [5] A. AMIN, W. U. K. TAREEN, M. USMAN et al., « A Review of Optimal Charging Strategy for Electric Vehicles under Dynamic Pricing Schemes in the Distribution Charging Network, » *Sustainability 2020, Vol. 12, Page 10160*, t. 12, n° 23, p. 10-160, déc. 2020. DOI : 10.3390/SU122310160. adresse : <https://www.mdpi.com/2071-1050/12/23/10160/htm><https://www.mdpi.com/2071-1050/12/23/10160>.

- [6] S. SHAO, M. PIPATTANASOMPORN et S. RAHMAN, « Development of physical-based demand response-enabled residential load models, » *IEEE Transactions on power systems*, t. 28, n° 2, p. 607-614, 2013.
- [7] « Global EV Outlook 2017 – Analysis - IEA, » International Energy Agency (IEA), rapp. tech. adresse : <https://www.iea.org/reports/global-ev-outlook-2017>.
- [8] *Global EV Outlook 2022*, sér. Global EV Outlook. OECD, mai 2022. DOI : 10.1787/c83f815c-en. adresse : https://www.oecd-ilibrary.org/energy/global-ev-outlook-2022_c83f815c-en.
- [9] *Update on the global transition to electric vehicles through 2020 - International Council on Clean Transportation*. adresse : <https://theicct.org/publication/update-on-the-global-transition-to-electric-vehicles-through-2020/>.
- [10] *Prévisions des ventes annuelles de véhicules à zéro émission et inventaire*. adresse : <https://tc.canada.ca/fr/transport-routier/technologies-novatrices/vehicules-zero-emission/previsions-ventes-annuelles-vehicules-zero-emission-inventaire>.
- [11] *L'avenir de la mobilité*. adresse : <https://propulsionquebec.com/industrie/horizon-2050-lavenir-de-la-mobilite/>.
- [12] *Statistiques SAAQ-AVÉQ sur l'électromobilité au Québec en date du 30 septembre 2022 [Infographie]*. adresse : <https://www.aveq.ca/actualiteacutes/statistiques-saaq-aveq-sur-lelectromobilite-au-quebec-en-date-du-30-septembre-2022-infographie>.
- [13] *Infographie : Véhicules zéro-émission au Québec et au Canada : les chiffres clés - Cours de mécanique automobile Montreal*. adresse : <https://www.ecoleauto.com/blog/infographie-vehicules-zero-emission-au-quebec-et-au-canada-les-chiffres-cles/>.
- [14] *Accueil | vehiculeselectriques.gouv.qc.ca*. adresse : <https://vehiculeselectriques.gouv.qc.ca/>.

- [15] *Association des Véhicules Électriques du Québec*. adresse : <https://www.aveq.ca/>.
- [16] *Le gouvernement modifie sa réglementation dans le but d'augmenter les ventes de véhicules électriques*. adresse : <https://www.environnement.gouv.qc.ca/infuseur/communique.asp?no=4758>.
- [17] J. D. KIM, « Insights into residential EV charging behavior using energy meter data, » *Energy Policy*, t. 129, p. 610-618, juin 2019. DOI : 10.1016/j.enpol.2019.02.049. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0301421519301326>.
- [18] J. ROLINK et C. REHTANZ, « Large-scale modeling of grid-connected electric vehicles, » *IEEE Transactions on Power Delivery*, t. 28, n° 2, p. 894-902, 2013. DOI : 10.1109/TPWRD.2012.2236364.
- [19] J. G. SMART et S. D. SALISBURY, « Plugged In : How Americans Charge Their Electric Vehicles, » Idaho National Laboratory, Idaho Falls, ID (United States), rapp. tech., juill. 2015. DOI : 10.2172/1369632. adresse : <http://www.osti.gov/servlets/purl/1369632/>.
- [20] J. HUBER, D. DANN et C. WEINHARDT, « Probabilistic forecasts of time and energy flexibility in battery electric vehicle charging, » *Applied Energy*, t. 262, 2020. DOI : 10.1016/j.apenergy.2020.114525.
- [21] M. AHMADI, S. H. HOSSEINI et M. FARSADI, « Optimal Allocation of Electric Vehicles Parking Lots and Optimal Charging and Discharging Scheduling using Hybrid Metaheuristic Algorithms, » *Journal of Electrical Engineering & Technology*, t. 16, n° 2, p. 759-770, mars 2021. DOI : 10.1007/s42835-020-00634-z. adresse : <http://link.springer.com/10.1007/s42835-020-00634-z>.
- [22] *Consommation d'électricité par grand froid*. adresse : <http://www.hydroquebec.com/residentiel/espace-clients/consommation/consommation-electrique-hiver.html>.
- [23] L. F. RUEDA VASQUEZ, « Modélisation du comportement des occupants pour des applications de gestion de la demande d'électricité dans le secteur résidentiel, » 2021.

- [24] HYDRO-QUÉBEC, « Rapport annuel 2010, » rapp. tech., 2010.
- [25] ———, « Rapport annuel 2011, » rapp. tech., 2011.
- [26] ———, « Rapport annuel 2012, » rapp. tech., 2012.
- [27] ———, « Rapport annuel 2013, » rapp. tech., 2013.
- [28] ———, « Rapport annuel 2014, » rapp. tech., 2014.
- [29] ———, « Rapport annuel 2015, » rapp. tech., 2015.
- [30] ———, « Rapport annuel 2016, » rapp. tech., 2016.
- [31] ———, « Rapport annuel 2017, » rapp. tech., 2017.
- [32] ———, « Rapport annuel 2018, » rapp. tech., 2018.
- [33] P.-O. PINEAU, « L'électricité au Québec : Faire entrer le secteur dans le 21^e siècle, » 2014.
- [34] F. WU et R. SIOSHANSI, « A two-stage stochastic optimization model for scheduling electric vehicle charging loads to relieve distribution-system constraints, » *Transportation Research Part B : Methodological*, t. 102, p. 55-82, août 2017. DOI : 10.1016/j.trb.2017.05.002. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0191261516305343>.
- [35] C. W. GELLINGS, « The Concept of Demand-Side Management for Electric Utilities, » *Proceedings of the IEEE*, t. 73, n^o 10, p. 1468-1470, 1985. DOI : 10.1109/PROC.1985.13318.
- [36] L. GELAŽANSKAS et K. GAMAGE, « Forecasting Hot Water Consumption in Residential Houses, » *Energies*, t. 8, n^o 11, p. 12 702-12 717, nov. 2015. DOI : 10.3390/en81112336. adresse : <http://www.mdpi.com/1996-1073/8/11/12336>.
- [37] *Le Quotidien — Déplacement domicile-travail : faits saillants du Recensement de 2016*. adresse : <https://www150.statcan.gc.ca/n1/daily-quotidien/171129/dq171129c-fra.htm>.

- [38] H. E. PEREZ, X. HU, S. DEY et S. J. MOURA, « Optimal charging of li-ion batteries with coupled electro-thermal-aging dynamics, » *IEEE Transactions on Vehicular Technology*, t. 66, n° 9, p. 7761-7770, 2017.
- [39] A. CHIS, J. LUNDEN et V. KOIVUNEN, « Reinforcement Learning-Based Plug-in Electric Vehicle Charging with Forecasted Price, » *IEEE Transactions on Vehicular Technology*, t. 66, n° 5, p. 1-1, 2016. DOI : 10.1109/TVT.2016.2603536.
- [40] X. HU, D. CAO et B. EGARDT, « Condition monitoring in advanced battery management systems : moving horizon estimation using a reduced electrochemical model, » *IEEE/ASME Transactions on Mechatronics*, t. 23, n° 1, p. 167-178, 2018.
- [41] X. LIN, « Theoretical Analysis of Battery SOC Estimation Errors Under Sensor Bias and Variance, » *IEEE Transactions on Industrial Electronics*, t. 65, n° 9, p. 7138-7148, 2018.
- [42] KEITH WILSON, « An Overview of SAE International Standards - Activities Related to Charging of Hybrid / Electric Vehicles, » SAE International, rapp. tech., 2016.
- [43] Y. ZHENG, S. NIU, Y. SHANG, Z. SHAO et L. JIAN, « Integrating plug-in electric vehicles into power grids : A comprehensive review on power interaction mode, scheduling methodology and mathematical foundation, » *Renewable and Sustainable Energy Reviews*, t. 112, p. 424-439, sept. 2019. DOI : 10.1016/J.RSER.2019.05.059.
- [44] Z. N. PAN, T. YU, L. P. CHEN, B. YANG, B. WANG et W. X. GUO, « Real-time stochastic optimal scheduling of large-scale electric vehicles : A multidimensional approximate dynamic programming approach, » *International Journal of Electrical Power & Energy Systems*, t. 116, p. 105 542, mars 2020. DOI : 10.1016/J.IJEPES.2019.105542.
- [45] J. A. DOMINGUEZ, A. W. DANTE, K. AGBOSSOU et al., « Optimal Charging Scheduling of Electric Vehicles based on Principal Component Analysis and Convex Optimization, » *IEEE International Symposium on Industrial Electronics*, t. 2020-June, p. 935-940, juin 2020. DOI : 10.1109/ISIE45063.2020.9152292.

- [46] K. CLEMENT-NYNS, E. HAESSEN et J. DRIESEN, « The impact of Charging plug-in hybrid electric vehicles on a residential distribution grid, » *IEEE Transactions on Power Systems*, t. 25, n° 1, p. 371-380, fév. 2010. DOI : 10.1109/TPWRS.2009.2036481.
- [47] S. S. HOSSEINI, A. BADRI et M. PARVANIA, « The plug-in electric vehicles for power system applications : The vehicle to grid (V2G) concept, » in *2012 IEEE International Energy Conference and Exhibition (ENERGYCON)*, IEEE, IEEE, sept. 2012, p. 1101-1106. DOI : 10.1109/EnergyCon.2012.6347734. adresse : <http://ieeexplore.ieee.org/document/6347734/>.
- [48] X. LIU, S. LI, H. YU et L. ZHANG, « Coordinated charging optimization mode of electric vehicles in the residential area, » *Diangong Jishu Xuebao/Transactions of China Electrotechnical Society*, t. 30, n° 20, p. 238-245, 2015.
- [49] M. B. RASHEED, M. AWAIS, T. ALQUTHAMI et I. KHAN, « An Optimal Scheduling and Distributed Pricing Mechanism for Multi-Region Electric Vehicle Charging in Smart Grid, » *IEEE Access*, t. 8, p. 40298-40312, 2020. DOI : 10.1109/ACCESS.2020.2976710. adresse : <https://ieeexplore.ieee.org/document/9016233/>.
- [50] E. HADIAN, H. AKBARI, M. FARZINFAR et S. SAEED, « Optimal allocation of electric vehicle charging stations with adopted smart charging/discharging schedule, » *IEEE Access*, t. 8, p. 196908-196919, 2020. DOI : 10.1109/ACCESS.2020.3033662.
- [51] Y. ZHENG, J. LUO, X. YANG et Y. YANG, « Intelligent Regulation on Demand Response for Electric Vehicle Charging : A Dynamic Game Method, » *IEEE Access*, t. 8, p. 66105-66115, 2020. DOI : 10.1109/ACCESS.2020.2985578.
- [52] M. SCHÜCKING et P. JOCHEM, « Two-stage stochastic program optimizing the cost of electric vehicles in commercial fleets, » *Applied Energy*, t. 293, p. 116649, juill. 2021. DOI : 10.1016/J.APENERGY.2021.116649.
- [53] S. FADDEL et O. A. MOHAMMED, « Automated distributed electric vehicle controller for residential demand side management, » *IEEE Transactions on Industry Applications*, t. 55, n° 1, p. 16-25, jan. 2019. DOI : 10.1109/TIA.2018.2866255.

- [54] M. MURATORI et G. RIZZONI, « Residential Demand Response : Dynamic Energy Management and Time-Varying Electricity Pricing, » *IEEE Transactions on Power Systems*, t. 31, n° 2, p. 1108-1117, mars 2016. DOI : 10.1109/TPWRS.2015.2414880.
- [55] z. LIU, Q. WU, M. SHAHIDEHPOUR, C. LI, S. HUANG et W. WEI, « Transactive Real-Time Electric Vehicle Charging Management for Commercial Buildings With PV On-Site Generation, » *IEEE Transactions on Smart Grid*, t. 10, n° 5, p. 4939-4950, sept. 2019. DOI : 10.1109/TSG.2018.2871171. adresse : <https://ieeexplore.ieee.org/document/8467995/>.
- [56] A. MOHAMMAD, R. ZAMORA et T. LIE, « Transactive Energy Management of PV-Based EV Integrated Parking Lots, » *IEEE Systems Journal*, 2020. DOI : 10.1109/JSYST.2020.3043327.
- [57] P. WANG, Z. ZHANG, L. FU et N. RAN, « Optimal design of home energy management strategy based on refined load model, » *Energy*, t. 218, 2021. DOI : 10.1016/j.energy.2020.119516.
- [58] Z. MA, S. ZOU et X. LIU, « A Distributed Charging Coordination for Large-Scale Plug-In Electric Vehicles Considering Battery Degradation Cost, » *IEEE Transactions on Control Systems Technology*, t. 23, n° 5, p. 2044-2052, sept. 2015. DOI : 10.1109/TCST.2015.2394319.
- [59] D. T. NGUYEN et L. B. LE, « Joint Optimization of Electric Vehicle and Home Energy Scheduling Considering User Comfort Preference, » *IEEE Transactions on Smart Grid*, t. 5, n° 1, p. 188-199, jan. 2014. DOI : 10.1109/TSG.2013.2274521. adresse : <http://ieeexplore.ieee.org/document/6596523/>.
- [60] G. BINETTI, A. DAVOUDI, D. NASO, B. TURCHIANO et F. L. LEWIS, « Scalable Real-Time Electric Vehicles Charging with Discrete Charging Rates, » *IEEE Transactions on Smart Grid*, t. 6, n° 5, p. 2211-2220, sept. 2015. DOI : 10.1109/TSG.2015.2396772.
- [61] A. GHAVAMI, K. KAR et A. GUPTA, « Decentralized Charging of Plug-in Electric Vehicles with Distribution Feeder Overload Control, » *IEEE Transactions on Automatic Control*, t. 61, n° 11, p. 3527-3532, nov. 2016. DOI : 10.1109/TAC.2016.2516240.

- [62] W. C. COHEN, « Optimal control theory—an introduction, Donald E. Kirk, Prentice Hall, Inc., New York(1971), 452 pages.\$13.50, » *AICHE Journal*, t. 17, n° 4, p. 1018-1018, juill. 1971. DOI : 10.1002/aic.690170452. adresse : <http://doi.wiley.com/10.1002/aic.690170452>.
- [63] R. L. HU, R. SKORUPSKI, R. ENTRIKEN et Y. YE, « A Mathematical Programming Formulation for Optimal Load Shifting of Electricity Demand for the Smart Grid, » *IEEE Transactions on Big Data*, 2016.
- [64] H. TURKER et S. BACHA, « Optimal Minimization of Plug-In Electric Vehicle Charging Cost With Vehicle-to-Home and Vehicle-to-Grid Concepts, » *IEEE Transactions on Vehicular Technology*, t. 67, n° 11, p. 10 281-10 292, nov. 2018. DOI : 10.1109/TVT.2018.2867428. adresse : <https://ieeexplore.ieee.org/document/8449109/>.
- [65] M. H. K. TUSHAR, C. ASSI, M. MAIER et M. F. UDDIN, « Smart microgrids : Optimal joint scheduling for electric vehicles and home appliances, » *IEEE Transactions on Smart Grid*, t. 5, n° 1, p. 239-250, jan. 2014. DOI : 10.1109/TSG.2013.2290894.
- [66] B. ŠKUGOR et J. DEUR, « Dynamic programming-based optimisation of charging an electric vehicle fleet system represented by an aggregate battery model, » *Energy*, t. 92, p. 456-465, déc. 2015. DOI : 10.1016/J.ENERGY.2015.03.057.
- [67] Y. CAO, S. TANG, C. LI et al., « An optimized EV charging model considering TOU price and SOC curve, » *IEEE Transactions on Smart Grid*, t. 3, n° 1, p. 388-393, mars 2012. DOI : 10.1109/TSG.2011.2159630.
- [68] J. YANG, L. HE et S. FU, « An improved PSO-based charging strategy of electric vehicles in electrical distribution grid, » *Applied Energy*, t. 128, p. 82-92, sept. 2014. DOI : 10.1016/J.APENERGY.2014.04.047.
- [69] M. ALONSO, H. AMARIS, J. G. GERMAIN et J. M. GALAN, « Optimal Charging Scheduling of Electric Vehicles in Smart Grids by Heuristic Algorithms, » *Energies* 2014, Vol. 7, Pages 2449-2475, t. 7, n° 4, p. 2449-2475, avr. 2014. DOI : 10.3390/EN7042449. adresse : <https://www.mdpi.com/1996-1073/7/4/2449/htmhttps://www.mdpi.com/1996-1073/7/4/2449>.

- [70] C. SRITHAPON, P. GHOSH, A. SIRITARATIWAT et R. CHATTHAWORN, « Optimization of Electric Vehicle Charging Scheduling in Urban Village Networks Considering Energy Arbitrage and Distribution Cost, » *Energies* 2020, Vol. 13, Page 349, t. 13, n° 2, p. 349, jan. 2020. DOI : 10.3390/EN13020349. adresse : <https://www.mdpi.com/1996-1073/13/2/349/htm><https://www.mdpi.com/1996-1073/13/2/349>.
- [71] W. TUSHAR, W. SAAD, H. V. POOR et D. B. SMITH, « Economics of electric vehicle charging : A game theoretic approach, » *IEEE Transactions on Smart Grid*, t. 3, n° 4, p. 1767-1778, 2012. DOI : 10.1109/TSG.2012.2211901.
- [72] A. ASHTARI, E. BIBEAU, S. SHAHIDINEJAD et T. MOLINSKI, « PEV Charging Profile Prediction and Analysis Based on Vehicle Usage Data, » *IEEE Transactions on Smart Grid*, t. 3, n° 1, p. 341-350, mars 2012. DOI : 10.1109/TSG.2011.2162009. adresse : <http://ieeexplore.ieee.org/document/6017151/>.
- [73] Y. NOOROLLAHI, A. ALIGHOLIAN et A. GOLSHANFARD, « Stochastic energy modeling with consideration of electrical vehicles and renewable energy resources-A review, » *Journal of Energy Management and Technology*, t. 4, n° 1, p. 13-26, mars 2020. DOI : 10.22109/JEMT.2019.174242.1162. adresse : http://www.jemat.org/article_91186.html.
- [74] A. HOLZINGER, M. PLASS, M. KICKMEIER-RUST et al., « Interactive machine learning : experimental evidence for the human in the algorithmic loop : A case study on Ant Colony Optimization, » *Applied Intelligence*, t. 49, n° 7, p. 2401-2414, juill. 2019. DOI : 10.1007/s10489-018-1361-5/FIGURES/12. adresse : <https://link.springer.com/article/10.1007/s10489-018-1361-5>.
- [75] S. ZHOU, Z. WU, J. LI et X.-p. ZHANG, « Real-time Energy Control Approach for Smart Home Energy Management System, » *Electric Power Components and Systems*, t. 42, n° 3-4, p. 315-326, mars 2014. DOI : 10.1080/15325008.2013.862322. adresse : <http://www.tandfonline.com/doi/abs/10.1080/15325008.2013.862322>.
- [76] L. YU, T. JIANG et Y. ZOU, « Online Energy Management for a Sustainable Smart Home With an HVAC Load and Random Occupancy, » *IEEE Transactions on Smart*

- Grid*, t. 10, n° 2, p. 1646-1659, mars 2019. DOI : 10.1109/TSG.2017.2775209. adresse : <https://ieeexplore.ieee.org/document/8115166/>.
- [77] A. ITO, A. KAWASHIMA, T. SUZUKI, S. INAGAKI, T. YAMAGUCHI et Z. ZHOU, « Model Predictive Charging Control of In-Vehicle Batteries for Home Energy Management Based on Vehicle State Prediction, » *IEEE Transactions on Control Systems Technology*, t. 26, n° 1, p. 51-64, jan. 2018. DOI : 10.1109/TCST.2017.2664727. adresse : <http://ieeexplore.ieee.org/document/7862801/>.
- [78] L. ZHANG et Y. LI, « Optimal Management for Parking-Lot Electric Vehicle Charging by Two-Stage Approximate Dynamic Programming, » *IEEE Transactions on Smart Grid*, t. 8, n° 4, p. 1722-1730, 2017. DOI : 10.1109/TSG.2015.2505298.
- [79] B. WANG, P. DEGHANIAN et D. ZHAO, « Chance-Constrained Energy Management System for Power Grids with High Proliferation of Renewables and Electric Vehicles, » *IEEE Transactions on Smart Grid*, t. 11, n° 3, p. 2324-2336, mai 2020. DOI : 10.1109/TSG.2019.2951797.
- [80] I. MOMBER, A. SIDDIQUI, T. G. S. ROMAN et L. SODER, « Risk averse scheduling by a PEV aggregator under uncertainty, » *IEEE Transactions on Power Systems*, t. 30, n° 2, p. 882-891, mars 2015. DOI : 10.1109/TPWRS.2014.2330375.
- [81] K. SEDDIG, P. JOCHEM et W. FICHTNER, « Two-stage stochastic optimization for cost-minimal charging of electric vehicles at public charging stations with photovoltaics, » *Applied Energy*, t. 242, p. 769-781, mai 2019. DOI : 10.1016/J.APENERGY.2019.03.036.
- [82] X. WU, X. HU, X. YIN et S. J. MOURA, « Stochastic Optimal Energy Management of Smart Home With PEV Energy Storage, » *IEEE Transactions on Smart Grid*, t. 9, n° 3, p. 2065-2075, mai 2018. DOI : 10.1109/TSG.2016.2606442. adresse : <https://ieeexplore.ieee.org/document/7562357/>.
- [83] P. GRAHN, K. ALVEHAG et L. SODER, « PHEV Utilization Model Considering Type-of-Trip and Recharging Flexibility, » *IEEE Transactions on Smart Grid*, t. 5, n° 1, p. 139-148, jan. 2014. DOI : 10.1109/TSG.2013.2279022. adresse : <http://ieeexplore.ieee.org/document/6623210/>.

- [84] J. MUNKHAMMAR, J. WIDÉN et J. RYDÉN, « On a probability distribution model combining household power consumption, electric vehicle home-charging and photovoltaic power production, » *Applied Energy*, t. 142, p. 135-143, 2015.
- [85] S. M. KANDIL, H. E. FARAG, M. F. SHAABAN et M. Z. EL-SHARAFY, « A combined resource allocation framework for PEVs charging stations, renewable energy resources and distributed energy storage systems, » *Energy*, t. 143, p. 961-972, jan. 2018. DOI : 10.1016/J.ENERGY.2017.11.005.
- [86] S. M. HAKIMI, A. HASANKHANI, M. SHAFIE-KHAH et J. P. CATALÃO, « Stochastic planning of a multi-microgrid considering integration of renewable energy resources and real-time electricity market, » *Applied Energy*, t. 298, p. 117 215, sept. 2021. DOI : 10.1016/J.APENERGY.2021.117215.
- [87] D. PANAHI, S. DEILAMI, M. A. MASOUM et S. M. ISLAM, « Forecasting plug-in electric vehicles load profile using artificial neural networks, » *2015 Australasian Universities Power Engineering Conference : Challenges for Future Grids, AUPEC 2015*, nov. 2015. DOI : 10.1109/AUPEC.2015.7324879.
- [88] W. TONG, A. HUSSAIN, W. X. BO et S. MAHARJAN, « Artificial Intelligence for Vehicle-To-Everything : A Survey, » *IEEE Access*, t. 7, p. 10 823-10 843, 2019. DOI : 10.1109/ACCESS.2019.2891073.
- [89] A. Y. SABER et G. K. VENAYAGAMOORTHY, « Resource scheduling under uncertainty in a smart grid with renewables and plug-in vehicles, » *IEEE Systems Journal*, t. 6, n° 1, p. 103-109, mars 2012. DOI : 10.1109/JSYST.2011.2163012.
- [90] O. SUNDSTROM et C. BINDING, « Flexible Charging Optimization for Electric Vehicles Considering Distribution Grid Constraints, » *IEEE Transactions on Smart Grid*, t. 3, n° 1, p. 26-37, mars 2012. DOI : 10.1109/TSG.2011.2168431. adresse : <http://ieeexplore.ieee.org/document/6112699/>.
- [91] *National Household Travel Survey Daily Travel Quick Facts | Bureau of Transportation Statistics*. adresse : <https://www.bts.gov/statistical-products/surveys/national-household-travel-survey-daily-travel-quick-facts>.

- [92] D. CUI, Z. WANG, P. LIU et al., « Battery electric vehicle usage pattern analysis driven by massive real-world data, » *Energy*, t. 250, p. 123 837, juill. 2022. DOI : 10.1016/J.ENERGY.2022.123837.
- [93] Z. YU, F. LU, Y. ZOU et X. YANG, « Quantifying energy flexibility of commuter plug-in electric vehicles within a residence–office coupling virtual microgrid. Part II : Case study setup for scenario and sensitivity analysis, » *Energy and Buildings*, t. 254, p. 111 552, jan. 2022. DOI : 10.1016/J.ENBUILD.2021.111552.
- [94] K. VALOGIANNI, (PDF) *Smart charging of electric vehicles using reinforcement learning*, 2013. adresse : https://www.researchgate.net/publication/286726772_Smart_charging_of_electric_vehicles_using_reinforcement_learning.
- [95] Y. MOTOAKI, W. YI et S. SALISBURY, « Empirical analysis of electric vehicle fast charging under cold temperatures, » *Energy Policy*, t. 122, p. 162-168, nov. 2018. DOI : 10.1016/j.enpol.2018.07.036. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0301421518304828>.
- [96] A. W. DANTÉ, K. AGBOSSOU, S. KELOUWANI, A. CARDENAS et J. BOUCHARD, « Online modeling and identification of plug-in electric vehicles sharing a residential station, » *International Journal of Electrical Power & Energy Systems*, t. 108, p. 162-176, juin 2019. DOI : 10.1016/j.ijepes.2018.12.024.
- [97] T.-E. CHEN, S.-I. YANG, L.-T. HO et al., « S1 and S2 heart sound recognition using deep neural networks, » *IEEE Transactions on Biomedical Engineering*, t. 64, n° 2, p. 372-380, 2017.
- [98] S. LEGENDRE, D. MASSICOTTE, J. GOYETTE et T. K. BOSE, « Neural classification of Lamb wave ultrasonic weld testing signals using wavelet coefficients, » *IEEE Transactions on Instrumentation and Measurement*, t. 50, n° 3, p. 672-678, 2001.
- [99] G. E. MCCLELLAN, R. N. DEWITT, T. H. HEMMER, L. N. MATHESON et G. O. MOE, « Multispectral image-processing with a three-layer backpropagation network, » in *International 1989 Joint Conference on Neural Networks*, 1989, p. 151-153. DOI : 10.1109/IJCNN.1989.118573.

- [100] N. K. KAMILA, *Handbook of Research on Emerging Perspectives in Intelligent Pattern Recognition, Analysis, and Image Processing*. IGI Global, 2015.
- [101] M. J. ALAM, T. KINNUNEN, P. KENNY, P. OUELLET et D. OSHAUGHNESSY, « Multi-taper MFCC and PLP features for speaker verification using i-vectors, » *Speech communication*, t. 55, n° 2, p. 237-251, 2013.
- [102] D KUMAR, P CARVALHO, M ANTUNES et al., « Detection of S1 and S2 heart sounds by high frequency signatures, » in *Engineering in Medicine and Biology Society, 2006. EMBS'06. 28th Annual International Conference of the IEEE*, IEEE, 2006, p. 1410-1416.
- [103] J. TRANGOL et A. HERRERA, « Traditional Method and Multi-Taper to Feature Extraction Using Mel Frequency Cepstral Coefficients, » *International Journal of Information and Electronics Engineering*, t. 5, n° 1, p. 27, 2015.
- [104] A. K. JAIN, R. P. W. DUIN et J. MAO, « Statistical pattern recognition : A review, » *IEEE Transactions on pattern analysis and machine intelligence*, t. 22, n° 1, p. 4-37, 2000.
- [105] P. K. RAHI et R. MEHRA, « Analysis of power spectrum estimation using Welch method for various window techniques, » *International Journal of Emerging Technologies and Engineering*, t. 2, n° 6, p. 106-109, 2014.
- [106] C. BHAT, B. VACHHANI et S. KOPPARAPU, « Recognition of dysarthric speech using voice parameters for speaker adaptation and multi-taper spectral estimation, » in *Proceedings of the Annual Conference of the International Speech Communication Association, INTERSPEECH*, t. 08-12-Sept, sept. 2016, p. 228-232. DOI : 10.21437/Interspeech.2016-1085. adresse : http://www.isca-speech.org/archive/Interspeech_2016/abstracts/1085.html.
- [107] S. KHOKHAR, A. A. MOHD ZIN, A. P. MEMON et A. S. MOKHTAR, « A new optimal feature selection algorithm for classification of power quality disturbances using discrete wavelet transform and probabilistic neural network, » *Measurement*, t. 95, p. 246-259, jan. 2017. DOI : 10.1016/J.MEASUREMENT.2016.10.013.

- [108] G. HUANG, S. SONG, J. N. GUPTA et C. WU, « Semi-supervised and unsupervised extreme learning machines, » *IEEE Transactions on Cybernetics*, t. 44, n° 12, p. 2405-2417, déc. 2014. DOI : 10.1109/TCYB.2014.2307349.
- [109] C. M. BISHOP, « Periodic Variables, » *Pattern recognition and machine learning*, t. 1, 2006.
- [110] C. W. HSU et C. J. LIN, « A comparison of methods for multiclass support vector machines, » *IEEE Transactions on Neural Networks*, t. 13, n° 2, p. 415-425, mars 2002. DOI : 10.1109/72.991427.
- [111] M. F. MØLLER, « A scaled conjugate gradient algorithm for fast supervised learning, » *Neural networks*, t. 6, n° 4, p. 525-533, 1993.
- [112] F. CUTZU, « Polychotomous classification with pairwise classifiers : A new voting principle, » *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, t. 2709, p. 115-124, 2003. DOI : 10.1007/3-540-44938-8_{_}12/COVER. adresse : https://link.springer.com/chapter/10.1007/3-540-44938-8_12.
- [113] A. W. DANTE, S. KELOUWANI, K. AGBOSSOU, N. HENAO, J. BOUCHARD et S. S. HOSSEINI, « A Stochastic Approach to Designing Plug-In Electric Vehicle Charging Controller for Residential Applications, » *IEEE Access*, t. 10, p. 52 876-52 889, 2022. DOI : 10.1109/ACCESS.2022.3175817.
- [114] A. ALI, K. MAHMOUD et M. LEHTONEN, « Multiobjective Photovoltaic Sizing with Diverse Inverter Control Schemes in Distribution Systems Hosting EVs, » *IEEE Transactions on Industrial Informatics*, t. 17, n° 9, p. 5982-5992, sept. 2021. DOI : 10.1109/TII.2020.3039246.
- [115] Y.-C. CHEN, « A tutorial on kernel density estimation and recent advances, » *Biostatistics & Epidemiology*, t. 1, n° 1, p. 161-187, jan. 2017. DOI : 10.1080/24709360.2017.1396742. adresse : <https://www.tandfonline.com/doi/full/10.1080/24709360.2017.1396742>.

- [116] S. S. HOSSEINI, S. KELOUWANI, K. AGBOSSOU, A. CARDENAS et N. HENAO, « Adaptive on-line unsupervised appliance modeling for autonomous household database construction, » *International Journal of Electrical Power & Energy Systems*, t. 112, p. 156-168, nov. 2019. DOI : 10.1016/J.IJEPES.2019.04.034.
- [117] F. AMARA, K. AGBOSSOU, Y. DUBÉ, S. KELOUWANI, A. CARDENAS et J. BOUCHARD, « Household electricity demand forecasting using adaptive conditional density estimation, » *Energy and Buildings*, t. 156, p. 271-280, 2017.
- [118] G. P. ZHANG, « Time series forecasting using a hybrid ARIMA and neural network model, » *Neurocomputing*, t. 50, p. 159-175, 2003.
- [119] B. DOUCOURE, K. AGBOSSOU et A. CARDENAS, « Time series prediction using artificial wavelet neural network and multi-resolution analysis : Application to wind speed data, » *Renewable Energy*, t. 92, p. 202-211, 2016.
- [120] V. VAHIDINASAB et S. JADID, « Bayesian neural network model to predict day-ahead electricity prices, » *European Transactions on Electrical Power*, t. 20, n° December 2008, n/a-n/a, 2008. DOI : 10.1002/etep.316.
- [121] J. SUN, J. ELLERBROEK et J. HOEKSTRA, « Bayesian inference of aircraft initial mass, » *12th USA/Europe Air Traffic Management R and D Seminar*, n° June, 2017.
- [122] J. LAMPINEN et A. VEHTARI, « Bayesian approach for neural networks—review and case studies, » *Neural Networks*, t. 14, n° 3, p. 257-274, avr. 2001. DOI : 10.1016/S0893-6080(00)00098-8.
- [123] K. QIAN, C. ZHOU, M. ALLAN et Y. YUAN, « Modeling of Load Demand Due to EV Battery Charging in Distribution Systems, » *IEEE Transactions on Power Systems*, t. 26, n° 2, p. 802-810, mai 2011. DOI : 10.1109/TPWRS.2010.2057456.
- [124] J. R. BIRGE et F. LOUVEAUX, « Uncertainty and Modeling Issues, » in *Springer Series in Operations Research and Financial Engineering*, Springer Nature, 2011, p. 55-100. DOI : 10.1007/978-1-4614-0237-4{_}2.

- [125] M. QUDDUS, O. SHAHVARI, M. MARUFUZZAMAN, J. USHER et R. JARADAT, « A collaborative energy sharing optimization model among electric vehicle charging stations, commercial buildings, and power grid, » *Applied Energy*, t. 229, p. 841-857, 2018. DOI : 10.1016/j.apenergy.2018.08.018.
- [126] T. T. WONG, « Performance evaluation of classification algorithms by k-fold and leave-one-out cross validation, » *Pattern Recognition*, t. 48, n° 9, p. 2839-2846, sept. 2015. DOI : 10.1016/J.PATCOG.2015.03.009.
- [127] N. SRIVASTAVA, G. HINTON, A. KRIZHEVSKY, I. SUTSKEVER et R. SALAKHUTDINOV, « Dropout : A Simple Way to Prevent Neural Networks from Overfitting, » *Journal of Machine Learning Research*, t. 15, n° 56, p. 1929-1958, 2014. adresse : <http://jmlr.org/papers/v15/srivastava14a.html>.
- [128] N. HENAO, K. AGBOSSOU, S. KELOUWANI, Y. DUBE et M. FOURNIER, « Approach in Nonintrusive Type i Load Monitoring Using Subtractive Clustering, » *IEEE Transactions on Smart Grid*, t. 8, n° 2, p. 812-821, mars 2017. DOI : 10.1109/TSG.2015.2462719.
- [129] A. KAWASHIMA, R. SASAKI, T. YAMAGUCHI, S. INAGAKI, A. ITO et T. SUZUKI, « Energy management systems based on real data and devices for apartment buildings, » in *Industrial Electronics Society, IECON 2015-41st Annual Conference of the IEEE, IEEE*, 2015, p. 3212-3217.
- [130] *2016 Nissan LEAF : 107 Miles EPA Range - Full Specs/Pricing*. adresse : <https://insideevs.com/news/326562/2016-nissan-leaf-107-miles-epa-range-full-specs-pricing/>.
- [131] « Commuting to work. National Household Survey (NHS), 2011. [Online]. Available : https://www12.statcan.gc.ca/nhs-enm/2011/as-sa/99-012-x/99-012-x2011003_1-eng.cfm, » rapp. tech. adresse : https://www12.statcan.gc.ca/nhs-enm/2011/as-sa/99-012-x/99-012-x2011003_1-eng.cfm.