



Titre: Agrégation d'un grand nombre de petites charges en incluant
Title: l'incertitude de la disponibilité des ressources

Auteur: Émilie Chénier
Author:

Date: 2018

Type: Mémoire ou thèse / Dissertation or Thesis

Référence: Chénier, É. (2018). Agrégation d'un grand nombre de petites charges en incluant
Citation: l'incertitude de la disponibilité des ressources [Master's thesis, École
Polytechnique de Montréal]. PolyPublie. <https://publications.polymtl.ca/3743/>

 **Document en libre accès dans PolyPublie**
Open Access document in PolyPublie

URL de PolyPublie: <https://publications.polymtl.ca/3743/>
PolyPublie URL:

**Directeurs de
recherche:** Miguel F. Anjos, & Laurent Lenoir
Advisors:

Programme: Génie énergétique
Program:

UNIVERSITÉ DE MONTRÉAL

AGRÉGATION D'UN GRAND NOMBRE DE PETITES CHARGES EN INCLUANT
L'INCERTITUDE DE LA DISPONIBILITÉ DES RESSOURCES

ÉMILIE CHÉNIER
DÉPARTEMENT DE MATHÉMATIQUE ET DE GÉNIE INDUSTRIEL
ÉCOLE POLYTECHNIQUE DE MONTRÉAL

MÉMOIRE PRÉSENTÉ EN VUE DE L'OBTENTION
DU DIPLÔME DE MAÎTRISE ÈS SCIENCES APPLIQUÉES
(GÉNIE ÉNERGÉTIQUE)
DÉCEMBRE 2018

UNIVERSITÉ DE MONTRÉAL

ÉCOLE POLYTECHNIQUE DE MONTRÉAL

Ce mémoire intitulé :

AGRÉGATION D'UN GRAND NOMBRE DE PETITES CHARGES EN INCLUANT
L'INCERTITUDE DE LA DISPONIBILITÉ DES RESSOURCES

présenté par : CHÉNIER Émilie

en vue de l'obtention du diplôme de : Maîtrise ès sciences appliquées

a été dûment accepté par le jury d'examen constitué de :

M. KUMMERT Michaël , Doctorat, président

M. ANJOS Miguel F., Ph. D., membre et directeur de recherche

M. LENOIR Laurent, Ph. D., membre et codirecteur de recherche

M. ALARIE Stéphane, M.Sc.A., membre externe

DÉDICACE

*À ma famille
et à mon copain*

REMERCIEMENTS

Tout d'abord, j'aimerais remercier mon directeur de recherche Miguel Anjos ainsi que mon codirecteur Laurent Lenoir pour toute l'aide apportée au cours de ma maîtrise. Merci pour toutes les opportunités offertes pendant ma maîtrise.

J'aimerais également souligner l'aide apportée par les membres de l'institut de recherche d'Hydro-Québec et spécialement Dalal Asber qui a beaucoup contribué à mon projet. J'ai beaucoup apprécié tout ton travail et ton investissement dans mon projet.

Également, je remercie les ingénieurs de Schneider Electric Claudio et Jesus pour leurs conseils.

Merci à tous les membres du laboratoire et spécialement à Mathilde avec qui j'ai pu avoir du soutien pour compléter ma maîtrise.

Merci au CRSNG pour le financement de la chaire de recherche dans laquelle j'ai travaillé.

Finalement, un grand merci à ma famille et à mes amis qui m'ont supporté à travers ma maîtrise. Tout spécialement, un grand merci à mon copain Yanis qui m'a offert tout le soutien nécessaire.

RÉSUMÉ

Le réseau électrique en continuel changement demande une gestion des ressources efficace pour assurer sa stabilité. Avec la nouvelle technologie de communication et les nouvelles ressources d'énergie renouvelables, la gestion du réseau électrique fait face à de nombreux défis. On anticipe une croissance de l'utilisation de la voiture électrique dans les années à venir. Si la recharge des voitures ne se fait pas de façon intelligente, on pourra observer une forte croissance de la demande énergétique en heure de pointe. Grâce à des programmes de Gestion de la demande (Demand Response (DR)), les clients peuvent adapter leur consommation d'électricité en échange d'incitatifs. Une requête de DR envoyée à un client lui permet d'adapter sa consommation d'électricité selon les besoins de l'utilité. Les producteurs d'électricité sont appelés utilités dans cette recherche. Les secteurs résidentiel et commercial offrent un grand potentiel pour les programmes de DR, car ensemble ces secteurs représentent près d'un tiers de la consommation totale. Bien que ces secteurs offrent un grand potentiel, l'exploitation de ceux-ci comporte également de grands défis. Un grand nombre de clients consommant de petites charges doivent être gérés efficacement. C'est pourquoi les agrégateurs sont introduits en tant qu'intermédiaires entre l'utilité et les consommateurs. Le rôle des agrégateurs est de faire la gestion des programmes de DR avec les clients. Grâce à eux, les requêtes de DR sont distribuées parmi les clients dans le but de satisfaire la requête d'utilité. La requête d'utilité quant à elle est une commande de réduction ou d'augmentation de la consommation globale dans le but d'équilibrer la production et la consommation d'électricité.

Le problème connu de répartition économique est utilisé comme référence pour développer le modèle mathématique de distribution des requêtes de DR. Ce problème de base est trivial à résoudre et ne comporte pas de complexité. Par contre, la difficulté résulte du fait qu'il existe une certaine probabilité qu'un client ne réponde pas à la requête de DR. Lorsqu'un client répond à une requête, cela signifie que le client adapte sa consommation selon la requête. S'il ne répond pas à la requête, cela signifie qu'il n'adapte pas sa consommation. L'agrégateur doit donc distribuer plus de requêtes de DR pour pallier l'incertitude de la réponse. L'objectif de cette recherche est de modéliser un problème mathématique réaliste de l'agrégateur en incluant l'incertitude de la réponse des clients. Le modèle est résolu trois fois par jour pendant une semaine. Les résolutions sont interreliées pour éviter d'envoyer les requêtes de DR toujours aux mêmes clients. Comme les requêtes de DR requièrent un coût, l'agrégateur doit faire une distribution de façon à minimiser ses coûts tout en assurant le respect de la requête d'utilité. Cette incertitude n'a pas été étudiée dans la littérature au niveau de l'agrégateur. Plusieurs méthodes peuvent être utilisées pour inclure l'incertitude dans un modèle

mathématique. La méthode choisie dans cette recherche s'appelle l'optimisation à contraintes probabilistes. Bien que cette méthode offre de bons résultats, elle est peu utilisée dans la littérature, car elle est plus complexe mathématiquement. Cette méthode assure que les requêtes de DR distribuées respectent la requête d'utilité avec un certain niveau de confiance.

La caractérisation de la probabilité de réponse des clients est très complexe en soi. Plusieurs facteurs externes peuvent influencer la réponse des clients. Les facteurs considérés dans cette recherche sont la période de la journée et le jour de la semaine. La fréquence des requêtes reçues pendant la semaine est également incluse dans le modèle. Finalement, les probabilités de réponses peuvent être différentes pour une augmentation ou une diminution de la charge. Les clients sont divisés en trois sous-ensembles de probabilité : un sous-ensemble de faible probabilité, un sous-ensemble de probabilité modérée et un sous-ensemble de forte probabilité. Les clients sont également divisés en sous-ensembles selon leur capacité à adapter leur consommation électrique. Un premier ensemble comprend les clients résidentiels n'ayant pas de voiture électrique ou d'appareil intelligent de gestion d'énergie. Le deuxième ensemble quant à lui comprend les clients résidentiels ayant soit une voiture électrique ou un appareil intelligent de gestion d'énergie. Ces clients possèdent une plus grande capacité d'adaptation de leur consommation puisque la charge ou décharge de la voiture peut être utilisée comme ressource. Finalement, les clients du secteur commercial forment le troisième sous-ensemble. Les courbes de consommation des clients commerciaux sont simulées à l'aide du logiciel eShapes en Nouvelle-Angleterre, aux États-Unis. Les courbes de consommation servent à calculer la capacité des clients commerciaux. Suite à quoi, les clients commerciaux sont regroupés en cinq sous-ensembles selon leur capacité d'adaptation de leur consommation. Un regroupement est fait pour les clients commerciaux afin de minimiser la distance des capacités d'un même sous-ensemble.

Pour estimer la valeur de la requête d'utilité, une prédiction de la consommation totale est réalisée. La requête d'utilité est calculée en prenant un pourcentage de la prédiction de la consommation. Ainsi, l'agrégateur vise une augmentation ou une réduction d'un certain pourcentage de la consommation. Trois méthodes sont choisies pour être comparées. La méthode de régression à l'aide de vecteurs de support, la méthode non-paramétrique et la méthode ARX ont été modélisées grâce à des données de consommation réelle. Les données de consommation ont été mesurées chaque heure par Hydro-Québec à neuf sous-stations à travers le Québec de décembre à février 2006. Les données recueillies en décembre, janvier et les trois premières semaines de février servent de données d'entraînement aux modèles. Des facteurs comme l'heure de la journée, le jour de la semaine, la température extérieure et la vitesse du vent ont été inclus dans les modèles de prévision. Les méthodes ont été testées avec les données de la dernière semaine de février. Suite à l'analyse des résultats, la méthode

non-paramétrique est choisie pour calculer la requête d'utilité.

Finalement, le modèle a été testé sur un ensemble de 30 000 clients. Le nombre de variables étant trop grand, le solveur ne trouvait aucune solution en moins de huit heures. Pour réduire le temps de résolution, une méthode de regroupements de clients a été développée. Le regroupement des charges permet de résoudre le modèle en quelques secondes tout en gardant les caractéristiques de la population de clients initiaux. Quatre études de cas sont testées pour analyser l'impact de certains paramètres sur la solution optimale. La première étude de cas sert de référence pour analyser l'impact des changements. L'impact des coûts reliés aux requêtes a été analysé. La détermination de ces coûts influence grandement les sous-ensembles de clients sollicités et doit être étudiée plus profondément. Le nombre de requêtes maximal permis à chaque client influence aussi la solution optimale. Suite à cette étude de cas, on conclut que le modèle doit être amélioré en le rendant dynamique. Ainsi, une planification de la distribution des requêtes peut éviter de trop grands coûts à la fin de la semaine. Finalement, la participation d'un sous-ensemble des clients résidentiels a été explorée. Un sous-ensemble des clients résidentiels a été enlevé de l'ensemble des clients dans la quatrième étude de cas. Les résultats montrent que les autres clients absorbent les requêtes et les coûts n'augmentent pas de façon significative.

ABSTRACT

The grid has changed a lot over the years. New technologies of communication and renewable production have arisen and create new challenges for the grid. We expect a higher penetration of electric vehicles in the next years. The increase use of electric vehicles can cause a large demand during peak times and have to be managed effectively. The utility can now communicate with the customers in real time. Utilities can have access to the load consumption information through smart meter. New technologies allow a new type of resources called Demand Response (DR). DR programs send requests to the customers to adapt their load consumption. The objective of the DR programs is to fit the load consumption curve to the production curve. The balance between the production and the consumption is essential to the stability of the grid. To do so, the customers adapt their load consumption according to DR requests. The load consumption can be reduced by a smart thermostat or smart water heater. It can also be shifted during off-peak periods with the charge or discharge of electric vehicles. To help the utility to dispatch DR requests among the customers, aggregators are introduced.

Aggregators act as intermediaries between the utility and the customers. They receive an incentive and utility request from the utility and distribute DR requests and incentives to customers. DR requests are defined by the load in kW to reduce, to increase or to shift. Their objective is to maximize their own profit. This research focuses on formulating an optimization problem of the aggregators. They aim to reduce the total load consumption during peak periods or to increase the total load consumption when the renewable production is high. In this research, 21 resolutions are made per week, three per day during peak times. The resolutions are interconnected to avoid the overuse of the same clients. The optimization model is based on the Economic Dispatch problem which is trivial to solve. The model dispatches DR requests among the customers while minimizing the total cost of the aggregator. The utility request has to be satisfied in order to keep the stability of the grid. The complexity of the problem comes with the uncertainty of the response of the clients. In the literature, this uncertainty is not included in the aggregator optimization problem. Several external factors influence the responsiveness of the clients like the time of the day, the day of the week, the frequency of the requests and the direction of the requests. When a client respond to the DR request, it means that the load consumption has been changed according to the request. Otherwise, the load consumption is unchanged and the client does not respond to the request. This uncertainty has to be included in the model to make it more realistic.

To account uncertainties in an optimization model, several techniques can be used. In this research, a chance-constrained optimization (CCO) model is formulated to include the uncertainty of the responsiveness of the clients to DR request. The chance constraints are transformed into nonlinear constraints using probabilistic laws. The customers are classified into three subsets to define their DR capacity. Clients with home who does not have any electric vehicle or smart appliance form the first subset. The second subset is defined by the customers who have electric vehicles or smart appliances. This group have a larger capacity DR. Finally, the commercial customers form the third subset. The commercial load profile is simulated hourly in New England, United States for several types of building such as school, restaurants, different sizes of office, etc. The software used is eShapes. Since the load consumption differs a lot between the type of commercial customers, a clustering is performed to form five clusters of commercial customers. Three subsets of probability also divide the clients with low, moderate and high probability of response.

To evaluate the utility requests, the aggregator forecasts the total load consumption. Three forecasting methods have been developed and compared. The Support Vector Machine (SVM), the nonparametric method and the ARX method have been used in the context of winter. Real data collected hourly at nine substations in December, January and February 2006 have been used to develop the methods. The nine substations are located in Quebec, Canada. Data of December, January and the first three weeks of February have been used as the training data, and the last week of February as the testing data. The three methods are compared using two metrics and the nonparametric is chosen to forecast to total load. To calculate the utility request a percentage of the total load consumption is taken.

Finally, a set of 30 000 clients is tested with the utility request calculated. The number of clients being too high, the solver does not find any solution in 8 hours. A method is developed to cluster the clients and reduce the number of variables. The cluster method has to respect the characteristic of each client and respect the probability law. With the clusters, the solver finds an optimal solution in less than a minute. Four case studies are conducted to analyse the impact of some parameters. Some conclusions can be listed from those case studies. First, the determination of the DR request cost has a huge impact on which customer is solicited. A better analysis of the cost in the electricity market should be done. Also, the model can be improved by making it dynamic. A dynamic problem minimizes the total cost over the week and can do a planning at the beginning of the week. The model can also analyse the participation of specific types of clients. A subset of clients has been removed without having a significant increase of costs.

TABLE DES MATIÈRES

DÉDICACE	iii
REMERCIEMENTS	iv
RÉSUMÉ	v
ABSTRACT	viii
TABLE DES MATIÈRES	x
LISTE DES TABLEAUX	xiii
LISTE DES FIGURES	xv
LISTE DES SIGLES ET ABRÉVIATIONS	xvii
LISTE DES ANNEXES	xviii
CHAPITRE 1 INTRODUCTION	1
1.1 Définitions et concepts de base	1
1.1.1 Réseaux électriques intelligents	1
1.1.2 Optimisation mathématique stochastique	3
1.1.3 Prédiction de la consommation	3
1.2 Éléments de la problématique	4
1.3 Objectifs de recherche	6
1.4 Plan du mémoire	6
CHAPITRE 2 REVUE DE LITTÉRATURE	7
2.1 Types de consommateurs	7
2.1.1 Secteur résidentiel	7
2.1.2 Secteur commercial	8
2.1.3 Secteur industriel	8
2.2 Profil de charge	9
2.3 Programmes de Demand Response	10
2.3.1 Objectifs principaux	10
2.3.2 Équipements de communication nécessaire aux programmes de DR	11

2.3.3	Présentation des différents programmes	12
2.4	Définition du rôle de l'agrégateur	16
2.5	Analyses des incertitudes de la disponibilité des ressources	17
2.5.1	Les causes de l'incertitude	18
2.5.2	L'impact sur le réseau	19
2.6	Les modèles d'optimisation mathématique	20
2.6.1	Le problème de répartition économique	20
2.6.2	Les modèles d'optimisation stochastiques	21
2.7	Prévision de la consommation d'électricité	22
2.7.1	Régression à l'aide de machine à vecteurs de support	23
2.7.2	Méthode non paramétrique	25
2.7.3	Régression ARX	27
2.8	Contribution	28
CHAPITRE 3 SYNTHÈSE DU TRAVAIL		29
3.1	Méthode globale	29
3.2	Le modèle mathématique	32
3.2.1	Le problème de base	32
3.2.2	Le problème stochastique simplifié	33
3.2.3	Le problème stochastique complet	35
3.3	Choix de la méthode de prévision	37
3.3.1	Présentation des techniques dans un contexte de consommation en temps hivernal	37
3.3.2	Outils de comparaison utilisés	39
3.3.3	Résultats	43
3.4	Détermination des paramètres	44
3.4.1	Sous-ensembles de clients	44
3.4.2	Regroupement des clients	49
3.5	Résolution	52
3.5.1	Résultats	53
CHAPITRE 4 DISCUSSION GÉNÉRALE		58
CHAPITRE 5 CONCLUSION ET RECOMMANDATIONS		61
5.1	Synthèse des travaux	61
5.2	Limitations de la solution proposée	61
5.3	Améliorations futures	62

RÉFÉRENCES	63
ANNEXES	66

LISTE DES TABLEAUX

Tableau 3.1	Comparaison des méthodes de prédiction pour chaque sous-station . .	43
Tableau 3.2	Requête d'utilité calculée par la méthode non paramétrique	43
Tableau 3.3	Superficie estimée pour chaque type d'immeuble en kpi^2	45
Tableau 3.4	Capacité minimale et maximale de chaque sous-ensemble calculée pour 30 000 clients	47
Tableau 3.5	Paramètre des études de cas	54
Tableau 3.6	Resultats des études de cas	54
Tableau A.1	Résultats des tests statistiques de chaque sous-station	66
Tableau A.2	Courbe de consommation réelle et prédite par les trois méthodes aux station (a) Saint-Donat et (b) Gatineau	67
Tableau A.3	Courbe de consommation réelle et prédite par les trois méthodes aux station (a) Saint-Lin et (b) Sainte-Émilie	68
Tableau B.1	Résultats des sous-stations Buckingham, Cheneville et Gamelin pour 30 000 clients et $\beta = 0,05$	69
Tableau B.2	Résultats des sous-stations Buckingham, Cheneville et Gamelin pour 30 000 clients et $\beta = 0,10$	69
Tableau B.3	Résultats des sous-stations Buckingham, Cheneville et Gamelin pour 20 000 clients et $\beta = 0,05$	69
Tableau B.4	Résultats des sous-stations Buckingham, Cheneville et Gamelin pour 20 000 clients et $\beta = 0,10$	70
Tableau B.5	Résultats du modèle des charges agrégées des sous-stations de Buckin- gham, Cheneville et Gamelin avec $\beta = 0,05$	70
Tableau B.6	Résultats du modèle des charges agrégées des sous-stations de Buckin- gham, Cheneville et Gamelin avec $\beta = 0,10$	70
Table C.1	Estimated size of each building type in kpi^2	82
Table C.2	DR capacities of 30,000 customers	82
Table C.3	Comparison of load prediction methods at each substation	84
Table C.4	Number of incorrect predictions n_{wp} calculated for four weeks at the nine substations	88
Table C.5	Total number of rejected loads n_{tot} calculated for four weeks at the nine substations	89
Table C.6	UR calculated by nonparametric method	90
Table C.7	Parameters for case studies	90

Table C.8	Results of case studies	90
-----------	-----------------------------------	----

LISTE DES FIGURES

Figure 2.1	: Part de consommation par secteur en 2013 aux États-Unis [1] . . .	7
Figure 2.2	: Exemple du profil de charge lors d'un évènement de DR [2]	9
Figure 2.3	: Flux d'information et d'électricité dans un réseau traditionnel [3] .	11
Figure 2.4	: Flux d'information et d'électricité dans un réseau électrique intelligent [3]	11
Figure 2.5	: Exemple d'une maison connectée aux programmes de DR [2]	12
Figure 2.6	: Classification des programmes de Demand Response [4]	13
Figure 2.7	: (a) Le programme centralisé (b) Le programme décentralisé [4] . .	13
Figure 2.8	: Exemple de planification des tâches et de gestion de l'énergie [4] . .	16
Figure 2.9	: La hiérarchie des agrégateurs [5]	17
Figure 2.10	: Opération pour un marché un jour à l'avance [5]	18
Figure 2.11	Les variables ζ_i et ζ_i^* [6]	24
Figure 2.12	Transformation de Kernel [7]	25
Figure 2.13	Structure de la méthode SVM [7]	26
Figure 3.1	Exemple de profil de consommation	29
Figure 3.2	Impact de la production solaire sur le profil de consommation [8] . .	30
Figure 3.3	Distribution de la loi normale standard	35
Figure 3.4	. Distribution des fréquences à la dernière semaine de février à la sous-station 1 de (a) la consommation réelle et de la consommation prédite avec (b) la méthode SVM (c) la méthode non paramétrique (d) la méthode ARX.	41
Figure 3.5	Profil de charge hebdomadaire de (a) une école et de (b) un restaurant	46
Figure 3.6	Exemple de regroupement pour les clients $i \in BH \cup LOW \cup CAT1$.	50
Figure 3.7	La hiérarchie de l'agrégation des clients	51
Figure 3.8	Répartition des requêtes de DR envoyées à chaque sous-ensemble de probabilité et de secteur pour (a) le cas de case , (b) l'étude de cas 1 et (c) l'étude de cas 2.	55
Figure 3.9	Coût par kW de réduction ou d'augmentation de chaque période de la semaine (\$/kW)	56
Figure 3.10	Répartition des requêtes de DR envoyées à chaque sous-ensemble de secteur pour (a) l'étude de cas 1 et (b) l'étude de cas 3.	57
Figure C.1	Hierarchical structure [5].	74
Figure C.2	Soft margin of SVR [6].	76

Figure C.3	Kernel transformation [7].	77
Figure C.4	Load profile of (a) school and (b) restaurant over one week.	82
Figure C.5	Example of clustering for clients $i \in BH \cup LOW \cup CAT_1$	83
Figure C.6	Hierarchical structure of clustering.	85
Figure C.7	Comparison of actual load collected during the last week of February at substation 1 and predicted load calculated by (a) SVM method, (b) nonparametric method, and (c) ARX method.	85
Figure C.8	Frequency distribution of load consumption of testing data at substation 1 using (a) actual load, (b) SVM method, (c) nonparametric method, and (d) ARX method.	86
Figure C.9	Actual and predicted loads for first week of February at substation 1.	88
Figure C.10	Distribution of DR requests for each probability level and each sector in (a) Base case, (b) Case study 1, and (c) Case study 2.	92
Figure C.11	Weekly cost per kW of reduction or increase (\$/kW).	93
Figure C.12	Distribution of DR request for each sector in (a) Base case and (b) Case study 3.	93

LISTE DES SIGLES ET ABRÉVIATIONS

DR	Demand Response
MVS	Machine à vecteurs de support
OCP	Optimisation à contraintes probabilistes
PCSO	Programmation sur le Cône du Second Ordre
PEAM	Pourcentage d'erreur absolue moyenne
REQM	Racine de l'erreur quadratique moyenne
REQMN	Racine de l'erreur quadratique moyenne normalisée
RU	Requête de l'utilité
THU	Tarification de l'heure d'utilisation
TPC	Tarification de la période critique
VAM	Valeur absolue moyenne
VE	Voiture électrique

LISTE DES ANNEXES

ANNEXE A	RÉSULTATS DE LA PRÉVISION DE LA CONSOMMATION . . .	66
ANNEXE B	RÉSULTATS DU MODÈLE D'OPTIMISATION	69
ANNEXE C	ARTICLE 1 : DEMAND RESPONSE VIA LARGE-SCALE CLUSTER- RING UNDER UNCERTAINTY OF RESOURCE AVAILABILITY .	71

CHAPITRE 1 INTRODUCTION

Le réseau électrique est en pleine transformation depuis l'avènement de nouvelles technologies. En effet, les énergies renouvelables sont en plein essor et leurs coûts de plus en plus faibles créent un engouement chez le consommateur. On voit alors apparaître davantage de ressources décentralisées, ou appelées distribuées. Traditionnellement, la génération d'électricité se faisait en masse et de façon centralisée comme avec les barrages hydro-électriques. Le consommateur d'aujourd'hui et de demain est de plus en plus soucieux de l'environnement et tend à produire de l'électricité à petite échelle. Le consommateur devient donc également producteur à travers les panneaux solaires, les batteries de stockage, etc. De plus, les technologies de communication sont également fortement améliorées. Elles permettent une communication entre le consommateur et l'utilité dans les deux sens. L'utilité peut donc utiliser le consommateur comme ressource d'électricité et s'en servir pour équilibrer le profil de charge à travers la journée. En effet, au Québec il existe une heure de pointe où la puissance totale appelée est très élevée. L'utilité peut alors utiliser les consommateurs pour réduire cette pointe à l'aide de programme incitatif. Cette recherche vise à étudier l'impact de la participation des consommateurs en heure de pointe et d'en inclure l'incertitude de la participation. De plus, cette recherche compare trois différentes méthodes de prédiction de la consommation en vue de l'inclure dans le modèle mathématique.

1.1 Définitions et concepts de base

Cette recherche comporte trois thèmes principaux, soit le réseau électrique intelligent, l'optimisation mathématique stochastique et la prédiction de la charge. Dans le but d'avoir une gestion efficace de ressources distribuées, un modèle d'optimisation mathématique est développé. Les concepts de base de chacun de ces thèmes sont détaillés dans cette section.

1.1.1 Réseaux électriques intelligents

Le réseau électrique en continuel changement voit de nouveaux acteurs apparaître. Parmi ceux-ci, les agrégateurs ont un rôle important dans le réseau électrique. Ils agissent en tant qu'intermédiaire entre l'utilité et le consommateur. C'est à travers lui que le client recevra des requêtes pour l'inciter à modifier sa consommation d'électricité. Ces requêtes font partie d'un programme incitatif appelé Gestion de la demande (Demand Response DR) qui vise à faire correspondre le profil de consommation avec le profil de production d'électricité. Ces

deux notions sont décrites ci-bas.

Agrégateur

Tel que décrit plus haut, un agrégateur est un intermédiaire entre l'utilité et les consommateurs. Il permet à l'utilité de limiter ses interactions et d'envoyer seulement des requêtes aux différents agrégateurs. Ces requêtes sont appelées requête de l'utilité (RU) et s'accompagne d'une récompense monétaire. Elles représentent la puissance totale à modifier et à distribuer à travers les consommateurs. Ces requêtes peuvent être négatives, ce qui signifie qu'une augmentation de la charge doit être effectuée. Typiquement, cela se produit à mi-journée. L'avènement des panneaux solaires peut créer une pointe de production lorsque l'irradiance solaire est au maximum. La consommation n'est généralement pas assez grande lors de cette période pour absorber cette trop grande production. L'agrégateur tend donc à faire augmenter la consommation électrique pour établir un équilibre entre la demande et la production. Les requêtes d'utilité peuvent également être positives, ce qui signifie une réduction de la consommation. Cela se produit au matin, entre 6h et 8h, et le soir, entre 17h et 19h, lorsque la consommation d'électricité est trop élevée par rapport à la production. L'agrégateur tend donc à faire diminuer la consommation totale. Ces changements des profils de consommation sont possibles grâce aux programmes de DR.

Programme incitatif

Les programmes de Demand Response sont une partie très importante du réseau électrique intelligent. Il existe plusieurs programmes différents. Dans le cadre de cette recherche, le déplacement de charge et la réduction/augmentation de la charge sont étudiés. Le déplacement de charge implique le retardement ou l'avancement d'une consommation prévue. Ce type de programme s'applique sur des charges spécifiques comme la recharge d'une voiture électrique ou l'utilisation des appareils comme une laveuse, une sècheuse ou un lave-vaisselle. Par exemple, la recharge d'une voiture électrique peut être repoussée dans la nuit au lieu qu'à l'heure d'arrivée du propriétaire qui est généralement en heure de pointe. La consommation totale sur une journée reste inchangée par ce programme, mais il permet de lisser la courbe en transférant les charges de pointe en charges hors pointe. Le déplacement de charge peut également aider à absorber la surproduction des panneaux solaires à mi-journée. La réduction/augmentation de la charge quant à elle impacte directement la consommation. Par exemple, la température d'une pièce peut être diminuée ou augmentée dans les limites du niveau de confort du client. Cette diminution, ou cette augmentation ne sera pas reprise au courant de la journée. L'agrégateur envoie donc des requêtes aux clients selon le programme

choisi. La requête comprend la puissance à modifier, la durée de l'évènement et la récompense monétaire. L'objectif de l'agrégateur est donc d'optimiser ses profits, soit la différence entre les bénéfices reçus de l'utilité et les récompenses offertes aux clients. La distribution des requêtes de DR se fait à l'aide de modèle d'optimisation et inclue l'incertitude que certains clients ne répondent pas à la requête. Dans le cadre de cette étude, une réponse positive d'un client signifie qu'il ajuste sa consommation selon la requête de DR. Une réponse négative signifie que sa consommation demeure inchangée.

1.1.2 Optimisation mathématique stochastique

Le modèle d'optimisation utilise les principes de recherche opérationnelle. Il vise à minimiser les coûts de l'agrégateur en s'assurant de respecter certaines contraintes. Les variables de ce modèle sont les requêtes de DR envoyés aux différents clients. Pour pallier l'incertitude de la réponse, l'agrégateur tend à envoyer un nombre suffisant de requêtes pour satisfaire la requête d'utilité. Il doit le faire cependant à moindre coût. La méthode utilisée dans cette recherche est l'optimisation à contraintes probabilistes (OCP). Le principe de cette méthode est d'assurer la satisfaction d'une contrainte à un certain niveau de confiance. En utilisant les principes probabilistes, il est possible de transformer cette contrainte en contrainte linéaire ou non linéaire et de l'inclure dans le modèle. La requête d'utilité est estimée grâce à la prédiction de la consommation au niveau d'une sous-station.

1.1.3 Prédiction de la consommation

La consommation d'électricité est représentée par une série chronologique, c'est-à-dire qu'elle est représentée par un ensemble de données observées chronologiquement. La prévision de la consommation permet d'estimer les valeurs futures à l'aide d'observations du passé. Ici, les valeurs des consommations des heures précédant la prévision sont utilisées pour prédire la consommation de l'heure suivante. Également, la température extérieure influence considérablement la consommation électrique durant l'hiver. Ce paramètre sera également à inclure dans les modèles de prévision de la charge. Lors de cette recherche, les modèles de prévision sont développés selon les données de consommation au Québec en hiver.

1.2 Éléments de la problématique

La décentralisation de la production d'électricité amène son lot de complexités. La génération de masse et contrôlée laisse de plus en plus de place à une génération à petite échelle et plus difficile à contrôler. L'électricité produite par des énergies renouvelables étant dépendante des conditions météorologiques n'est disponible que lorsque les conditions sont favorables et non lorsque la production est nécessaire. Ceci peut engendrer un grand déséquilibre entre la production et la consommation. Pour utiliser efficacement ces moyens de génération d'électricité, il faut pouvoir augmenter la consommation quand la production est plus élevée et la diminuer quand la production est plus faible. Des batteries de stockage peuvent aider à la régulation du réseau. Des programmes de DR peuvent également jouer le rôle de régulateur au sein du réseau.

La pénétration grandissante des voitures électriques demande à son tour une étude approfondie. Une forte croissance de l'utilisation des voitures électriques peut accroître de façon considérable la consommation en heure de pointe. La recharge des voitures se faisant généralement au retour du travail doit donc se faire de manière intelligente pour lisser la courbe de consommation. Ce que le client désire en réalité c'est que sa voiture soit rechargée lorsqu'il en a besoin. Sa recharge peut donc se faire pendant la nuit quand la consommation électrique est plus faible, ou encore à son lieu de travail à mi-journée lorsque la production solaire est plus élevée. De multiples solutions existent pour mettre à profit la génération par énergies renouvelables, il faut cependant en faire une bonne gestion pour en optimiser la fiabilité du réseau.

Il est important pour la fiabilité du réseau électrique d'avoir l'équilibre entre la production et la consommation. La régulation de la fréquence du réseau doit se faire pour assurer le bon fonctionnement. Au Québec, la fréquence doit toujours être à 60 Hz. Lorsqu'il existe une différence entre la consommation et la production, la fréquence change et les utilités doivent réagir pour l'ajuster. Une instabilité peut causer des dommages matériels ou encore des pannes d'électricité. Traditionnellement, des réserves de puissance sont mises à disposition pour ajuster la fréquence lorsque nécessaire. Avec les nouvelles technologies, ces réserves peuvent être remplacées par des batteries de stockage. Ces batteries peuvent être chargées lorsque la production d'électricité est plus importante et déchargée lorsque la consommation est plus grande.

Un autre niveau de difficulté à la gestion efficace du réseau électrique s'annonce avec la diversité des ressources dans le secteur résidentiel et commercial. Traditionnellement, les utilités avaient des contrats avec les grands consommateurs tels les industriels. Lorsque né-

cessaire, les utilités demandaient à ces clients de réduire leur consommation. Ici, les requêtes de réduction sont peu nombreuses, mais significatives. Avec la gestion du secteur résidentiel et commercial, les requêtes sont très nombreuses et petites en termes de puissance. Les clients ont différents profils de charge et différentes capacités d'ajustement de la charge. Par exemple, un restaurant ne consomme pas de la même façon qu'une école ou qu'une maison. L'algorithme doit pouvoir intégrer toutes les particularités des clients. De plus, même dans le secteur résidentiel les clients peuvent différer considérablement. Une maison peut être dotée d'appareils permettant la gestion de la consommation. Par exemple, les clients peuvent posséder des voitures électriques, des panneaux solaires ou des appareils comme les thermostats intelligents. D'autres maisons peuvent être dite de base. La maison de base peut modifier sa consommation à l'aide des thermostats ou des chauffe-eau. Le comportement de chaque client diffère également, donc la réponse aux requêtes doit pouvoir être différente d'un client à l'autre. Ce sont tous des paramètres à considérer lors de l'étude. L'hétérogénéité et le grand nombre de clients amènent la nécessité d'avoir des agrégateurs qui peuvent faire la gestion des requêtes. Les utilités peuvent donc gérer à un plus haut niveau et n'interagissent qu'avec les agrégateurs.

La distribution des requêtes de Demand Response se fait de façon très efficace avec l'aide d'un solveur. Ce qui rend le problème beaucoup plus complexe est l'intégration de l'incertitude de la réponse. En effet, plusieurs raisons peuvent faire en sorte qu'un client réponde ou non à une requête. Un projet pilote testant la réponse des clients face à un programme incitatif a mis de l'avant quelques facteurs. La température extérieure peut être un élément décisif pour un client. Par exemple, il peut faire trop froid pour qu'il accepte de baisser sa température intérieure en heure de pointe. La direction de la requête, une augmentation ou une diminution, peut également être un facteur qui influence la décision d'un client. Selon l'étude, les clients sont plus propices à répondre à une diminution de consommation qu'une augmentation de la consommation. La récompense monétaire est également un facteur très important. Évidemment, les clients seront plus enclins à répondre si le montant reçu est plus important. La détermination des coûts des requêtes est en soi un problème complexe. D'autres facteurs peuvent influencer le comportement humain notamment l'heure de la journée ou le jour de la semaine. Outre les facteurs associés au comportement humain, des raisons technologiques peuvent empêcher une réponse positive. En effet, si l'envoi de la requête échoue, il est impossible pour le client d'ajuster sa consommation. De plus, il y a forcément des facteurs imprévisibles qui influenceront la réponse d'un client. C'est pourquoi il est extrêmement difficile de prévoir de façon exacte la réponse de milliers de clients. Cette recherche tente de donner des outils aux agrégateurs afin de pallier cette incertitude.

Même s'il est difficile de prévoir la réponse réelle des clients, l'importance d'inclure cette

incertitude dans les modèles est capitale. Les programmes de DR sont utilisés pour équilibrer la production et la consommation. Si la réponse aux requêtes est surestimée, cet équilibre ne sera pas atteint. Au contraire, si la réponse est sous-estimée ou simplement négligée, d'importantes sommes d'argent seront dépensées inutilement. Il faut donc avoir un certain compromis entre le nombre de requêtes envoyées et les coûts engendrés pour obtenir le meilleur équilibre entre la production et la consommation.

1.3 Objectifs de recherche

Un des objectifs de la recherche est de créer un modèle mathématique fiable à la réalité au niveau de l'agrégateur qui distribue des requêtes de Demand Response à travers les clients disponibles. Les clients sont issus du secteur résidentiel et commercial. Ce modèle d'optimisation inclura l'incertitude liée à la réponse du consommateur face à une requête de DR. Le deuxième objectif de la recherche est de faire la prédiction à court terme de la consommation d'électricité au niveau d'une sous-station. Cette prédiction sert à calculer la requête d'utilité et est utilisée dans le modèle mathématique. La prédiction doit donc être précise pour rendre le modèle d'optimisation fidèle à la réalité. Trois méthodes de prédiction sont comparées afin de trouver celui qui offre la meilleure performance pour des données de sous-station à travers le Québec en temps hivernal. Des indicateurs sont utilisés afin d'évaluer la performance des méthodes.

1.4 Plan du mémoire

Au chapitre 2, une revue critique de la littérature présente les différents concepts utilisés dans cette recherche. Il fait état des avancées scientifiques dans ce domaine et explique les différents défis à venir. Une synthèse des travaux est présentée au chapitre 3. Ce chapitre explique la méthode utilisée et les différentes étapes de la recherche. Les différents résultats y sont également montrés. Au chapitre 4, une discussion de l'ensemble des travaux est amenée. Les avancements grâce à cette recherche sont exposés. Puis, les limitations de l'étude ainsi que les pistes de solution sont exprimées. Finalement, le chapitre 5 conclut ce mémoire. Un article scientifique, présenté en annexe, a été rédigé suite aux résultats de cette étude.

CHAPITRE 2 REVUE DE LITTÉRATURE

2.1 Types de consommateurs

Le secteur commercial et résidentiel représente ensemble une importante partie de la consommation totale d'électricité, ce qui représente un grand potentiel de réduction énergétique. Par exemple, aux États-Unis ces deux secteurs représentent plus d'un tiers de la consommation totale [1]. Jusqu'à aujourd'hui, ces deux secteurs ont été très peu exploités avec les programmes de DR, car ils amènent un lot de complexité comparé aux secteurs industriels. La présente section discute des particularités de chaque secteur ainsi que leurs applicabilités aux programmes de DR. Cette recherche est axée sur le secteur résidentiel et commercial. La figure 2.1 montre les proportions qu'ont les différents secteurs de consommation.

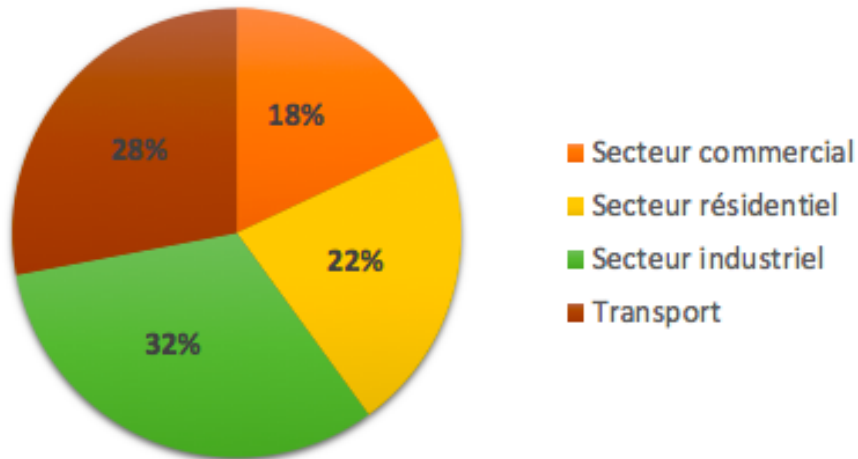


Figure 2.1 : Part de consommation par secteur en 2013 aux États-Unis [1]

2.1.1 Secteur résidentiel

L'implantation de programme de DR dans le secteur résidentiel comporte beaucoup de difficultés. Premièrement, les profils de consommation diffèrent d'un client à l'autre, et même pour un seul client différent d'une journée à l'autre. La modélisation de la consommation doit être flexible pour s'adapter à cette hétérogénéité. Dans ce secteur, les programmes de DR peuvent encourager le client à réduire sa consommation ou à déplacer sa charge dans le temps. Une charge consommée en heure de pointe peut être déplacée en heure hors pointe. Une autre particularité de ce secteur est l'hétérogénéité des appareils que les clients possèdent. En ef-

fet, plusieurs types d'appareils peuvent être utilisés pour modifier la consommation. Parmi ceux-ci, on compte les voitures électriques, les thermostats intelligents, les chauffe-eau, etc. Chaque client a donc une capacité différente à modifier sa consommation électrique. De plus, chaque client possède son horaire spécifique. Par exemple, les voitures électriques sont de plus en plus répandues et doivent être chargées de façon intelligente pour éviter une trop grosse pointe. Par contre, les clients ont des heures d'arrivée et de départ différentes. Le réseau possède un grand nombre de clients résidentiels qui chacun consomme de petites charges comparées aux clients industriels. Une gestion efficace de ces petites charges peut réduire de façon considérable la consommation en heure de pointe. Les réductions de consommation individuelles sont de l'ordre du kilowatt. Bien que le secteur résidentiel comporte beaucoup de complexité, il possède un grand potentiel pour les programmes de DR [4].

2.1.2 Secteur commercial

Typiquement, les profils de charge du secteur commercial sont plus prévisibles. Ils peuvent varier d'une journée à l'autre selon les opérations, mais sont généralement très semblables d'une semaine à l'autre. La consommation dans ce secteur dépend principalement de la température extérieure, des opérations de l'entreprise et du moment de la journée ou de la semaine. Les consommations électriques les plus importantes sont l'utilisation de climatiseur ou de chauffage, l'éclairage et l'utilisation d'appareils électroniques. Les programmes de DR vont généralement modifier la température ambiante pour ajuster la consommation [4]. Ce secteur comprend plusieurs types de bâtiment comme des écoles, des restaurants, des hôtels, des bureaux d'entreprises, etc. Chacun de ces bâtiments a des profils de charge différents. Leur consommation individuelle est plus importante que dans le secteur résidentiel, mais leur nombre est moins important. Leur réduction individuelle varie d'un bâtiment à l'autre, mais est de l'ordre d'une dizaine ou d'une centaine de kilowatts dépendamment de la taille de l'immeuble. Ce secteur offre également un grand potentiel pour les programmes de DR lorsqu'il est bien géré.

2.1.3 Secteur industriel

Finalement, le secteur industriel est formé des plus grands consommateurs en termes de mégawatts. Ils sont moins nombreux, mais consomment beaucoup plus que les autres secteurs. Traditionnellement, les clients de ce secteur ont des contrats avec les utilités pour réduire leurs consommations lorsque nécessaire. Ces réductions sont de l'ordre du mégawatt et sont récompensées par une réduction sur la facture.

2.2 Profil de charge

Pour comprendre l'utilité des programmes de DR, il est important de comprendre les profils de charge. À la figure 2.2, un exemple de profil de charge est illustré. La courbe en bleu représente la consommation (en W) d'un certain client en fonction du temps. Ce que visent les programmes de DR est de diminuer la puissance en heure de pointe pendant un certain temps. Pour pallier une trop grande consommation de puissance, l'utilité doit activer des centrales d'appoint ce qui résulte en de grands coûts de production. Les utilités veulent réduire la consommation totale en heure de pointe pour éviter d'avoir à activer les centrales d'appoint. L'énergie consommée (en Wh) est représentée par l'aire sous la courbe. Il existe des programmes de DR qui ne modifient pas l'énergie consommée pendant la journée, mais diminuent la puissance consommée en heure de pointe. La courbe en orange représente la consommation réelle lors de l'évènement de DR et la courbe en gris représente la charge qui aurait été consommée sans évènement de DR. Un évènement de DR est défini comme un changement de consommation par rapport à la consommation de base en échange d'un incitatif.

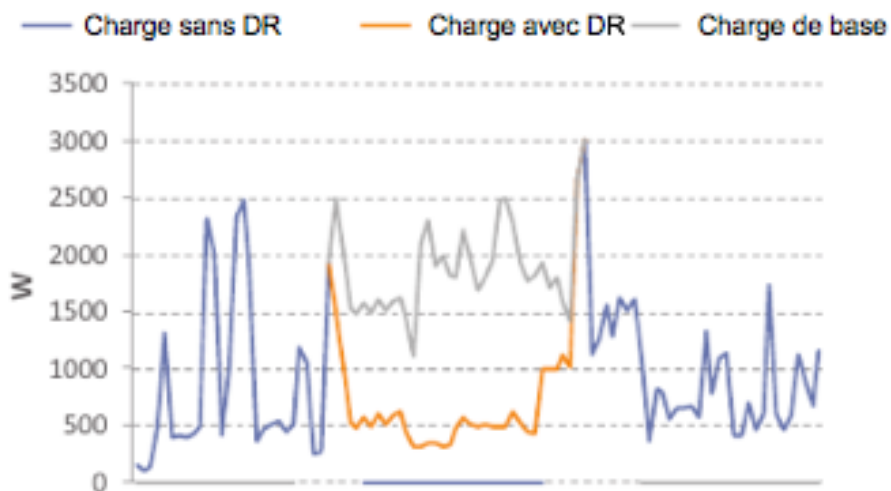


Figure 2.2 : Exemple du profil de charge lors d'un évènement de DR [2]

Lors d'une requête de DR, les clients reçoivent comme information la direction de la requête (augmentation ou diminution de la consommation), le volume de la requête [kW], la valeur de la récompense monétaire [\$/kW], l'heure de l'évènement et la durée de l'évènement [2].

2.3 Programmes de Demand Response

Selon le Département de l'Énergie des États-Unis (US Department of Energy), le DR est défini comme «un tarif ou un programme établi pour motiver des changements de consommation d'électricité par le client, en réponse au changement du prix de l'électricité dans le temps, ou pour distribuer des incitatifs prévus pour encourager la baisse de la consommation d'électricité quand les prix courants sont hauts ou quand la stabilité du réseau électrique est menacée» [9]. Le DR offre plusieurs avantages au réseau électrique et peut être classifié en différentes catégories.

2.3.1 Objectifs principaux

Les programmes de DR ont quatre principaux objectifs décrits ci-dessous [4].

1. La réduction de la consommation totale d'électricité : cette réduction profite au consommateur qui réduit sa facture d'électricité, mais également à l'utilité qui réduit ses coûts associés à la production. Cette réduction est faite grâce au changement de consommation de la part du consommateur [10].
2. Réduction de la quantité nécessaire de production électrique : cet objectif découle de l'objectif décrit ci-haut. En réduisant la consommation totale en heure de pointe, l'utilisation des centrales d'appoints n'est plus nécessaire. Les centrales d'appoints sont utilisées pour assurer la production d'électricité nécessaire en heure de pointe. En réduisant la production, les utilités peuvent plus facilement atteindre leurs objectifs de réduction de pollution atmosphérique et diminuer leurs coûts de production [9].
3. L'adaptation de la demande conformément à l'énergie disponible : spécialement dans les régions où la pénétration des énergies renouvelables est grande, il est important que la demande s'adapte selon l'électricité générée pour assurer la stabilité du réseau. La génération par énergie renouvelable comporte plus d'incertitude due aux conditions météorologiques. Une surproduction ou une sous-production peut se produire et ainsi entraîner une instabilité sur le réseau [11].
4. Réduction ou élimination des surcharges dans le réseau de distribution : cet objectif est atteint grâce aux opérateurs sur le réseau de distribution qui prennent des décisions en temps quasi-réel pour assurer la stabilité du réseau [12].

2.3.2 Équipements de communication nécessaire aux programmes de DR

Les figures 2.3 et 2.4 montrent l'évolution du réseau électrique. Les nouvelles technologies de communication permettent un flux d'information à deux sens. Traditionnellement, l'information de consommation passait seulement des consommateurs à l'utilité. Aujourd'hui, l'utilité peut envoyer de l'information comme des requêtes de DR aux consommateurs et les consommateurs peuvent envoyer leur information de consommation plus rapidement à l'aide des compteurs électriques intelligents.

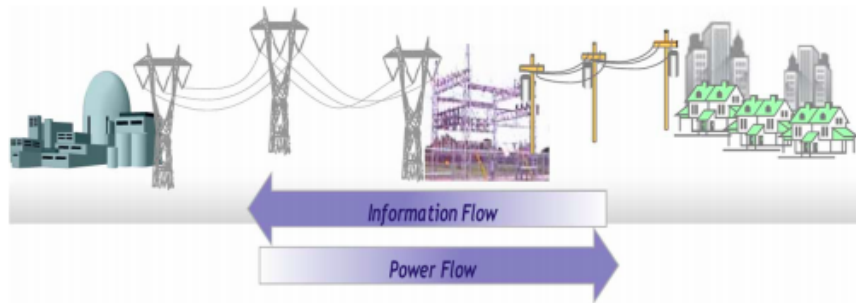


Figure 2.3 : Flux d'information et d'électricité dans un réseau traditionnel [3]

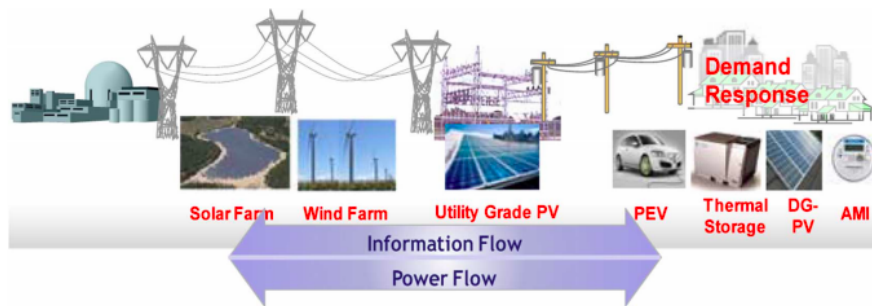


Figure 2.4 : Flux d'information et d'électricité dans un réseau électrique intelligent [3]

Plus précisément, la figure 2.5 montre les équipements de communication nécessaire pour offrir un programme de DR. L'agrégateur communique avec un appareil résidentiel de gestion d'énergie qui à son tour communiquera avec les appareils intelligents. L'appareil résidentiel de gestion d'énergie peut gérer la température d'un thermostat intelligent par exemple. Les appareils de communication dans un réseau électrique intelligent doivent avoir certaines caractéristiques pour assurer le bon fonctionnement des programmes de DR [4].

- Offrir une qualité de service : les appareils assurant la communication entre les divers acteurs du réseau électrique intelligent doivent être fiables. Ils doivent avoir une bande passante assez large pour permettre le transport des différents messages avec un minimum d'échec [13].
- Être interopérable : dans le réseau électrique intelligent, la communication entre divers appareils est essentiel. Ces appareils doivent donc pouvoir interagir entre eux via des protocoles de communication standard [13].
- Être évolutif et flexible : les programmes de DR sont plus efficaces lorsqu'un grand nombre de clients y participent. Les systèmes de communication doivent donc être évolutifs et flexibles pour permettre une adaptation du nombre de clients. Les systèmes inscrits dans un nuage semblent être une bonne solution pour ce type d'application [14].
- Être sécuritaire : il est nécessaire que les appareils de communication soient sécuritaires afin de protéger l'information privée des consommateurs. De plus, ces appareils doivent être protégés contre l'altération d'information comme les prix courants envoyés par l'agrégateur ou l'utilité. L'infiltration des programmes malveillants pourrait compromettre le réseau et doit être bloquée [15].



Figure 2.5 : Exemple d'une maison connectée aux programmes de DR [2]

2.3.3 Présentation des différents programmes

Les programmes de DR peuvent être classifiés en différentes catégories montrées à la figure 2.6. Le détail de chaque catégorie est présenté dans la présente section.

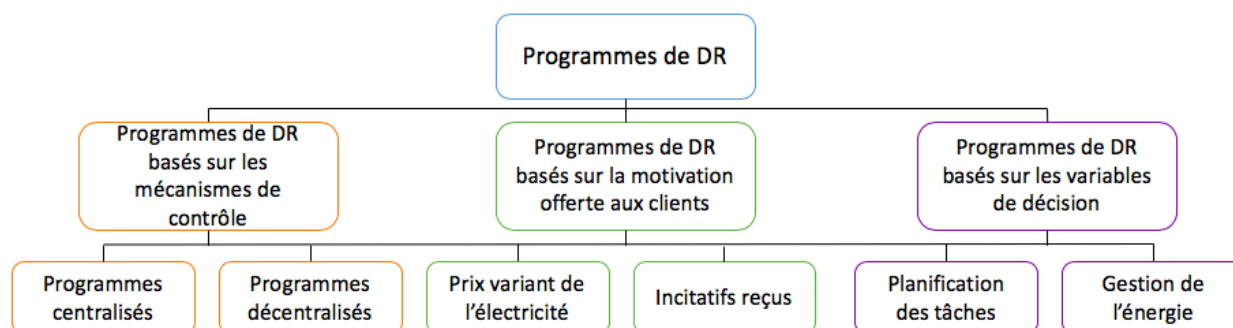


Figure 2.6 : Classification des programmes de Demand Response [4]

Programmes de DR basés sur les mécanismes de contrôle

La figure 2.7 montre les deux types de programmes basés sur les mécanismes de contrôles, soit le programme centralisé et le programme décentralisé.

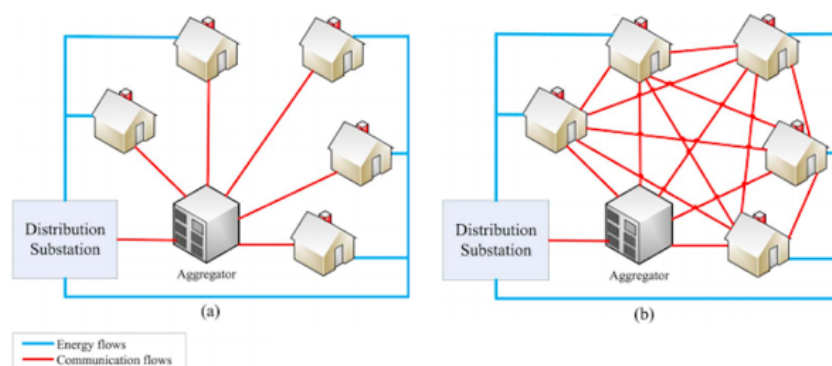


Figure 2.7 : (a) Le programme centralisé (b) Le programme décentralisé [4]

Les programmes centralisés sont contrôlés par une seule entité qui collecte l'information de chaque client. Dans ce schéma, l'agrégateur prend toutes les décisions de DR et communique lui-même avec chacun des clients. Les programmes centralisés sont efficaces pour contrôler les charges thermodynamiques (air conditionné, chauffage) et le rechargement des voitures électriques. Ils sont également très utilisés dans les micro-réseaux. Ils facilitent l'intégration d'énergie renouvelable et assurent l'équilibre du micro-réseau en mode îloté [4]. Un micro-réseau est défini comme « un groupe de charges interconnectées et de ressources distribuées compris dans une frontière électrique définie qui agit comme une seule entité contrôlable en respect du réseau électrique. Un micro-réseau peut être connecté ou déconnecté du réseau

électrique et a la capacité d’opérer en mode connecté au réseau ou en mode îloté»[16]. Dans ce schéma, les clients n’ont pas conscience de l’implication des autres clients et agissent individuellement. Ce type des programmes est utilisé dans cette recherche où les décisions de DR sont prises uniquement par l’agrégateur.

Les programmes décentralisés quant à eux permettent une communication entre les clients. Les consommateurs ont accès à l’état du réseau et peuvent réagir si l’état du réseau est critique. Les consommateurs reçoivent de l’utilité les prix courants et peuvent ajuster leurs consommations par rapport à ce prix. Ce schéma est également utilisé pour faire la gestion des recharges de voitures électriques. Les consommateurs peuvent conjointement réduire la consommation totale. Ce type de programmes permet une meilleure protection de l’information du consommateur, car l’utilité ne collecte pas les données sur les prises de décision.

Programmes de DR basés sur la motivation offerte aux clients

Ces programmes de DR offrent deux différentes motivations aux clients, soit un prix variable de l’électricité ou des incitatifs reçus. Habituellement, la méthode du prix variable est utilisée dans le secteur résidentiel et la méthode par récompenses est utilisée dans le secteur industriel. Il existe plusieurs méthodes de facturation de l’électricité. Les principales sont décrites ci-dessous.

- Prix fixe : comme établi au Québec, le prix de l’électricité ne varie pas dans le temps. Ainsi, la seule façon pour un client de recevoir une facture d’électricité plus faible est de réduire sa consommation d’électricité pendant un moment de la journée.
- Tarification de l’heure d’utilisation (THU) : selon cette méthode, les tarifs sont fixes pour différentes périodes. Les tarifs peuvent varier au courant de la journée ou de la semaine. Ainsi, en heure de pointe le prix d’électricité est plus élevé et hors pointe le prix est plus faible. Cette méthode est grandement utilisée internationalement, notamment en Ontario. Le client peut donc ajuster sa consommation durant la journée pour consommer moins en heure de pointe et plus en heure hors pointe. De cette façon, il peut consommer autant d’électricité pendant la journée, mais avoir tout de même une réduction au niveau de sa facture.
- Tarification de la période critique (TPC) : cette méthode de facturation est très semblable au THU, mais le prix d’une période peut changer. Lorsque le réseau est en péril, l’utilité peut modifier le prix d’une période et en avertir les clients généralement un jour à l’avance.

Les programmes par incitatifs offrent des récompenses monétaires fixes ou variables dans le temps aux consommateurs qui modifient leur consommation durant certaines périodes où

le réseau électrique est en stress. La participation à ce genre de programmes est volontaire. Les consommateurs reçoivent des réductions sur leur facture dépendamment de leur réponse. Certains programmes peuvent même pénaliser un client si celui-ci ne répond pas à un événement de DR. Cette recherche utilise ce type de programme. Il existe plusieurs programmes par incitatifs. Les principaux sont décrits ci-dessous.

- Contrôle direct de la charge : dans ce type de programme, l'utilité peut directement contrôler les charges en activant ou désactivant l'appareil. Habituellement, l'utilité peut contrôler les climatiseurs et les chauffe-eau en s'assurant que le niveau de confort du client est respecté. Le contrôle direct de la charge s'applique bien au secteur résidentiel. Il nécessite l'installation de système de contrôle pour assurer la communication entre l'utilité et le consommateur. Le client reçoit donc une réduction de facture lorsqu'une réduction de consommation est effectuée.
- Charge réductible ou interruptible : ce type de programme s'adresse principalement au secteur industriel. Ils offrent des contrats aux clients dans le but de réduire la consommation lors de période critique. L'utilité communique avec le client lorsque nécessaire et le client a un certain temps pour répondre à la requête. En cas de refus, le client peut recevoir une pénalité monétaire, et en cas d'acceptation il reçoit un montant d'argent.

Il existe d'autres types de programmes par récompense comme le programme d'urgence, le programme de capacité du marché et le programme par enchère [4].

Programmes de DR basés sur les variables de décision

Les programmes peuvent être divisés selon deux types de variables de décision : la planification des tâches et la gestion d'énergie. La planification des tâches consiste à déterminer l'heure d'activation d'une certaine tâche. Ces tâches peuvent être arrêtées et déplacées dans le temps. Parmi ces tâches, la recharge de la voiture électrique est un bon exemple. La recharge peut se faire pendant la nuit au lieu du retour à la maison, qui correspond généralement à l'heure de pointe. Ces programmes doivent considérer les différentes contraintes des clients pour émettre une certaine planification. L'objectif principal est de réduire la consommation en heure de pointe et de la déplacer en heure hors pointe. Le client reçoit une récompense monétaire lorsqu'une charge est déplacée. Ce type de programme ne permet pas une réduction globale de l'énergie, mais permet une régulation du profil de charge. Le déplacement de la charge est une méthode grandement utilisée dans la littérature.

Contrairement à la planification des tâches, la gestion d'énergie vise à réduire la consommation d'électricité en heure de pointe sans déplacement de la consommation en heure hors

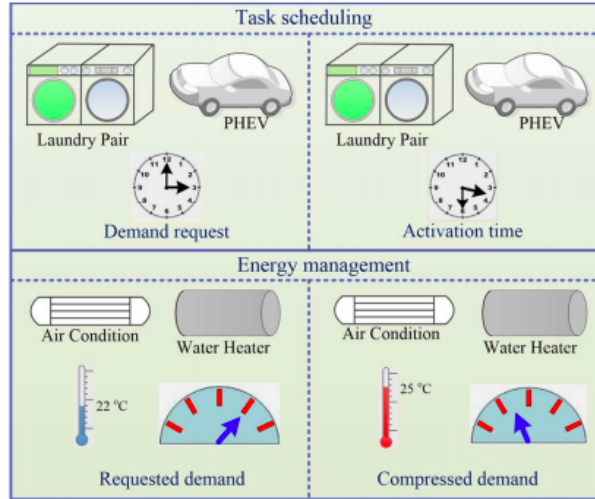


Figure 2.8 : Exemple de planification des tâches et de gestion de l'énergie [4]

pointe [17]. Ce type de programme s'applique davantage aux charges thermodynamiques comme les climatiseurs et le chauffage. Par exemple, en heure hors de pointe en hiver la température d'une pièce pourrait être diminuée pendant un certain temps pour réduire la consommation. Évidemment, le confort du client doit être considéré dans la prise de décision. Les clients reçoivent une réduction sur leur facture d'électricité lorsqu'un évènement de DR se produit.

Cette recherche n'utilise pas explicitement l'un ou l'autre type de programmes. L'agrégateur envoie une requête pour une réduction de consommation. L'appareil résidentiel de gestion d'énergie du client pourra décider de la façon dont la consommation est réduite, soit par le déplacement de charge ou par la réduction de consommation. L'agrégateur ne prend pas ce genre de décision par rapport à un client.

2.4 Définition du rôle de l'agrégateur

L'agrégateur, présenté à la figure 2.9, agit en tant qu'intermédiaire entre l'utilité et les consommateurs [5]. Au plus haut niveau, l'opérateur détermine les récompenses allouées aux agrégateurs par unité de réduction. L'opérateur vise à minimiser ses frais d'opération. L'opérateur envoie la requête d'utilité à l'agrégateur. La requête d'utilité est définie comme le nombre de kW à augmenter ou à diminuer par rapport à la consommation totale des clients. Au niveau du milieu, l'agrégateur tente de maximiser ses profits selon les récompenses reçues de l'opérateur et des récompenses allouées aux clients. L'agrégateur envoie les requêtes

de DR aux clients afin de satisfaire la requête d'utilité. Finalement, au niveau le plus bas les clients visent à modifier leur consommation en maximisant leur récompense reçue. Dans cette recherche, l'étude se trouve au niveau de l'agrégateur. La fonction objectif est donc de maximiser les profits en respectant certaines contraintes.

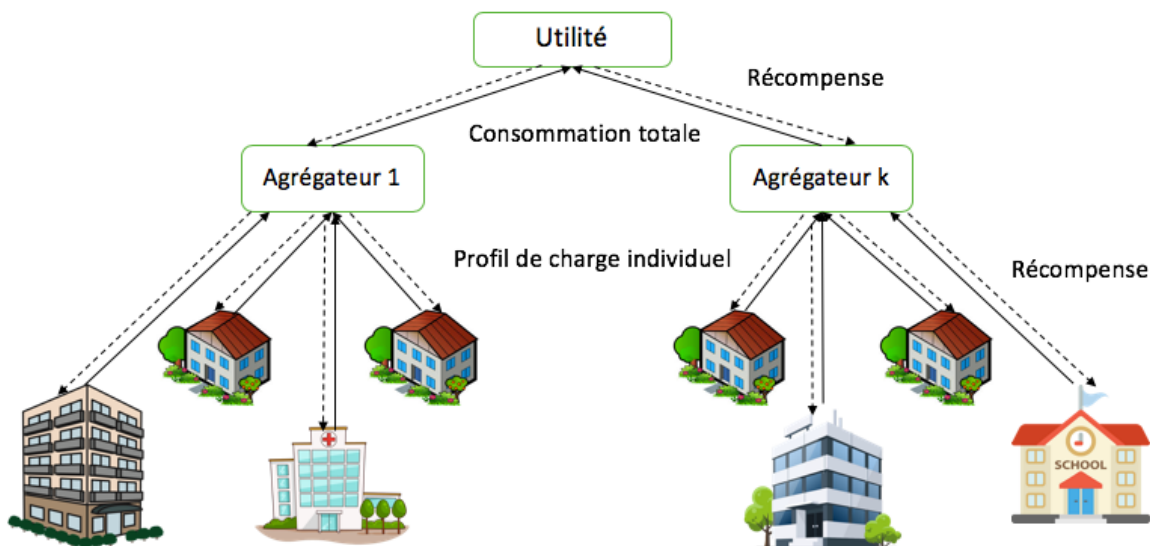


Figure 2.9 : La hiérarchie des agrégateurs [5]

Une suite d'opération et de négociation se fait entre l'agrégateur et les clients. Dans le marché de l'électricité, l'opérateur annonce aux agrégateurs un jour à l'avance le montant des récompenses alloué pour chaque unité de réduction. Alors chaque agrégateur à son tour entre en négociation avec les clients. L'agrégateur annonce les récompenses aux clients. Ceux-ci modifient leur profil de consommation en maximisant leur bénéfice individuel. L'agrégateur change ou non sa récompense. Suite à un accord entre l'agrégateur et le client, la négociation prend fin. Ensuite, chaque agrégateur annonce à l'opérateur les offres de DR et s'en suit une compétition entre les différents agrégateurs. L'opérateur accepte donc certaines offres et remet les récompenses monétaires aux agrégateurs concernés. Toute l'opération est montrée à la figure 2.10.

2.5 Analyses des incertitudes de la disponibilité des ressources

Afin de bien modéliser l'incertitude de la réponse des clients face aux requêtes de DR, il est important d'en comprendre les causes. La sous-section 2.5.1 présente les causes de l'incerti-

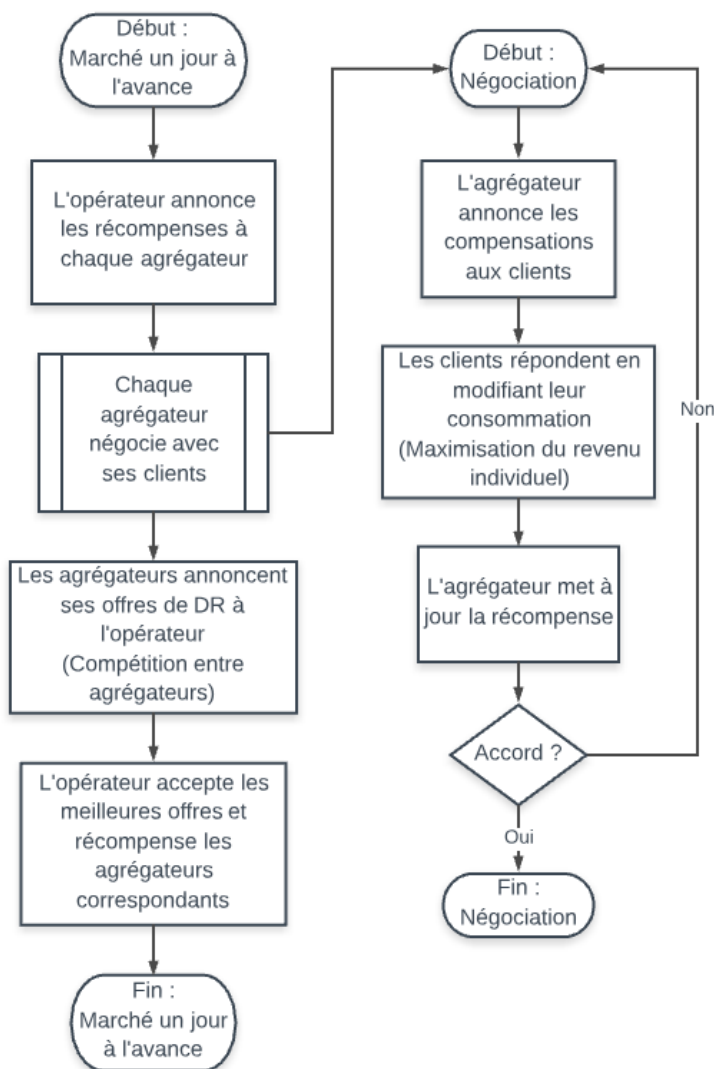


Figure 2.10 : Opération pour un marché un jour à l'avance [5]

tude trouvées grâce à un projet pilote en Espagne. La sous-section 2.5.2 montre les impacts potentiels de cette incertitude sur le réseau.

2.5.1 Les causes de l'incertitude

Dans une récente étude, les chercheurs ont établi une méthode pour caractériser la flexibilité des clients issus du secteur résidentiel face aux programmes de Demand Response [2]. Un projet pilote a été effectué en Espagne pour obtenir des données réelles sur les clients en réponse au DR. Les chercheurs présentent la flexibilité comme étant :

$$Flex_{it} = L_{it} - L'_{it} \quad (2.1)$$

La flexibilité d'un client i au temps t est représentée par la différence entre la charge observée L_{it} et la charge de base estimée L'_{it} . La charge de base est la charge qui serait observée s'il n'y avait aucun évènement de DR. Ainsi si un client ne répond pas à la requête de DR, sa flexibilité devient nulle puisque $L_{it} = L'_{it}$. Une analyse de la flexibilité des clients peut donc être utilisée afin de caractériser les probabilités de réponse des clients face aux requêtes de DR.

La flexibilité est influencée par plusieurs facteurs externes. Grâce aux observations, les facteurs trouvés sont la température extérieure, l'heure de la journée, la journée de la semaine, la fréquence des requêtes et la direction des requêtes (augmentation ou diminution de la charge). La durée des requêtes ainsi que les récompenses monétaires associées aux requêtes sont également des facteurs.

Les chercheurs en sont également venus à établir quatre critères pour caractériser la flexibilité des clients, soit la consommation d'électricité annuelle, le nombre d'occupants dans la maison, le nombre de pièces de la maison qui sert d'indicateur de la grandeur de la maison et le niveau d'éducation des occupants de la maison. Ces critères permettent de catégoriser les clients en trois catégories de flexibilité, soit une catégorie faible, une catégorie modérée et une catégorie élevée. Plusieurs facteurs externes seront considérés pour cette recherche et seront énoncés dans le chapitre 3. La notion de catégorisation des clients sera également utilisée afin de modéliser l'incertitude.

En plus, tel qu'énoncé dans la sous-section 2.3.2, les appareils de communication doivent être fiables. Il existe cependant une probabilité qu'un appareil fasse défaut et que la requête de DR ne soit pas reçue par un client.

2.5.2 L'impact sur le réseau

Dans une étude, les chercheurs présentent deux études de cas d'agrégation de ressources de DR, une sur l'agrégation des véhicules électriques et l'autre sur l'agrégation des climatiseurs [18]. Dans cette recherche, l'impact d'une mauvaise estimation de la flexibilité est expliqué.

D'une part, une surestimation de la flexibilité des ressources peut mener à une incapacité de l'agrégateur à atteindre ses objectifs ce qui amène des pénalités financières. De la même façon, une surestimation de la probabilité de réponse des clients peut amener à une insatisfaction de la requête d'utilité.

D'une autre part, une sous-estimation de la flexibilité mène à une sous-utilisation des ressources et par conséquent à une perte d'opportunité de revenu. La comparaison avec les probabilités de réponses des clients peut également se faire. Une sous-estimation de la probabilité d'une ressource mène à une sous-exploitation de cette ressource et peut engendrer des coûts supplémentaires à l'agrégateur.

2.6 Les modèles d'optimisation mathématique

Pour effectuer une bonne gestion de la distribution des requêtes de DR, l'agrégateur doit développer un modèle d'optimisation mathématique. Ces modèles visent à trouver la valeur optimale d'une fonction objectif tout en s'assurant de respecter certaines contraintes. Dans le cas de cette recherche, la fonction objectif minimise les coûts totaux de l'agrégateur. Les contraintes peuvent être des contraintes physiques ou des contraintes de confort déterminées par les clients. Pour faire la distribution des requêtes, le modèle mathématique s'inspire d'un modèle connu du nom de problème de répartition économique. Pour inclure l'incertitude de la disponibilité des ressources, le modèle utilise l'optimisation à contraintes probabilistes.

2.6.1 Le problème de répartition économique

Le problème de répartition économique, ou *Economic Dispatch* en anglais, est un problème connu et largement étudié dans la littérature. Ce problème vise à minimiser les coûts de génération de l'électricité sur une période de temps tout en satisfaisant diverses contraintes. Généralement, la période de temps est d'une durée d'une heure [19]. La formulation du problème de base est :

$$\min_P \quad F = \sum_{i=1}^n f_i(P_i) \quad (2.2)$$

$$s.c. \quad \sum_{i=1}^n P_i = P_D + P_{pertes} \quad (2.3)$$

$$\underline{P}_i \leq P_i \leq \overline{P}_i \quad (2.4)$$

Les coûts de production sont représentés par la fonction $f_i(P_i)$ exprimés en \$. La variable P représente la quantité d'électricité générée par la ressource i exprimée en kW. P_D est la demande d'électricité du système et P_{pertes} est la puissance perdue à cause du transport. Finalement, \underline{P}_i et \overline{P}_i sont respectivement les capacités minimales et maximales de génération de la ressource i . Le problème de base développé lors de cette étude s'inspire de ce problème

connu.

2.6.2 Les modèles d'optimisation stochastiques

Les modèles d'optimisation stochastiques sont des modèles qui incluent l'incertitude d'un ou plusieurs paramètres approximatés par des distributions probabilistes. Les modèles déterministes sont des modèles où tous les paramètres sont connus lors de la résolution du problème. Par contre, dans la réalité les paramètres sont rarement connus de façon exacte. Une estimation des paramètres peut être utilisée dans les modèles déterministes par exemple en prenant la moyenne des paramètres observés. Ce type de modèle n'est pas représentatif de la réalité et peut mener à une mauvaise prise de décision. Pour une meilleure représentation de la réalité, les modèles stochastiques sont préférables même s'ils sont mathématiquement plus complexes.

Différentes approches sont utilisées dans la littérature pour inclure de l'incertitude dans les modèles. Parmi celles-ci, les modèles en deux étapes sont grandement utilisés dans la littérature pour faire la gestion des programmes de DR [20]. Cette méthode consiste à modéliser plusieurs scénarios dont les probabilités de réalisation suivent une distribution. La première étape consiste à prendre des décisions sans savoir l'information sur la valeur des paramètres incertains. Une fois l'incertitude dévoilée, une deuxième prise de décision est réalisée ce qui correspond à la deuxième étape [21].

Finalement, l'optimisation à contraintes probabilistes est la méthode utilisée dans cette étude pour modéliser le problème stochastique. Bien que cette méthode offre beaucoup d'avantages, celle-ci est peu utilisée dans la littérature, car elle est mathématiquement plus complexe [22].

Optimisation à contraintes probabilistes

L'optimisation à contraintes probabilistes, *Chance-Constrained Optimization* en anglais, s'appuie sur un problème initial qui ne comprend aucune incertitude. Une ou plusieurs contraintes sont transformées en contraintes probabilistes, comme à l'équation (2.10). La contrainte probabiliste assure que la contrainte (2.7) sera toujours respectée avec un niveau de confiance α . La contrainte probabiliste (2.10) peut être transformée en contrainte linéaire ou non linéaire pour permettre la résolution du problème. Cette transformation implique une connaissance de la distribution de $g_i(x)$ [23].

$$\text{Problème initial :} \quad \min_x f(x) \quad \text{s.c.} \quad h(x) = 0 \quad (2.5)$$

$$g(x) \geq 0 \quad (2.6)$$

$$g_i(x) \geq 0 \quad (2.7)$$

$$\text{Problème OCP :} \quad \min_x f(x) \quad \text{s.c.} \quad h(x) = 0 \quad (2.8)$$

$$g(x) \geq 0 \quad (2.9)$$

$$Prob(g_i(x) \geq 0) \geq \alpha \quad (2.10)$$

$$\alpha \in [0, 1] \quad (2.11)$$

2.7 Prédiction de la consommation d'électricité

La prévision de la consommation est une partie importante du problème. La requête d'utilité est estimée grâce aux modèles de prévision. Plusieurs familles de méthodes existent pour faire la prévision de la consommation d'électricité. Les caractéristiques des différentes méthodes statistiques et d'apprentissage automatique sont présentées [24] et discutées dans cette section.

Parmi les méthodes statistiques, on compte les méthodes ARMA, ARIMA et ARX. Ces méthodes sont simples, rapides et offrent des résultats relativement précis. Elles peuvent également prendre en compte les saisonnalités des séries chronologiques. Elles sont efficaces pour des prévisions à court terme. Dans la famille des méthodes statistiques, on compte également la régression linéaire. Cette méthode est aussi simple, rapide et offre une précision respectable. Par contre, la régression linéaire ne peut pas prendre en compte les saisonnalités. De plus, les méthodes statistiques ne sont pas efficaces avec les modèles non linéaires.

Une autre grande famille de technique de prévision est l'apprentissage automatique. Bien que l'apprentissage automatique offre de grands avantages comparativement aux méthodes statistiques, ces méthodes sont beaucoup plus complexes. Parmi les méthodes d'apprentissage automatique, deux méthodes ont fait leurs preuves pour la prévision de la consommation électrique [6]. Le réseau de neurones permet d'obtenir des résultats précis dans un temps rapide pour des modèles non linéaires [25]. Finalement, la régression à l'aide de machine à vecteurs de support (MVS), offre également une bonne précision pour les modèles non linéaires. Son architecture est plus robuste que le réseau de neurones et nécessite moins de données d'entraînement. Cette méthode est grandement utilisée dans la littérature pour la prédiction de consommation [26].

Lors de cette recherche, trois méthodes de prédiction ont été utilisées et comparées. La

régression à l'aide de vecteurs de support, la méthode non paramétrique et la méthode ARX sont les trois méthodes choisies pour faire la prédiction de la consommation. La théorie de chaque méthode est présentée dans les prochaines sections.

2.7.1 Régression à l'aide de machine à vecteurs de support

La consommation d'électricité peut être prédite à l'aide d'apprentissage automatique, plus précisément à l'aide de la méthode de machine à vecteurs de support, ou *Support Vector Machine* (SVM) en anglais [27]. Cette méthode vise à approximer la matrice des valeurs de sortie y en fonction de la matrice des paramètres d'entrée x , également appelées prédicteurs.

$$y = f(x) = w * \phi(x) + b \quad (2.12)$$

L'objectif est de déterminer les valeurs optimales des poids w et du seuil b . Ces paramètres peuvent être calculés en minimisant la «platitude» des poids et le risque empirique. La «platitude» est calculée par la norme Euclidienne $\|w\|^2$ et le risque empirique $R_{emp}(f)$ est l'erreur générée par l'estimation de la valeur.

L'objectif global est de minimiser le risque régularisé $R_{reg}(f)$.

$$R_{reg}(f) = R_{emp}(f) + \frac{1}{2}\|w\|^2 \quad (2.13)$$

Le modèle d'optimisation du SVM est :

$$\min R_{reg}(f) = \min R_{emp}(f) + \frac{1}{2}\|w\|^2 \quad (2.14)$$

$$R_{emp}(f) = \frac{1}{N} \sum_{i=1}^N L_{\epsilon}(y_i, f(x_i)) \quad (2.15)$$

En utilisant la fonction incitative ϵ , le problème devient :

$$\min \frac{1}{2}\|w\|^2 + C \sum_{i=1}^N L_{\epsilon}(y_i, f(x_i))$$

$$L_{\epsilon}(Y_i, f(X_i)) = \begin{cases} 0 & \text{si } |y_i - f(x_i)| \leq \epsilon \\ |y_i - f(x_i)| - \epsilon & \text{sinon} \end{cases}$$

Pour rendre le problème faisable, des variables ζ_i et ζ_i^* sont introduites.

$$\min_{\zeta_i, \zeta_i^*, w, b} \quad \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\zeta_i + \zeta_i^*) \quad (2.16)$$

$$s.c. \quad y_i - w\phi(x_i) - b \leq \epsilon + \zeta_i \quad i = 1 \dots N \quad (2.17)$$

$$w\phi(x_i) + b - y_i \leq \epsilon \zeta_i^* \quad i = 1 \dots N \quad (2.18)$$

$$\zeta_i, \zeta_i^* \geq 0 \quad i = 1 \dots N \quad (2.19)$$

Comme le problème est convexe, il est plus simple de le résoudre en utilisant la forme duale et les multiplicateurs de Lagrange. Le problème dual est présenté sous la forme :

$$\max_{\alpha_i, \alpha_i^*} \quad -\frac{1}{2} \sum_{i,j=1}^N (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) \langle x_i, x_j \rangle \quad (2.20)$$

$$-\epsilon \sum_{i=1}^N (\alpha_i - \alpha_i^*) + \sum_{i=1}^N y_i (\alpha_i - \alpha_i^*) \quad (2.21)$$

$$s.c. \quad \sum_{i=1}^N (\alpha_i - \alpha_i^*) = 0 : \alpha_i, \alpha_i^* \in [0, C] \quad (2.22)$$

L'approximation de la valeur de sortie $y = f(x)$ devient :

$$f(x) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) \langle x, x_i \rangle + b. \quad (2.23)$$

Afin de traiter la non-linéarité, une fonction de kernel est utilisée pour mettre en plan l'es-

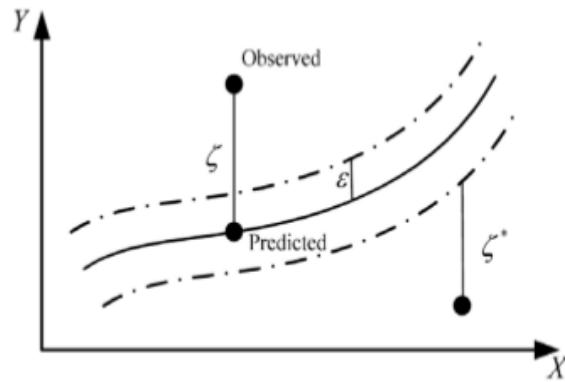


Figure 2.11 Les variables ζ_i et ζ_i^* [6]

pace d'entrée X dans une dimension supérieure. Une fonction de kernel est une fonction qui satisfait la condition de Mercer :

$$k(x_i, x_j) = \langle \phi(x_i), \phi(x_j) \rangle. \quad (2.24)$$

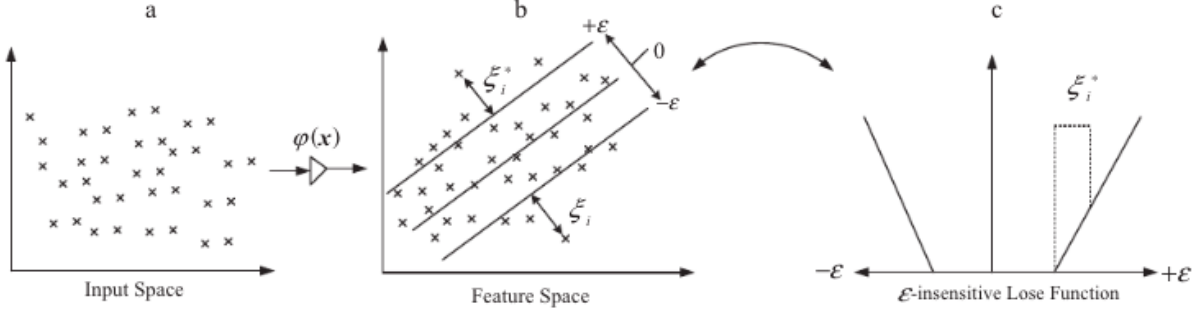


Figure 2.12 Transformation de Kernel [7]

Cette fonction peut être remplacée dans l'approximation de $f(x)$:

$$f(x) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) k(x_i, x_j) + b. \quad (2.25)$$

Dans la littérature, la fonction de kernel gaussienne est fréquemment utilisée :

$$k(x_i, x_j) = \exp(-\lambda \|x_i - x_j\|^2) \quad (2.26)$$

Les points qui sont sur ou à l'extérieur du tube ϵ avec des multiplicateurs de Lagrange α nuls sont définis comme les vecteurs de support. Les paramètres optimaux sont ceux qui minimisent l'erreur de prédiction et sont habituellement définis empiriquement.

2.7.2 Méthode non paramétrique

La méthode non paramétrique est une méthode efficace pour la prédiction de consommation énergétique à court terme [28]. La régression non paramétrique peut être construite en calculant l'estimation de la fonction de densité à partir d'un échantillonnage de données.

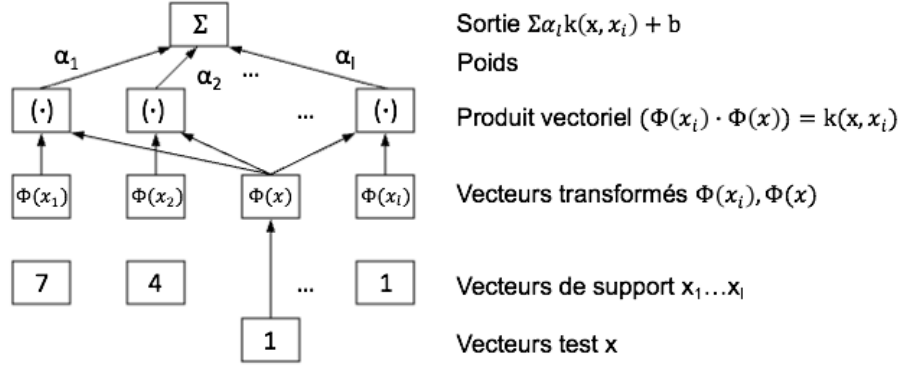


Figure 2.13 Structure de la méthode SVM [7]

$$PDF = f(P, x) \approx \hat{f}(P, x) = \frac{\sum_{i=1}^n \left\{ K \left(\frac{P-P_i}{h_p} \right) \prod_{j=1}^r K \left(\frac{x_j-x_{ji}}{h_j} \right) \right\}}{nh_p h_1 \dots h_r} \quad (2.27)$$

$$\approx \hat{f}(P, x) = \frac{\sum_{i=1}^n \exp - \left\{ \frac{(P-P_i)^2}{2h_p^2} + \sum_{j=1}^r \frac{(x_j-x_{ji})^2}{2h_j^2} \right\}}{(2\pi)^{\frac{r+1}{2}} nh_p h_1 \dots h_r} \quad (2.28)$$

P est la matrice des consommations mesurées chaque heure, x est la matrice des paramètres d'entrée, h_p, h_1, \dots, h_r sont les paramètres de lissage et K est une fonction de kernel. La fonction de kernel gaussienne est également utilisée pour cette méthode.

La consommation espérée \hat{P} est donnée par :

$$\hat{P}(x) = \frac{\int P \hat{f}(P, x) dP}{\int \hat{f}(P, x) dP} \quad (2.29)$$

Pour la fonction de kernel gaussienne, \hat{P} est calculé par :

$$\hat{P}(x) = \frac{\sum_{i=1}^n \left\{ P_i \exp \left(- \sum_{j=1}^r \frac{(x_j-x_{ji})^2}{2h_j^2} \right) \right\}}{\sum_{i=1}^n \left\{ \exp \left(- \sum_{j=1}^r \frac{(x_j-x_{ji})^2}{2h_j^2} \right) \right\}} \quad (2.30)$$

La valeur des paramètres de lissage h doit minimiser l'erreur de prédiction.

$$\hat{h} = \min_h error(h) \quad (2.31)$$

$$error(h) = \frac{1}{n} \sum_{i=1}^n [P_i - \hat{P}_{-i}(x_i)]^2 \quad (2.32)$$

Les valeurs optimales des paramètres de lissage peuvent être calculées en utilisant la méthode du gradient conjugué.

Le résidu au temps t est influencé par le résidu au temps $t - 1$. Un modèle autorégressif d'ordre 1 (modèle AR) est basé sur les résidus.

$$e(t+1) = \phi e(t) = \phi \hat{P}(t) - P(t) \quad (2.33)$$

où $0 < \phi < 1$ est un paramètre estimé à partir des valeurs antérieures de e .

La prédiction de la consommation $\hat{P}(x, e)$ est maintenant calculée en incluant le modèle basé sur les résidus.

$$\hat{P}(x, e) = \hat{P}(x) + e(t)\phi^T \quad (2.34)$$

2.7.3 Régression ARX

La matrice de valeurs de sortie $y(t)$ influencée par la matrice des paramètres d'entrée $x(t)$ est définie avec le modèle ARX à l'équation (2.35) [29].

$$y(t) + a_1 y(t-1) + \dots + a_{n_a} y(t-n_a) = b_1 x(t-1-n_k) + b_{n_b} x(t-n_b-n_k) + e(t). \quad (2.35)$$

Cette équation peut être écrite sous une forme polynomiale.

$$A(q)y(t) = B(q)x(t-n_k) + e(t) \quad (2.36)$$

$$A(q) = 1 + a_1 q^{-1} + \dots + a_{n_a} q^{-n_a} \quad (2.37)$$

$$B(q) = b_1 q^{-1-n_k} + \dots + b_{n_b} q^{-n_b-n_k} \quad (2.38)$$

n_a représente l'ordre du polynôme de sortie $A(q)$ et n_b est l'ordre du polynôme d'entrée $B(q)$. n_k est le délai temporel entre $y(t)$ et $y(t)$. Le bruit blanc est représenté avec la variable $e(t)$. q est l'opérateur de délai, $x(t=1) = q^{-1}x(t)$. Les paramètres $A(q)$ et $B(q)$ sont calculés en

utilisant la méthode des moindres carrés.

2.8 Contribution

Finalement, les programmes de DR sont beaucoup étudiés dans la littérature. Par contre, l'incertitude de la réponse des clients est un sujet très peu étudié. Deux études récentes traitent de cette problématique. L'une d'elles caractérise la réponse des clients ce qui aide les agrégateurs à gérer leurs requêtes. L'autre étudie la gestion des voitures électriques et des climatiseurs, mais avec une méthode en deux étapes. La contribution de cette recherche se situe à deux niveaux. Premièrement, le modèle d'optimisation à contraintes probabilistes est très peu utilisé dans la littérature. L'incertitude de la réponse du client n'a jamais été traitée avec cette méthode. Grâce à celle-ci, la stabilité du réseau peut être assurée avec un certain niveau de confiance contrairement aux modèles en deux étapes utilisés dans la littérature. Deuxièmement, la méthode développée lors de ce projet rassemble plusieurs études. En effet, trois techniques de prévision de la consommation, une méthode de caractérisation des clients ainsi qu'un modèle d'optimisation à contraintes probabilistes sont utilisés afin d'obtenir une approche fiable à la réalité. Notre approche permet à l'agrégateur de distribuer les requêtes de DR en ayant une bonne prévision de la demande et une bonne caractérisation des clients.

CHAPITRE 3 SYNTHÈSE DU TRAVAIL

Le présent chapitre explique les différentes étapes du projet. Elle montre le détail de la méthode développée au cours de cette étude. En premier lieu, les différentes étapes de modélisation du problème complet sont décrites. Ensuite, la prédiction de la consommation d'électricité est décrite et les résultats sont montrés. Finalement, les méthodes pour la détermination des paramètres sont expliquées et quatre études de cas sont analysées.

3.1 Méthode globale

Dans cette section, la méthode globale de l'agrégateur est présentée. Dans un premier temps, on introduit l'indice $t = 1, 2, \dots, 21$ qui représente 21 périodes dans la semaine. La résolution se fait trois fois par jour en heure de pointe. Cette recherche se concentre sur la consommation électrique en hiver dans la province de Québec, Canada. Les profils de consommation sont donc en hiver. Les profils de consommation en été sont différents et ne sont pas considérés dans cette étude. Une première heure de pointe est observée à environ 7h00. Une deuxième heure de pointe est observée à environ 19h00. Lors de ces deux heures de pointe, l'agrégateur tente de réduire la consommation totale des clients. Les requêtes d'utilité et les requêtes de DR seront donc positives. La figure 3.1 montre les deux heures de pointe.

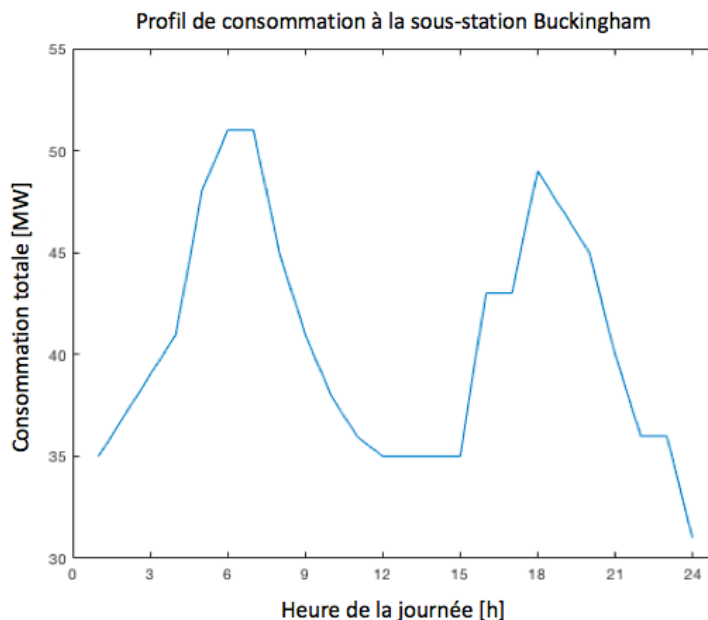


Figure 3.1 Exemple de profil de consommation

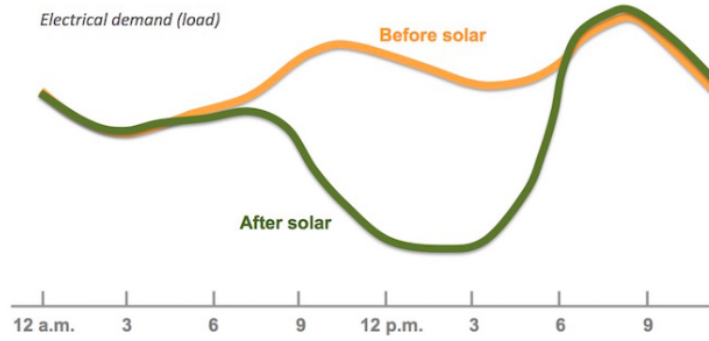


Figure 3.2 Impact de la production solaire sur le profil de consommation [8]

Une action de l'agrégateur est également nécessaire à 12h00. Contrairement aux deux autres heures de pointe, l'agrégateur tentera d'augmenter la consommation globale des clients. Avec l'avènement de la production par énergie solaire, une surproduction peut se produire lorsque l'irradiance du soleil est à son maximum. Ceci se produit à midi lorsque la consommation des clients est à un creux. On observe donc une différence entre la production et la consommation des clients. Pour absorber cette surproduction, l'agrégateur envoie des requêtes de DR négatives aux clients pour augmenter leur consommation. Ceci peut être fait par l'augmentation de la température d'une pièce grâce au thermostat intelligent ou par la charge d'une voiture électrique par exemple. La figure 3.2 montre l'impact de la production solaire sur le profil de charge. La consommation électrique peut diminuer de façon considérable lorsque la production solaire est importante. Ceci peut mener à une surproduction et ainsi mener au gaspillage d'électricité si la consommation n'augmente pas.

Suite aux résultats d'un programme pilote en Espagne [2], la probabilité p_i qu'un client réponde à la requête de DR varie selon plusieurs facteurs. Premièrement, selon la période de la semaine la probabilité peut varier. La probabilité peut également être différente selon la direction de la requête. Selon les résultats du programme pilote, les clients seraient plus enclins à réduire leur consommation qu'à l'augmenter. Ainsi, pour chaque période t une probabilité p_{it}^+ et p_{it}^- est établie. Finalement, les clients peuvent être sensibles à la fréquence des requêtes. On établit donc une probabilité en fonction du nombre de requêtes envoyées au cours de la semaine n . Un sous-ensemble de clients CAT_1 est insensible aux fréquences des requêtes. Leur probabilité est donc constante en fonction de n tel que montrée aux équations 3.1 et 3.2. Un autre sous-ensemble de client CAT_2 quant à lui est sensible aux fréquences des requêtes. Dans cette recherche, on émet l'hypothèse que cette relation est linéaire. Les équations 3.3 et 3.4 montrent cette relation. Chaque client possède un nombre maximal de

requêtes désirées au cours de la semaine n_{max} . Lorsqu'un client atteint son nombre maximal de requêtes pendant la semaine, sa probabilité de réponse tombe à zéro pour le reste de la semaine. Au début de chaque semaine, le paramètre n est réinitialisé. Le coût c des requêtes peut également varier selon les périodes. Le détail de la caractérisation de tous les paramètres et sous-ensembles est présenté dans la sous-section 3.4.

$$p_i^+ = p_{it}^+ \quad \forall i \in CAT_1 \quad (3.1)$$

$$p_i^- = p_{it}^- \quad \forall i \in CAT_1 \quad (3.2)$$

$$p_i^+ = p_{it}^+ - \frac{p_{it}^+}{n_{max}^i} n_i \quad \forall i \in CAT_2 \quad (3.3)$$

$$p_i^- = p_{it}^- - \frac{p_{it}^-}{n_{max}^i} n_i \quad \forall i \in CAT_2 \quad (3.4)$$

L'agrégateur suit les étapes suivantes pour faire la distribution des requêtes de DR.

1. Initialiser le nombre de requêtes passées n , la période t , le coût c et les probabilités p
2. Faire la prévision de la demande totale (L_t) à la période t
3. Évaluer la requête d'utilité avec $U = \beta L_t$ pour une réduction de la charge et $U = -\beta L_t$ pour une augmentation de la charge.
4. Réduire le modèle mathématique selon la valeur de la requête d'utilité
5. Mise à jour des paramètres n , t , c et p
6. Aller à l'étape 2) jusqu'à ce que $t = 21$
7. Aller à l'étape 1)

Avant la première résolution de la semaine, les paramètres n et t sont initialisés. L'agrégateur met $n = 0$ et $t = 1$. Ensuite, la probabilité des clients est calculée avec les équations (3.1) à (3.4). Le coût c est également établi selon la période. La prévision de la demande totale L_t est faite selon la méthode de prévision choisie et la requête d'utilité est évaluée grâce à $U = \beta L_t$ pour une réduction de la consommation et $U = -\beta L_t$ pour une augmentation, avec β qui représente le pourcentage de la consommation à réduire ou à augmenter. Lorsque la requête d'utilité est connue, le problème d'optimisation est résolu selon le signe de la requête d'utilité. Les résultats du problème d'optimisation permettent de faire la mise à jour des paramètres n , t grâce à la variable binaire w_i , qui est égale à 1 si le client i reçoit une requête.

$$n_i = n_i + w_i \quad (3.5)$$

$$t = t + 1 \quad (3.6)$$

Les probabilités p sont alors recalculées avec les nouveaux n et t . Les coûts c sont ajustés selon la nouvelle période. Finalement, après la dernière résolution, lorsque $t = 21$, les paramètres n et t sont réinitialisés et le cycle recommence.

3.2 Le modèle mathématique

Dans la présente section, le développement du modèle d'optimisation complet est présenté. Le modèle stochastique développé à travers ce projet s'appuie sur un modèle de base. Certaines contraintes ont été transformées en contraintes probabilistes pour inclure l'incertitude. Afin de résoudre le modèle à l'aide de solveur, les contraintes probabilistes doivent être à leur tour transformées en contraintes linéaires ou non linéaires. Un cas simplifié du problème a été étudié pour approximer les fonctions de distributions. Finalement, le modèle complet est décrit.

3.2.1 Le problème de base

Le problème mathématique de base est inspiré du problème connu de répartition économique [19].

$$\min_{\Delta P} \quad \sum_{i \in I} c_i \Delta P_i \quad (3.7)$$

$$\text{s.c.} \quad \underline{\Delta P}_i \leq \Delta P_i \leq \overline{\Delta P}_i \quad \forall i \in I \quad (3.8)$$

$$\sum_{i \in I} \Delta P_i = U \quad (3.9)$$

Comme dans le modèle de répartition économique, l'agrégateur vise à minimiser ses coûts. Pour chaque requête envoyée à un client, des coûts y sont rattachés. Représentés dans le modèle par c_i , ces coûts sont exprimés en \$/kW et peuvent être différents pour chaque client. L'ensemble I représente l'ensemble de tous les clients participant aux programmes de DR, avec $|I| = n_c$ où n_c est le nombre de clients. Dans ce modèle, on fait varier ΔP qui représente la quantité de kW que chaque client doit réduire ou augmenter sa charge.

Cette variable est nommée la requête de DR. Pour borner ΔP , chaque client possède une capacité de DR minimale $\underline{\Delta P}_i$ et une capacité de DR maximale $\overline{\Delta P}_i$. Ici, on fait la distinction entre l'augmentation ou la réduction de la charge. Deux modèles sont créés pour prendre en compte les différents paramètres. Les requêtes ΔP_i sont distribuées aux clients dans le but de satisfaire une certaine requête de l'utilité U . Sans aucune incertitude, ce problème se résout de façon triviale. L'agrégateur n'a qu'à distribuer les requêtes aux clients coûtant le moins cher jusqu'à atteindre la requête de l'utilité. Par contre, dus à plusieurs facteurs énoncés en revue de littérature, il existe une certaine probabilité qu'un ou plusieurs clients ne répondent pas à leur requête.

3.2.2 Le problème stochastique simplifié

Pour inclure l'incertitude de la disponibilité des ressources, un modèle stochastique a été développé. Ces modèles mathématiques nécessitent une connaissance des fonctions de distribution des paramètres incertains. Une analyse doit être faite pour approximer la fonction de distribution de la réponse réelle des clients aux requêtes de DR (ΔP^*). Un problème pour $U \geq 0$ et $U \leq 0$ doit être fait séparément, car la fonction objective et la contrainte probabiliste sont différentes. Les problèmes (P1) et (P2) simplifiés sont présentés ci-dessous.

Le problème (P1) lorsque la requête d'utilité est positive ($U \geq 0$) est :

$$\min_{\Delta P} \sum_{i \in I} c_i^+ \Delta P_i \quad (3.10)$$

$$\text{s.c.} \quad \underline{\Delta P}_i \leq \Delta P_i \leq \overline{\Delta P}_i \quad \forall i \in I \quad (3.11)$$

$$Prob \left(\sum_{i \in I} \Delta P_i^* \geq U \right) \geq \alpha \quad (3.12)$$

Le problème (P2) lorsque la requête d'utilité est négative ($U \leq 0$) est :

$$\min_{\Delta P} - \sum_{i \in I} c_i^- \Delta P_i \quad (3.13)$$

$$\text{s.c.} \quad \underline{\Delta P}_i \leq \Delta P_i \leq \overline{\Delta P}_i \quad \forall i \in I \quad (3.14)$$

$$Prob \left(\sum_{i \in I} \Delta P_i^* \leq U \right) \geq \alpha \quad (3.15)$$

La fonction objectif de (P2) doit avoir un signe négatif, car les coûts $c_i^- \geq 0$ et la variable $\Delta P_i \leq 0$, $\forall i \in I$. Dans un premier temps, seul le problème (P1) est étudié pour établir la

fonction de distribution. L'équation 3.12 peut être écrite sous une différente forme :

$$Prob(\sum_{i \in I} \Delta P_i^* \geq U) \geq \alpha \equiv Prob(X \geq k) \geq \alpha \quad (3.16)$$

où

$$k = \left\lceil \frac{U}{\Delta P_i} \right\rceil. \quad (3.17)$$

k représente le nombre minimal de réponses positives nécessaires pour satisfaire la requête d'utilité. p_i représente la probabilité qu'un client i réponde à la requête de DR. n est le nombre de clients participant aux programmes de DR.

Sous certaines conditions, X suit une loi binomiale $X \sim \beta(n, p)$. Les conditions sont que tous les clients sont identiques, c'est-à-dire que $\overline{\Delta P_i} = \overline{\Delta P}$, $\underline{\Delta P_i} = \underline{\Delta P} = 0$ kW, $p_i = p$, $c_i = c$, $\forall i \in I$. Ces hypothèses sont faites pour le modèle simplifié seulement.

Pour un n suffisamment large, X peut être approximée comme une loi normale.

$$X \sim \mathcal{N}(np, np(1-p)) \quad (3.18)$$

Sous ces conditions, le problème (P1) peut être réécrit et la contrainte probabiliste (3.12) devient une contrainte non-linéaire.

$$\min_n \quad nc\overline{\Delta P} \quad (3.19)$$

$$\text{s.c.} \quad k - np \leq Z_{1-\alpha} \sqrt{np(1-p)} \quad (3.20)$$

$$k \leq n \leq |I| \quad (3.21)$$

Le détail de la transformation de la contrainte probabiliste est expliqué ci-dessous :

$$Prob(X \geq k) \geq \alpha \equiv Prob(X \leq k) \leq 1 - \alpha \quad (3.22)$$

$$\equiv Prob\left(Y \leq \frac{k - \mu}{\sqrt{\sigma^2}}\right) \leq 1 - \alpha \quad (3.23)$$

avec $Y \sim \mathcal{N}(0, 1)$, $\mu = np$, $\sigma^2 = np(1-p)$.

La contrainte peut donc s'écrire sous la forme :

$$k - np \leq Z_{1-\alpha} \sqrt{np(1-p)} \quad (3.24)$$

avec $Z_{1-\alpha}$ étant la fonction de répartition inverse de la loi normale standard évaluée en $1 - \alpha$.

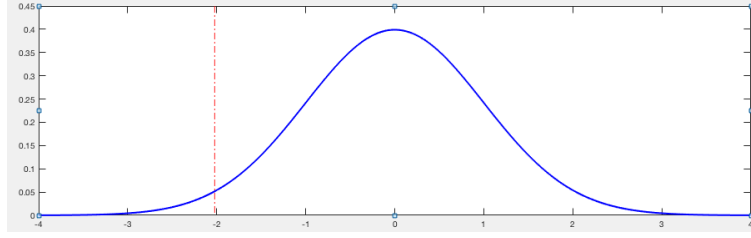


Figure 3.3 Distribution de la loi normale standard

3.2.3 Le problème stochastique complet

Le problème stochastique complet n'impose pas les hypothèses du problème simplifié. Les clients sont hétérogènes et les requêtes d'utilité peuvent être négatives ou positives. La réponse ΔP^{i*} d'un client i est exprimée avec une espérance $E[\Delta P^{i*}] = \Delta P^i p_i$ et une variance $Var[\Delta P^{i*}] = p_i(1 - p_i)\Delta P_i^2$. Avec le théorème central limite, la réponse totale des clients $\sum_{i \in I} \Delta P^{i*}$ peut être exprimée avec une loi normale. Les clients sont considérés comme indépendants.

$$\sum_{i \in I} \Delta P^{i*} \sim \mathcal{N}(\mu, \sigma^2) \quad (3.25)$$

$$\mu = \sum_{i \in I} p_i \Delta P_i \quad (3.26)$$

$$\sigma^2 = \sum_{i \in I} p_i(1 - p_i)\Delta P_i^2 \quad (3.27)$$

Les probabilités 3.12 et 3.15 peuvent être transformées en contraintes non-linéaires.

$$-U \geq Z_\alpha \sqrt{\sigma^2} - \mu \quad \text{si } U \geq 0 \quad (3.28)$$

$$U \geq Z_\alpha \sqrt{\sigma^2} + \mu \quad \text{si } U \leq 0 \quad (3.29)$$

avec Z_α étant la fonction de répartition inverse de la loi normale standard évaluée en α .

La transformation pour une requête d'utilité positive ($U \geq 0$) est montrée.

$$Prob(\sum_{i \in I} \Delta P_i^* \geq U) \geq \alpha \equiv Prob(-\sum_{i \in I} \Delta P_i^* \leq -U) \geq \alpha \quad (3.30)$$

$$\equiv Prob(Y \leq \frac{-U + \mu}{\sqrt{\sigma^2}}) \geq \alpha \quad (3.31)$$

$$\equiv -U \geq Z_\alpha \sqrt{\sigma^2} - \mu \quad (3.32)$$

Dans un deuxième lieu, la transformation pour une requête d'utilité négative ($U \leq 0$) est montrée.

$$Prob(\sum_{i \in I} \Delta P_i^* \leq U) \geq \alpha \equiv Prob(Y \leq \frac{U - \mu}{\sqrt{\sigma^2}}) \geq \alpha \quad (3.33)$$

$$\equiv U \geq Z_\alpha \sqrt{\sigma^2} + \mu \quad (3.34)$$

avec $Y \sim \mathcal{N}(0, 1)$, $\mu = \sum_{i \in I} p_i \Delta P_i$, $\sigma^2 = \sum_{i \in I} p_i(1 - p_i) \Delta P_i^2$.

Une variable binaire w est introduite au modèle pour permettre la capacité minimale ΔP d'être différente de zéro. Ainsi, lorsque le client i reçoit une requête, la variable w_i prend la valeur 1 et ΔP_i varie de $\underline{\Delta P_i}$ à $\overline{\Delta P_i}$. Autrement, w_i reste égal à 0, ce qui force ΔP_i d'être aussi nul.

Si $U \geq 0$, le problème (P1) est résolu.

$$\min_{\Delta P, \mu, \sigma, w} \sum_{i \in I} c_{it}^+ \Delta P_i \quad (3.35)$$

$$\mu = \sum_{i \in I} p_i^+ \Delta P_i \quad (3.36)$$

$$\sigma^2 = \sum_{i \in I} p_i^+(1 - p_i^+) \Delta P_i^2 \quad (3.37)$$

$$-U \geq Z_\alpha \sqrt{\sigma^2} - \mu \quad (3.38)$$

$$\underline{\Delta P_i}^+ w_i \leq \Delta P_i \leq \overline{\Delta P_i}^+ w_i \quad \forall i \in I \quad (3.39)$$

$$n_i + w_i \leq n_{max}^i \quad \forall i \in I \quad (3.40)$$

Si $U \leq 0$, le problème (P2) est résolu.

$$\min_{\Delta P, \mu, \sigma, w} - \sum_{i \in I} c_{it}^- \Delta P_i \quad (3.41)$$

$$\mu = \sum_{i \in I} p_i^- \Delta P_i \quad (3.42)$$

$$\sigma^2 = \sum_{i \in I} p_i^- (1 - p_i^-) \Delta P_i^2 \quad (3.43)$$

$$U \geq Z_\alpha \sqrt{\sigma^2} + \mu \quad (3.44)$$

$$\underline{\Delta P}_i^- w_i \leq \Delta P_i \leq \overline{\Delta P}_i^- w_i \quad \forall i \in I \quad (3.45)$$

$$n_i + w_i \leq n_{max}^i \quad \forall i \in I \quad (3.46)$$

Dans les deux modèles, une contrainte est ajoutée pour limiter le nombre de requêtes envoyé au même client durant la semaine. Ce nombre doit être inférieur ou égal au nombre maximal permis n_{max} .

3.3 Choix de la méthode de prévision

Ce projet vise également à faire la comparaison entre différentes techniques de prévision de la consommation pour calculer la requête d'utilité. Trois méthodes ont été expliquées dans la revue de littérature et seront comparées dans cette section. Premièrement, les caractéristiques des trois techniques dans le contexte de la prévision de la consommation en temps hivernal sont décrites. Ensuite, les outils de comparaison seront expliqués et les résultats présentés.

3.3.1 Présentation des techniques dans un contexte de consommation en temps hivernal

Les méthodes de prédiction de la consommation électrique diffèrent quelque peu d'une saison à l'autre. En effet, les facteurs influençant la consommation électrique ne sont pas les mêmes en été qu'en hiver. Bien que la température influence la consommation, cette relation n'est pas linéaire [30].

Quand les températures sont faibles, la consommation est due au chauffage. La température augmente jusqu'à un point où le chauffage n'est plus nécessaire. Puis finalement, la température augmente et la consommation est due à la climatisation. La consommation atteint un plateau lorsque la climatisation atteint son maximum. De plus, en hiver un facteur non négligeable est la vitesse du vent. Du chauffage supplémentaire est nécessaire lorsque la vitesse du vent est élevée. En été, l'humidité est un facteur influençant la consommation. Plus

l'humidité est élevée, plus la consommation due à la climatisation est élevée. Dans le cadre de cette recherche, on présente les méthodes de prédiction développées dans le contexte de l'hiver québécois. Le détail de chaque méthode est présenté.

Les données utilisées

Les méthodes de prédiction ont été conçues avec les données réelles recueillies par Hydro-Québec à neuf sous-stations à travers le Québec. La consommation (en MW) a été mesurée chaque heure pendant les mois de décembre, janvier et février 2006. Les neuf sous-stations sont issues du secteur résidentiel et commercial. Les sous-stations sont 1-Buckingham, 2-Cheneville, 3-Doc. Grignon, 4-Gamelin, 5-Gatineau, 6-Glenwood, 7-Saint-Donat, 8-Saint-Lin et 9-Sainte-Émilie. Les données météo ont été mesurées à la station météorologique la plus proche de chaque station. La température extérieure et la vitesse du vent ont été recueillies chaque heure. Chaque modèle a été créé grâce à l'ensemble de données dit d'entraînement. Les données du mois de décembre, de janvier et des trois premières semaines de février sont comprises dans l'ensemble d'entraînement. Finalement, les modèles ont été testés sur un ensemble de tests. Les données de la dernière semaine de février ont été sélectionnées dans l'ensemble de tests.

La méthode SVM

Tel qu'expliqué en revue de littérature, la méthode SVM se base sur des prédicteurs pour faire la prévision de la consommation. Les prédicteurs utilisés sont l'heure de la semaine $t = 1, 2, \dots, 168$, la consommation des heures précédentes X_{t-i} , $i = 1, 2, \dots, 5$, la température extérieure, la moyenne de la température extérieure des cinq heures précédentes et la vitesse du vent.

Également, afin de créer le modèle SVM le paramètre de pénalité C , le rayon ϵ et le paramètre de la fonction de kernel gaussienne λ doivent être déterminés. Ces paramètres doivent être choisis afin de minimiser l'erreur de prédiction. Il n'existe cependant pas de problème d'optimisation pour choisir ses paramètres. Ils doivent être déterminés empiriquement et un mauvais choix de paramètres peut avoir des conséquences sur la précision de la prédiction [6].

Parmi ces impacts, un C trop petit peut entraîner un surapprentissage et créer une trop grande erreur sur la prédiction. Par contre, un C trop grand peut mener à une perte de sa signification. Le modèle retourne donc à minimiser le risque empirique seulement. Ici, on peut se retrouver en situation de sous-apprentissage. Un ϵ trop grand limite la quantité de

vecteurs de support et rend la courbe de prédiction plus plate. Finalement, un λ trop grand peut également mener à une augmentation de la prédiction.

Les meilleurs paramètres trouvés pour le modèle sont $C = 300$, $\epsilon = 0,1$ et $\lambda = 5$. Ces paramètres sont les mêmes pour toutes les sous-stations.

La méthode non-paramétrique

La méthode non paramétrique quant à elle n'utilise que trois prédicteurs, soit l'heure du jour $t = 1, 2, \dots, 24$, le jour de la semaine $j = 1, 2, \dots, 7$ et la température ajustée avec le facteur éolien. La température ajustée avec le facteur éolien T_{WC} est calculée à l'équation 3.47 selon Environnement Canada [31].

$$T_{WC} = 13.12 + 0.6215T_a - 11.37v^{0.16} + 0.3965T_av^{0.16}, \quad (3.47)$$

avec T_a la température extérieure ($^{\circ}\text{C}$) et v la vitesse du vent à 10 mètres (km/h)

La méthode ARX

La méthode ARX est la plus simple. Elle ne prend pas en compte les différentes saisonnalités dans le modèle. Comme présenté en revue de littérature, elle considère seulement les consommations des heures précédentes. Dans ce cas-ci, les sept heures précédentes ont été considérées dans le modèle.

3.3.2 Outils de comparaison utilisés

Plusieurs indicateurs sont utilisés dans la littérature pour comparer différents modèles. Parmi ceux-ci, on compte le pourcentage d'erreur absolue moyenne (PEAM), et la racine de l'erreur quadratique moyenne (REQM) [32]. Selon une série chronologique $S = \{s_1, s_2, \dots, s_n\}$ définie comme étant la consommation réelle et une série chronologique $\tilde{S} = \{\tilde{s}_1, \tilde{s}_2, \dots, \tilde{s}_n\}$ définie comme étant la prédiction de la consommation, le PEAM se calcule avec l'équation 3.48.

$$PEAM = \frac{1}{n} \sum_{i=1}^n \left| \frac{s_i - \tilde{s}_i}{s_i} \right| \quad (3.48)$$

Le REQM quant à lui se calcule avec l'équation 3.49.

$$REQM = \sqrt{\frac{1}{n} \sum_{i=1}^n (s_i - \tilde{s}_i)^2}. \quad (3.49)$$

Le PEAM est un bon indicateur de la performance d'une méthode de prévision. Cependant, cet indicateur performe moins bien avec des valeurs avoisinant le zéro. Dans ce cas, le PEAM tend vers l'infini et dans le cas où une valeur s_i est nulle, le PEAM est indéfini. Dans le cadre de cette recherche, la prédiction de la charge se fait au niveau des sous-stations. Les consommations totales des sous-stations sont de l'ordre du mégawatt. Il n'y a donc aucun risque qu'une valeur s'approche de zéro. Le PEAM est donc un indicateur fiable pour comparer les méthodes de prévision. Le REQMN quant à lui est dépendant de l'ordre de grandeur des valeurs s_i . Les sous-stations ont des valeurs différentes de consommation, une sous-station peut atteindre 170 MW tandis qu'une autre atteint son maximum à 30 MW. Pour pouvoir comparer efficacement les méthodes entre les différentes sous-stations, la racine de l'erreur quadratique moyenne normalisée (REQMN) est utilisée.

$$REQMN = \sqrt{\frac{\sum_{i=1}^n (s_i - \tilde{s}_i)^2}{\sum_{i=1}^n s_i^2}} \quad (3.50)$$

Le REQMN est indépendant de l'ordre des valeurs et est robuste avec les valeurs près de zéro. Comme on divise par la somme des s_i^2 , il faudrait que tous les s_i approchent zéro pour que le REQMN tende vers l'infini. Dans cette étude, le PEAM et le REQMN sont deux indicateurs pertinents pour comparer les trois méthodes de prévision. Ces indicateurs ont été calculés pour la dernière semaine de février.

En plus des indicateurs, une analyse statistique est effectuée pour comparer les modèles. La figure 3.4 montre la distribution des fréquences de la consommation réelle (a) et de la consommation prédite par la méthode SVM (b), par la méthode non paramétrique (c) et par la méthode ARX (d). Les quatre histogrammes sont montrés pour la sous-station 1 à la dernière semaine de février. Ils montrent que les distributions des consommations peuvent être estimées avec une loi normale. Avec cette conclusion, deux autres tests sont réalisés afin de comparer la distribution normale $\mathcal{N}(\mu_a, \sigma_a^2)$ de la consommation réelle et des distributions normales $\mathcal{N}(\mu_j, \sigma_j^2)$, $j \in b, c, d$ des consommations prédites à l'aide des trois méthodes.

Le premier test est le test de Student qui vise à vérifier l'égalité de deux moyennes issues de deux différents ensembles de données. L'hypothèse à vérifier est :

$$H_0 : \mu_a = \mu_j \quad \forall j \in \{b, c, d\} \quad (3.51)$$

Cette hypothèse est considérée comme vraie et le test calcule une valeur p sous cette hypothèse. Le test vérifie si la valeur p calculée est en dessous d'un certain seuil α_t . Dans le cas

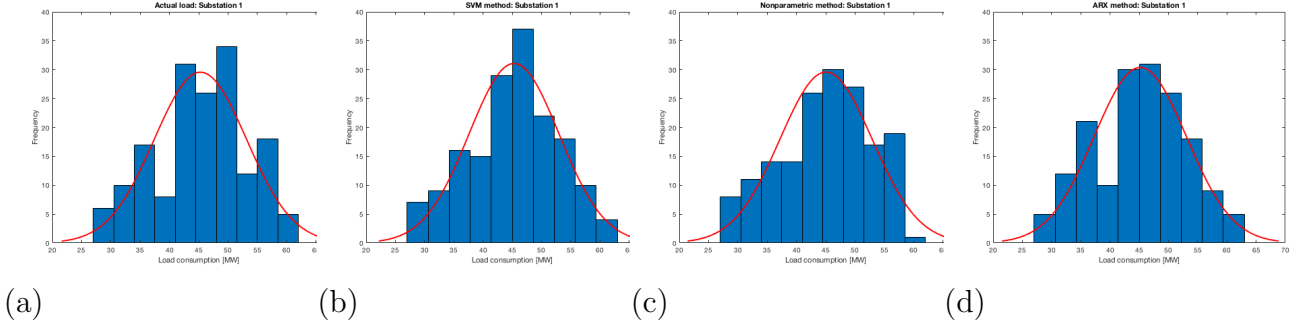


Figure 3.4 . Distribution des fréquences à la dernière semaine de février à la sous-station 1 de (a) la consommation réelle et de la consommation prédite avec (b) la méthode SVM (c) la méthode non paramétrique (d) la méthode ARX.

où p est effectivement en dessous de ce seuil, l'hypothèse est rejetée et l'hypothèse inverse est jugée vraie. L'hypothèse inverse est :

$$H_1 : \mu_a \neq \mu_j \quad \forall j \in \{b, c, d\} \quad (3.52)$$

Ici, les variances des différents ensembles de données ne sont pas considérées comme égales. Les deux ensembles de données sont cependant jugés indépendants. Sous ces conditions, le test est aussi appelé le test de Welch. La valeur statistique T de deux ensembles de données indépendants avec des variances différentes est donnée par l'équation 3.53.

$$T = \frac{\overline{X}_a - \overline{X}_j}{s_{\Delta}^-} \quad \forall j \in \{b, c, d\} \quad (3.53)$$

$$s_{\Delta}^- = \sqrt{\frac{s_a^2}{n_a} + \frac{s_j^2}{n_j}} \quad \forall j \in \{b, c, d\} \quad (3.54)$$

Le test statistique peut être approximé par une distribution de Student avec un degré de liberté ($d.l.$) calculé par l'équation de Welch-Satterthwaite

$$d.l. = \frac{\left(\frac{s_a^2}{n_a} + \frac{s_j^2}{n_j}\right)^2}{\frac{(s_a^2/n_a)^2}{n_a-1} + \frac{(s_j^2/n_j)^2}{n_j-1}} \quad \forall j \in \{b, c, d\} \quad (3.55)$$

\overline{X}_a est la moyenne observée de la consommation réelle et \overline{X}_j est la moyenne observée de la consommation prédite de chaque méthode. n_a et n_j sont le nombre de données observées qui dans ce cas sont égaux. $n_a = n_j = 168$, ce qui représente le nombre d'heures dans une semaine, la consommation étant mesurée chaque heure. s_a^2 et s_j^2 sont les estimateurs sans biais de la variance de chaque ensemble de données. Avec un seuil $\alpha_t = 0,05$, l'hypothèse de l'égalité des moyennes n'est pas rejetée pour toutes les méthodes.

Un second test a été effectué pour vérifier l'hypothèse de l'égalité des variances. Le test de Fisher tend à vérifier l'hypothèse suivante :

$$H_0 : \sigma_a^2 = \sigma_j^2 \quad \forall j \in \{b, c, d\}. \quad (3.56)$$

Comme pour le test de Student, l'hypothèse est jugée vraie et le test calcule une valeur p sous cette hypothèse. Également, si la valeur p est sous un seuil α_f , l'hypothèse est rejetée et l'hypothèse inverse est acceptée.

$$H_1 : \sigma_a^2 \neq \sigma_j^2 \quad \forall j \in \{b, c, d\} \quad (3.57)$$

La statistique F est calculée avec l'équation 3.58.

$$F = \frac{s_a^2}{s_j^2} \quad \forall j \in \{b, c, d\} \quad (3.58)$$

Le test statistique peut être approximé par la distribution de Fisher avec un degré de liberté au numérateur égal à $n_a - 1$ et un degré de liberté au dénumérateur égal à $n_j - 1$. Ce ratio peut être analysé comme une performance des méthodes. Si le ratio dévie grandement de 1, cela signifie que l'hypothèse d'égalité des variances tend à être rejetée. Plus ce ratio s'approche de 1, plus cette hypothèse tend à être acceptée. Sous un seuil $\alpha_f = 0,05$, l'hypothèse H_0 n'est pas rejetée pour toutes les sous-stations. Les résultats des deux tests statistiques sont présentée à l'annexe A.

3.3.3 Résultats

Le tableau 3.1 montre le PEAM et le REQM de chaque méthode de prévision et de chaque sous-station. Les méthodes de prévision ont été créées à partir des données des mois de décembre et de janvier ainsi que des trois premières semaines de février. La prévision a été faite à chaque heure pour la dernière semaine de février. Les plus petites valeurs sont soulignées en gras.

Tableau 3.1 Comparaison des méthodes de prédiction pour chaque sous-station

	Méthode	S1	S2	S3	S4	S5	S6	S7	S8	S9
PEAM (%)	SVM	3,84	3,12	3,28	2,37	1,95	3,28	3,05	3,40	3,03
	NP	1,37	1,51	1,328	1,12	0,73	1,32	1,43	2,30	1,16
	ARX	3,92	3,05	3,29	2,34	2,17	3,69	2,93	3,37	2,70
REQM (%)	SVM	4,77	3,81	4,16	3,01	2,40	3,93	3,91	4,25	4,02
	NP	2,04	2,17	2,02	1,60	1,23	2,10	2,04	3,46	1,68
	ARX	4,94	3,80	4,09	3,21	2,87	4,72	3,64	4,42	3,54

Selon ces résultats, la méthode non-paramétrique est utilisée pour calculer la requête d'utilité de chaque sous-station avec les équations 3.59 et 3.60.

$$U = \beta L_t \quad \text{Pour une diminution de la charge} \quad (3.59)$$

$$U = -\beta L_t \quad \text{Pour une augmentation de la charge} \quad (3.60)$$

Le tableau 3.2 montre les requêtes d'utilité de chaque sous-station calculées avec la méthode non paramétrique. Les requêtes d'utilité sont calculées 21 fois au courant de la semaine, et le tableau montre le maximum, le minimum et la valeur absolue moyenne (VAM) des requêtes calculées. Les requêtes sont calculées lors de la dernière semaine de février 2006.

Tableau 3.2 Requête d'utilité calculée par la méthode non paramétrique

β	U (kW)	S1	S2	S3	S4	S5	S6	S7	S8	S9
0.05	Max.	3085	1520	3633	8457	5487	4208	1967	1520	2123
	Min.	-2800	-1301	-3533	-7739	-5167	-4147	-1906	-1479	-2046
	VAM	2338	1159	2948	6754	4721	3460	1576	1293	1801
0.10	Max.	6170	3039	7266	16914	10973	8416	3935	3039	4246
	Min.	-5600	-2601	-7065	-15477	-10335	-8294	-3811	-2957	-4092
	VAM	4675	2318	5896	13509	9443	6919	3152	2586	3602

Le tableau 3.2 montre que la sous-station 1 (Buckingham) peut être considérée comme une

sous-station moyenne en termes de kW. La sous-station 2 (Cheneville) est la plus petite sous-station et la sous-station 4 (Gamelin) est la plus grande sous-station. Ce sont donc sur ces trois sous-stations que le modèle a été testé sous différents paramètres.

3.4 Détermination des paramètres

Suite à la détermination du modèle de prévision et du calcul des requêtes d'utilités, les paramètres du modèle d'optimisation doivent être approximés. Afin de rendre le modèle fidèle à la réalité, des sous-ensembles de clients doivent être créés. Ces sous-ensembles ont différentes caractéristiques et sont décrits dans la présente section. Pour diminuer le temps de résolution, un processus d'agrégation des charges doit être fait afin de diminuer le nombre de variables du modèle. Le processus est expliqué dans cette section.

3.4.1 Sous-ensembles de clients

Cette section présente la façon dont les différents sous-ensembles de clients ont été créés ainsi que leurs caractéristiques respectives.

La capacité de chaque client doit aussi être déterminée. Pour permettre une meilleure caractérisation de la capacité des clients, trois autres sous-ensembles BH , SH et COM de client sont créés. Les équations (3.61) et (3.62) montrent leurs caractéristiques, avec I l'ensemble des clients et n_c le nombre de clients.

$$|BH| + |SH| + |COM| = n_c \quad (3.61)$$

$$BH \cup SH \cup COM = I \quad (3.62)$$

Le sous-ensemble BH représente les clients du secteur résidentiel qui possèdent une maison dite de «base». Les maisons de base ne possèdent aucun appareil intelligent pour faire la gestion de l'énergie consommée ni de voiture électrique. La diminution, ou l'augmentation de la charge se fait par l'entremise du chauffe-eau ou du thermostat. Le sous-ensemble SH représente les clients du secteur résidentiel qui possède une maison dite «intelligente». Celle-ci possède des appareils intelligents de gestion d'énergie et/ou une voiture électrique. La diminution, ou l'augmentation peuvent se faire par la charge ou la décharge de la batterie de la voiture en plus d'avoir la gestion du chauffe-eau et du thermostat. Le déplacement de la charge peut se faire à l'aide d'appareil intelligent comme le lave-vaisselle, la laveuse ou la sècheuse. Dans cette étude, la reprise de la charge n'est pas prise en considération. En effet, lorsque

qu'un chauffe-eau est interrompu et qu'il reprend du service, une charge supplémentaire est nécessaire pour le rallumer. Finalement, le sous-ensemble *COM* représente les clients du secteur commercial sont traités différemment des sous-ensembles issus du secteur résidentiel.

La capacité maximale des clients commerciaux est déterminée en prenant un pourcentage η de la consommation observée en heure de pointe L_c . On considère que les clients commerciaux peuvent augmenter ou diminuer leur consommation de ηL_c kW. Le logiciel eShapes permet de générer des courbes de consommation dans le secteur commercial sur le territoire des États-Unis en 2001. La Nouvelle-Angleterre a été choisie pour faire les simulations, car les conditions météorologiques de cette région ressemblent à ceux du Québec. Les courbes de consommation sont générées pour le mois de janvier en W/pi² pour neuf types d'immeubles soit : un bloc de logement, une université ou un établissement d'étude supérieure, une école, un restaurant, un hôtel, des bureaux de petite, moyenne et grande taille et un magasin. Le tableau 3.3 montre les superficies estimées pour chaque type d'immeuble. Ces superficies sont variées de $\pm 20\%$ pour générer plusieurs courbes de consommation différentes. Le nombre d'immeubles de chaque type a été estimé égal pour cette recherche pour des fins de simplification. Un agrégateur doit faire varier le nombre d'immeubles de chaque type pour correspondre plus fidèlement à la réalité.

Tableau 3.3 Superficie estimée pour chaque type d'immeuble en kpi²

Bloc de logement	75	Université	240	École	60
Restaurant	3	Hôtel	36	Petit bureau	1
Bureau moyen	100	Grand bureau	150	Magasin	10

Les profils de la figure 3.5 montrent la consommation simulée de la première semaine de février 2006. Une certaine tendance peut être observée de ces profils. Premièrement, on remarque que les consommations diffèrent selon les jours de la semaine. Pour l'école, la consommation du samedi et du dimanche est très faible comparée à la consommation en semaine. Le 1^{er} février 2001 étant un jeudi, on remarque les deux premières pointes qui correspondent aux journées de jeudi et vendredi. Pour le restaurant, la différence entre les jours de la semaine est moins marquante. On note toutefois une certaine diminution de la consommation pour les jours de lundi à mercredi.

Dans cette recherche, le pourcentage $\eta = 0,05$ a été utilisé. Les clients du secteur commercial peuvent être très différents, passant d'un petit café à une grande université. Les consommations et les capacités maximales des clients sont donc également très différentes. Les clients commerciaux d'une sous-station sont donc séparés en h sous-ensembles. Le nombre de sous-ensembles peut varier. Ici, cinq sous-ensembles ont été utilisés pour la modélisation.

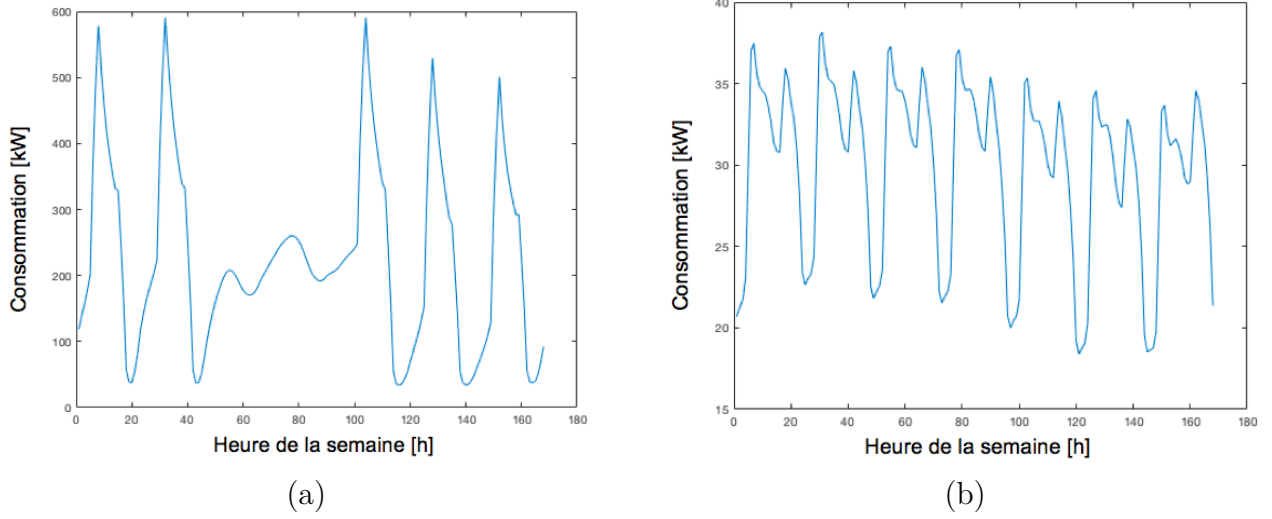


Figure 3.5 Profil de charge hebdomadaire de (a) une école et de (b) un restaurant

$$|COM1| + |COM2| + |COM3| + |COM4| + |COM5| = |COM| \quad (3.63)$$

$$COM1 \cup COM2 \cup COM3 \cup COM4 \cup COM5 = COM \quad (3.64)$$

Les clients commerciaux sont catégorisés en minimisant la distance des capacités d'une même catégorie. La distance euclidienne a été utilisée. Finalement, la capacité maximale d'une catégorie est déterminée en calculant la moyenne des capacités des clients contenus dans cette catégorie.

Les proportions des clients ont été distribuées ainsi : 75 % des clients totaux sont résidentiels et 25 % des clients sont commerciaux. Ensuite, on émet l'hypothèse que 50 % des clients résidentiels possèdent une maison de base et 50 % des clients résidentiels possèdent une maison intelligente. L'approche a été testée sur un ensemble de 30 000 clients. Le tableau 3.4 montre les capacités des cinq sous-ensembles commerciaux et des deux sous-ensembles résidentiels. Ces sept sous-ensembles sont appelés les sous-ensembles de secteur.

On émet deux hypothèses pour caractériser la capacité des clients. Premièrement, la capacité maximale est la même pour une augmentation de la consommation et pour une diminution de la consommation, c'est-à-dire que $\underline{\Delta P}_i^- = -\overline{\Delta P}^+, \forall i \in I$. Deuxièmement, on estime que $\underline{\Delta P}_i^+ = 1 \text{ kW}$ et $\overline{\Delta P}_i^- = -1 \text{ kW}, \forall i \in I$.

Ensuite, le paramètre de probabilités initiales doit également être approximé. Lors du projet pilote en Espagne, les chercheurs ont montré une méthode pour caractériser les clients des

Tableau 3.4 Capacité minimale et maximale de chaque sous-ensemble calculée pour 30 000 clients

Sous-ensemble	$\overline{\Delta P}^+$ (kW)	Cardinalité
BH	2	11250
SH	10	11250
COM1	3	2250
COM2	107	2100
COM3	36	530
COM4	152	1667
COM5	70	953

programmes de DR. Ils en sont venus à trois catégories de clients, soit les clients ayant une réponse «faible», les clients ayant une réponse «modérée» et les clients ayant une réponse «élevée». Dans cette recherche, ces trois catégories de client ont été utilisées pour caractériser la probabilité de réponse de client. Les sous-ensembles *LOW*, *MOD* et *HIGH* sont donc créés en respectant les équations 3.65 et 3.66. Ces sous-ensembles sont appelés les sous-ensembles de probabilité et comprennent des clients de chaque sous-ensemble de secteur. On émet l'hypothèse que chaque sous-ensemble de probabilité possède chacun un tiers du nombre total de clients.

$$|LOW| + |MOD| + |HIGH| = n_c \quad (3.65)$$

$$LOW \cup MOD \cup HIGH = I \quad (3.66)$$

Les probabilités peuvent être différentes d'une période à l'autre pour un même client. C'est pourquoi la loi uniforme est utilisée pour chaque période t . Ainsi, avant chaque résolution du problème, les probabilités p_i^+ et p_i^- sont calculés à l'aide des équations 3.1 à 3.4 en utilisant les paramètres p_{it}^+ et p_{it}^- avec t connu. L'utilisation de la loi uniforme aide également le solveur à résoudre le problème. Ayant un très grand nombre de petites charges similaires, l'algorithme de résolution peut avoir de la difficulté à converger vers une solution optimale. En rendant les probabilités différentes pour chaque client, l'algorithme converge plus rapidement. Chaque sous-ensemble de probabilité a un intervalle dans lequel la probabilité de chaque client peut s'inscrire. Le détail est présenté dans les équations (3.67) à (3.72).

$$p_{it}^+ \sim \mathcal{U}(0, 4; 0, 6) \quad \forall i \in LOW, \forall t \in T \quad (3.67)$$

$$p_{it}^- \sim \mathcal{U}(0, 4; 0, 6) \quad \forall i \in LOW, \forall t \in T \quad (3.68)$$

$$p_{it}^+ \sim \mathcal{U}(0, 6; 0, 8) \quad \forall i \in MOD, \forall t \in T \quad (3.69)$$

$$p_{it}^- \sim \mathcal{U}(0, 6; 0, 8) \quad \forall i \in MOD, \forall t \in T \quad (3.70)$$

$$p_{it}^+ \sim \mathcal{U}(0, 8; 0, 99) \quad \forall i \in HIGH, \forall t \in T \quad (3.71)$$

$$p_{it}^- \sim \mathcal{U}(0, 8; 0, 99) \quad \forall i \in HIGH, \forall t \in T \quad (3.72)$$

Le coût de chaque requête est déterminé pour chaque sous-ensemble de probabilité. Un client répondant avec une grande probabilité peut espérer obtenir un plus grand incitatif qu'un client répondant avec une faible probabilité. Cette relation doit être exprimée dans la détermination des coûts. Les équations (3.73) à (3.75) montre les coûts pour chaque catégorie de sous-ensembles.

$$c_{it}^+ = c_{it}^- = 1 \quad \forall i \in LOW, \forall t \in T \quad (3.73)$$

$$c_{it}^+ = c_{it}^- = 2 \quad \forall i \in MOD, \forall t \in T \quad (3.74)$$

$$c_{it}^+ = c_{it}^- = 3 \quad \forall i \in HIGH, \forall t \in T \quad (3.75)$$

Finalement, les clients sont divisés en deux sous-ensembles CAT_1 et CAT_2 nommés les sous-ensembles de catégories. Ceux-ci sert pour calculer les probabilités aux équations (3.1) à (3.4). Les clients du sous-ensemble CAT_1 ne sont pas influencés par la fréquence de la requête tandis que les clients du sous-ensemble CAT_2 sont linéairement dépendants du nombre de requêtes reçues. Les caractéristiques des sous-ensembles de catégorie sont exprimées ci-dessous. On émet l'hypothèse que chaque sous-ensemble de catégorie possède chacun la moitié du nombre total de client.

$$|CAT_1| + |CAT_2| = n_c \quad (3.76)$$

$$CAT_1 \cup CAT_2 = I \quad (3.77)$$

Le nombre maximal de requêtes permis n_{max} est exprimé en fonction des catégories de clients. On émet l'hypothèse que si un client n'est pas influencé par la fréquence des requêtes, il ne

possède pas de nombre maximal de requêtes. Dans ce cas-ci, n_{max} est égal au nombre de périodes. Pour les clients de catégories 2, on émet l'hypothèse qu'ils acceptent une requête par jour, et donc $n_{max} = 7$.

$$n_{max}^i = 21 \quad \forall i \in CAT_1, \forall t \in T \quad (3.78)$$

$$n_{max}^i = 7 \quad \forall i \in CAT_2, \forall t \in T \quad (3.79)$$

Les paramètres α et β sont déterminés par l'agrégateur. Plusieurs valeurs de α et β ont été testées aux sous-stations Buckingham, Cheneville et Gamelin pour voir l'impact sur la valeur optimale. Les résultats sont présentés à l'annexe B. On peut remarquer qu'une augmentation de la valeur de α augmente les coûts de l'agrégateur, car plus de requêtes de DR doivent être distribuées. Une plus petite valeur de α offre cependant moins de stabilité au réseau.

3.4.2 Regroupement des clients

Le modèle a été testé avec un ensemble de 30 000 clients avec les paramètres décrits plus haut et les requêtes d'utilités approximées par la méthode non-paramétrique. Le temps de résolution dépasse grandement le temps alloué. Par exemple, le solveur ne converge pas en 8 heures à la sous-station Cheneville. La résolution du problème se faisant dans l'heure précédant l'heure de pointe, le temps de résolution ne devrait pas excéder 30 min. Une diminution du nombre de charges doit être réalisée pour limiter le nombre de variables du problème. Pour ce faire, plusieurs clients de mêmes sous-ensembles de secteur, de probabilité et de catégorie sont regroupés ensemble pour former une seule charge. Les regroupements du secteur résidentiel sont nommés *AR* et les regroupements du secteur commercial sont nommées *AC*. Ayant un plus grand nombre et une plus grande homogénéité de clients résidentiels, les clients commerciaux sont regroupés différemment des clients résidentiels. En introduisant le paramètre a comme le degré de regroupement du secteur résidentiel, a clients résidentiels ayant les mêmes caractéristiques sont regroupées en une charge *AR*. De la même façon b est le degré de regroupement du secteur commercial. b clients commerciaux ayant les mêmes caractéristiques sont regroupés en une seule charge *AC*. Un exemple de regroupement est montré à la figure 3.6. Elle montre le regroupement des clients résidentiels ayant une maison de base, une faible probabilité et insensibles aux fréquences des requêtes.

Suites aux regroupements des clients, l'agrégateur peut maintenant distribuer les requêtes parmi les *AR* et les *AC*. Le nombre de charges passe donc de n_c clients à V regroupements avec $V < n_c$, ce qui réduit considérablement le temps de résolution. Les temps de résolution

sont présentés à l'annexe B pour plusieurs degrés de regroupement a et b et plusieurs sous-stations.

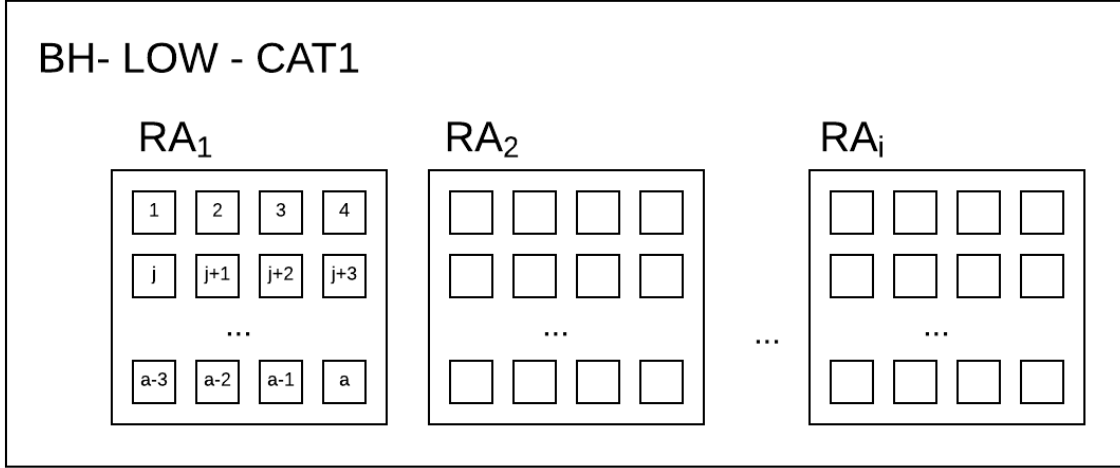


Figure 3.6 Exemple de regroupement pour les clients $i \in BH \cup LOW \cup CAT1$

Afin de respecter les caractéristiques du modèle sans regroupements, plusieurs hypothèses doivent être faites. Premièrement, lorsqu'une requête est envoyée à un regroupement, cette requête est ensuite distribuée équitablement entre les clients du regroupement comme montrée à la figure 3.7. Pour ce faire, la capacité d'un regroupement résidentiel doit être a fois plus grande que la capacité de ses clients. Également pour le secteur commercial, la capacité d'un regroupement commercial est b fois plus grande que la capacité de ses clients.

Finalement, le regroupement de charges nécessite une analyse probabiliste pour respecter les caractéristiques du modèle sans regroupement. L'analyse pour un client résidentiel est faite. Le même développement s'applique pour les clients commerciaux.

Un client résidentiel j faisant partie d'un regroupement i reçoit comme requête $\frac{\Delta P_i}{a}$. Son espérance mathématique et sa variance sont donc :

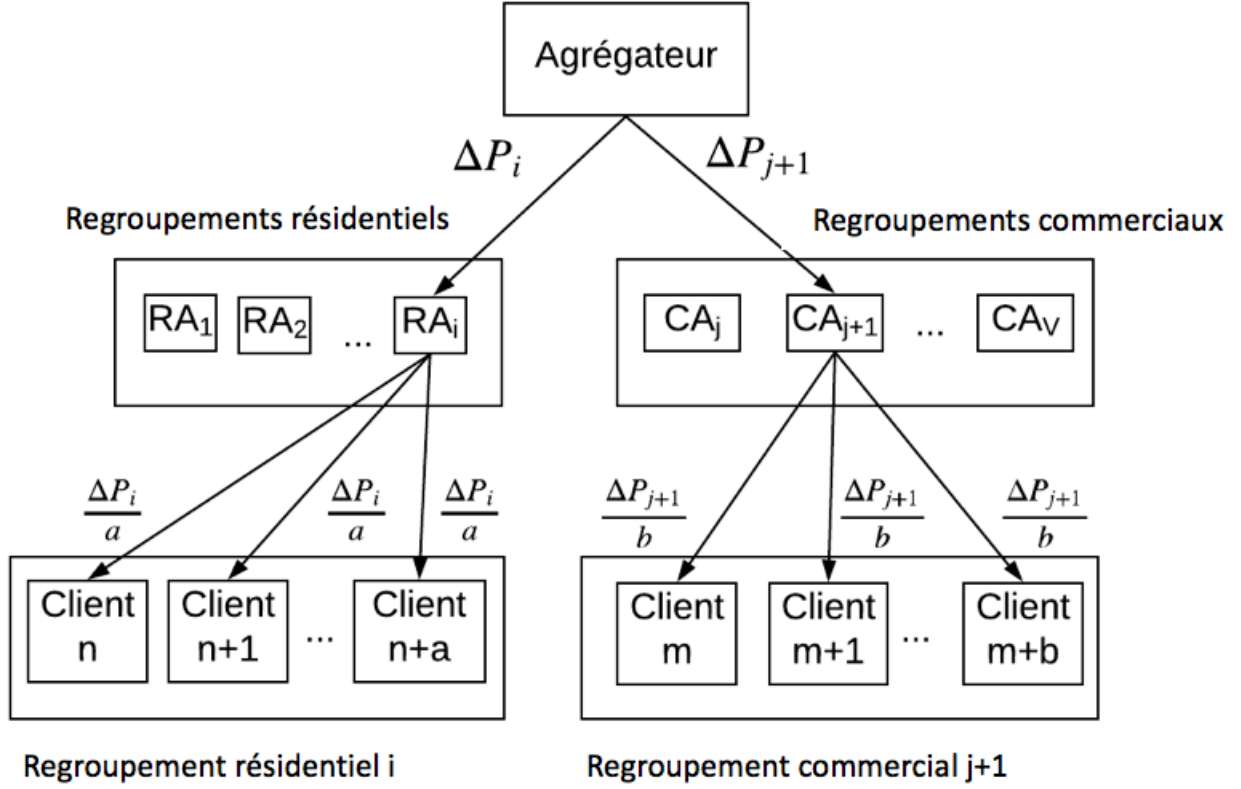


Figure 3.7 La hiérarchie de l'agrégation des clients

$$E[\Delta P_{j*}] = \frac{\Delta P_i}{a} p_i \quad (3.80)$$

$$Var[\Delta P_{j*}] = p_i(1 - p_i) \left(\frac{\Delta P_i}{a} \right)^2 \quad (3.81)$$

Les clients étant homogènes dans un même regroupement, l'espérance mathématique et la variance du client j peuvent être multipliées par a pour calculer l'espérance mathématique et la variance du regroupement.

$$E[\Delta P_i^*] = \Delta P_i p_i \quad \forall i \in I \quad (3.82)$$

$$Var[\Delta P_i^*] = \frac{p_i(1-p_i)\Delta P_i^2}{a} \quad \forall i \in BH \cup SH \quad (3.83)$$

$$Var[\Delta P_i^*] = \frac{p_i(1-p_i)\Delta P_i^2}{b} \quad \forall i \in COM \quad (3.84)$$

Différents degrés de regroupement a et b ont été testés sur trois sous-stations et les résultats sont présentés à l'annexe B.

3.5 Résolution

Pour résoudre plus efficacement le modèle, une transformation est faite sur la contrainte non-linéaire. Celle-ci est transformée en problème de Programmation sur le Cône du Second Ordre (PCSO). La contrainte non linéaire de ce type de problème doit s'écrire selon l'équation 3.85.

$$\sum_{i \in I} x_i^2 \leq y^2 \quad (3.85)$$

avec $y \geq 0$.

Les contraintes (3.36), (3.37) et (3.38) du problème (P1) sont transformés sous la forme de l'équation 3.85.

$$\mu = \sum_{i \in I} p_i^+ \Delta P_i \quad (3.86)$$

$$y = \frac{\mu - P_u}{Z_\alpha^2} \quad (3.87)$$

$$x_i = k_i \Delta P_i \quad \forall i \in I \quad (3.88)$$

$$y^2 \geq \sum_{i \in I} x_i^2 \quad (3.89)$$

$$y \geq 0 \quad (3.90)$$

La variable $y \in \mathbb{R}^+$ est ajoutée au modèle ainsi que la variable $x \in \mathbb{R}^{1 \times n}$. Le paramètre k est un coefficient issu du calcul de la variance de la réponse et est donc différent selon le degré de regroupement a et b .

$$k_i = \frac{\sqrt{p_i(1-p_i)}}{a} \quad \forall i \in BH \cup SH \quad (3.91)$$

$$k_i = \frac{\sqrt{p_i(1-p_i)}}{b} \quad \forall i \in COM \quad (3.92)$$

Les contraintes (3.42), (3.44) et (3.44) du problème (P2) sont transformées également pour obtenir la même forme.

$$\mu = \sum_{i \in I} p_i^- \Delta P_i \quad (3.93)$$

$$y = \frac{P_u - \mu}{Z_\alpha^2} \quad (3.94)$$

$$x_i = k_i \Delta P_i \quad \forall i \in I \quad (3.95)$$

$$y^2 \geq \sum_{i \in I} x_i^2 \quad (3.96)$$

$$y \geq 0 \quad (3.97)$$

Avec cette nouvelle formulation, n'importe quel solveur traitant les problèmes PCSO peut être utilisé. Ici, le solveur Gurobi a été utilisé pour faire la résolution du problème.

3.5.1 Résultats

Trois études de cas ont été testées à la sous-station Buckingham avec les requêtes d'utilités calculées avec $\beta = 0, 10$. La sous-station Bukingham a été choisie, car elle a les plus grandes requêtes d'utilités. La valeur de la requête d'utilité de chaque période est montrée à la figure 3.8. Le niveau de confiance α est constant pour les trois études de cas et est égal à 0,95. Un ensemble initial de 30 000 clients a été regroupé avec un niveau de regroupement $a = 100$ et $b = 10$ ce qui réduit à 975 le nombre de regroupements. Le cas de base est utilisé à titre de référence pour étudier l'impact des changements sur la solution optimale. Les paramètres des trois études de cas sont présentés dans le tableau 3.5.

Étude de cas de base

Le figure 3.8 montre que seuls les clients ayant une faible probabilité sont sollicités dans le cas de base. L'agrégateur préfère envoyer plus de requêtes à moindre coût pour satisfaire

Tableau 3.5 Paramètre des études de cas

Cas	c_i (\$/kW)			n_{max}^i		Sous-Ensemble
	<i>LOW</i>	<i>MOD</i>	<i>HIGH</i>	<i>CAT</i> ₁	<i>CAT</i> ₂	
Cas de base	1	2	3	21	7	<i>BH, SH, COM</i>
Cas 1	1	1.5	1.75	21	7	<i>BH, SH, COM</i>
Cas 2	1	2	3	1	1	<i>BH, SH, COM</i>
Cas 3	1	2	3	21	7	<i>SH, COM</i>

Tableau 3.6 Resultats des études de cas

Cas	Temps de résolution (s)	Coût total (\$)
Cas de base	2	501 768
Cas 1	1	500 458
Cas 2	2	732 523
Cas 3	12	502 491

la requête d'utilité plutôt que d'envoyer moins de requêtes à plus grand coût. La figure 3.9 montre le coût par kW de réduction ou d'augmentation (\$/kW) à travers la semaine. Ce coût représente le coût des requêtes de DR pour une période divisée par la requête d'utilité de cette même période. Ainsi, le coût par kW de réduction ou d'augmentation peut être comparé d'une période à l'autre et d'une étude de cas à l'autre. La figure 3.9 montre que pour le cas de base, ce coût varie entre 1.73 \$/kW et 1.81 \$/kW. Comme le coût des requêtes des clients des sous-ensembles *MOD* et *HIGH* est respectivement 2 \$/kW et 3 \$/kW, l'agrégateur n'a aucun intérêt à solliciter ces clients.

Étude de cas 1

Cependant, l'agrégateur vise une participation des clients avec une probabilité approchant 1. Un agrégateur a donc de l'intérêt à vouloir prioriser les clients ayant une grande probabilité. Pour ce faire, la détermination des coûts des requêtes doit être faite de façon stratégique. L'étude de cas 1 analyse l'impact des coûts des requêtes sur les sous-ensembles de probabilité sollicités. Le tableau 3.5 montre les coûts de chaque sous-ensemble. Dans la figure 3.8, on voit que le sous-ensemble *HIGH* est maintenant sollicité avec les nouveaux coûts. Le tableau 3.9 montre que le coût par kW de réduction ou d'augmentation (\$/kW) n'a sensiblement pas changé. Les coûts totaux pour le cas de base sont de 501 768 \$ et de l'étude de cas 1 est de 500 458 \$ ce qui représente 0,26 % de réduction. Bien que les coûts totaux n'ont presque pas changé, l'agrégateur a de l'intérêt à vouloir prioriser les clients ayant une grande probabilité.

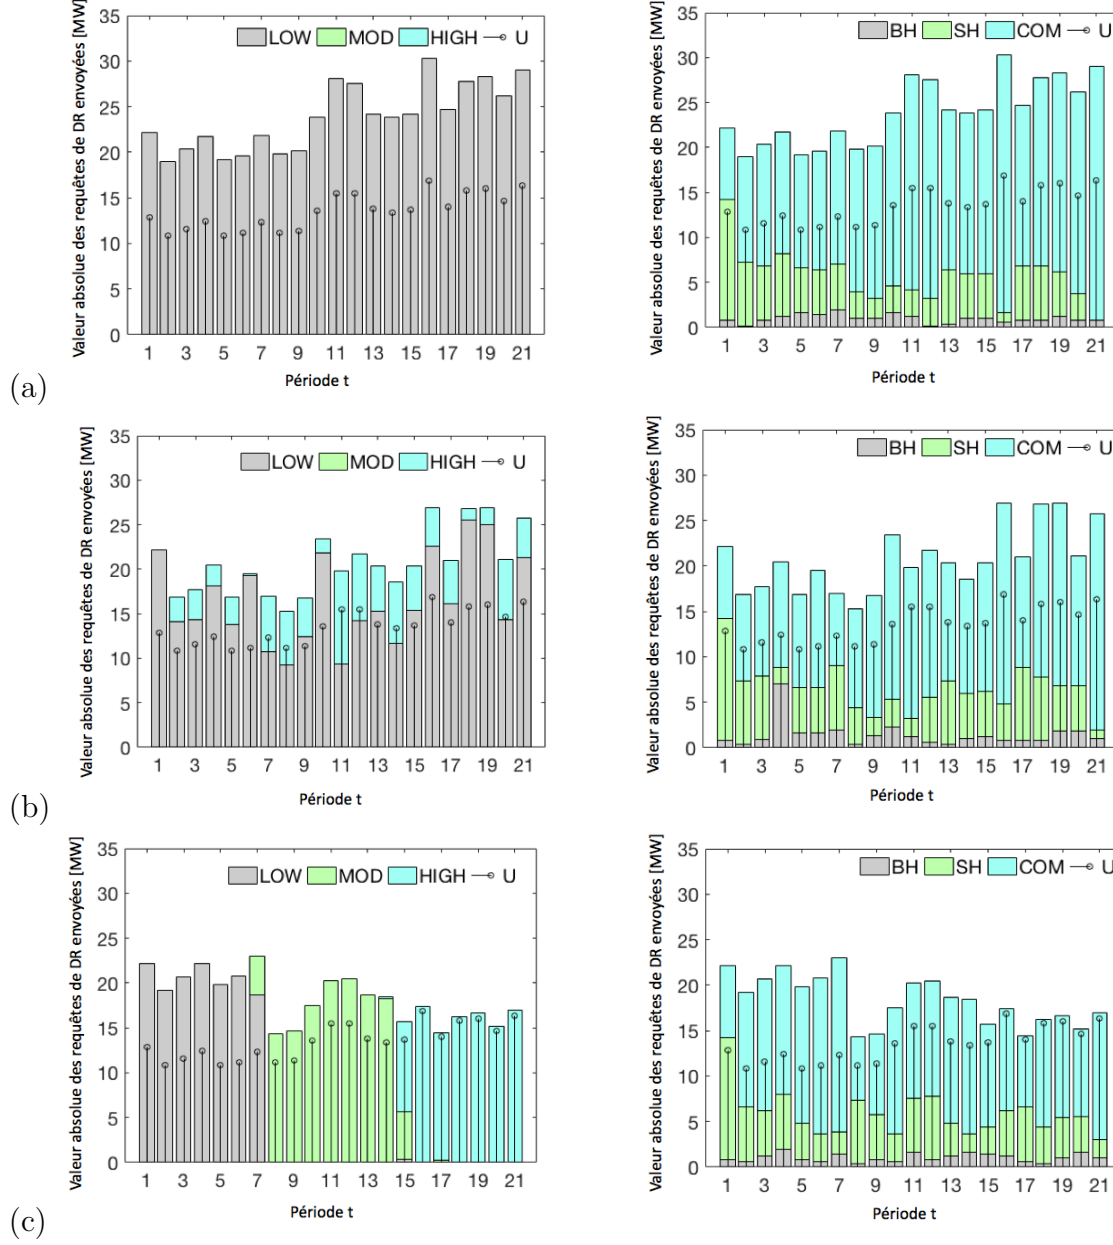


Figure 3.8 Répartition des requêtes de DR envoyées à chaque sous-ensemble de probabilité et de secteur pour (a) le cas de base, (b) l'étude de cas 1 et (c) l'étude de cas 2.

Étude de cas 2

L'étude de cas 2 montre les limites du modèle. Le modèle a été testé avec un maximum d'une requête par semaine pour chaque client. La figure 3.9 montre que le coût par kW de réduction ou augmentation varie pendant la semaine. À la fin de la semaine, ce coût est à 3,10 \$/kW tandis qu'au début il est à 1,73 \$/kW. Cette forte augmentation s'explique avec

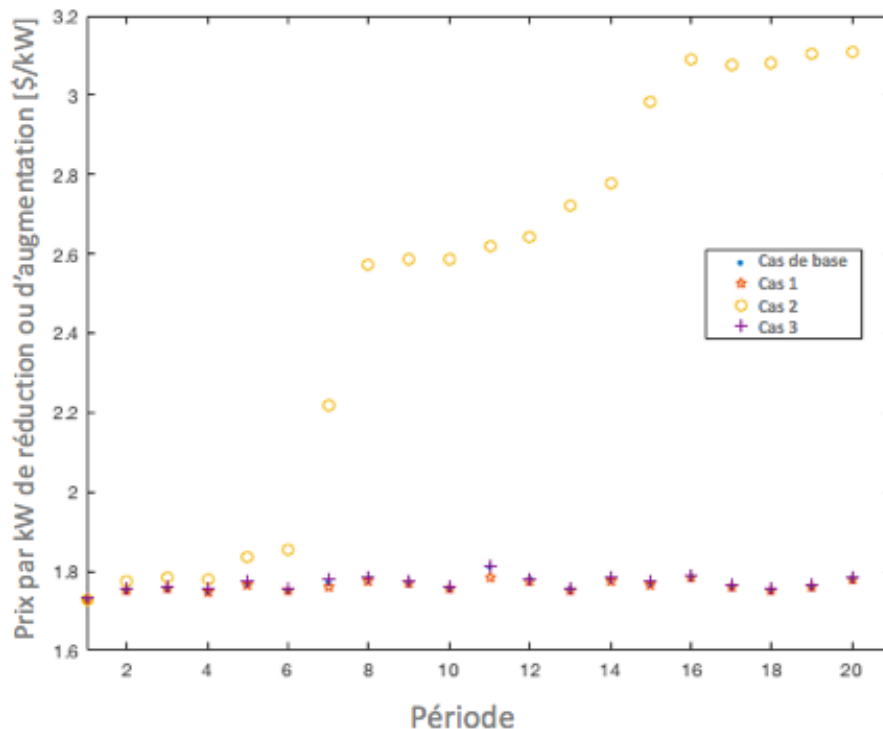


Figure 3.9 Coût par kW de réduction ou d'augmentation de chaque période de la semaine (\$/kW)

la figure 3.8. Au début de la semaine, l'agrégateur sollicite seulement les clients du sous-ensemble *LOW* jusqu'à ce qu'aucun client ne soit disponible. L'agrégateur passe ensuite aux clients du sous-ensemble *MOD* puis aux clients du sous-ensemble *HIGH*. L'agrégateur n'anticipe pas les décisions prises en début en fonction des conditions de la fin de la semaine, ce qui peut engendrer de grands coûts. Par exemple, une grande requête d'utilité en fin de semaine coûtera presque 2 fois plus qu'une grande requête d'utilité en début de semaine. Une façon de pallier ce problème est de rendre le modèle dynamique. Ainsi, l'agrégateur peut minimiser les coûts totaux de la semaine. Par contre, pour ce faire la méthode de prévision de la consommation doit s'adapter. En effet, un modèle dynamique résout le problème pour une semaine complète. La prévision de la consommation doit donc se faire pour toute la semaine, et ce en début de semaine.

Étude de cas 3

Finalement, un agrégateur peut vouloir analyser l'impact de la participation de certains secteurs aux programmes de DR. Étant donné que les programmes de DR nécessitent une installation d'équipement de communication, des coûts initiaux sont associés à l'implantation

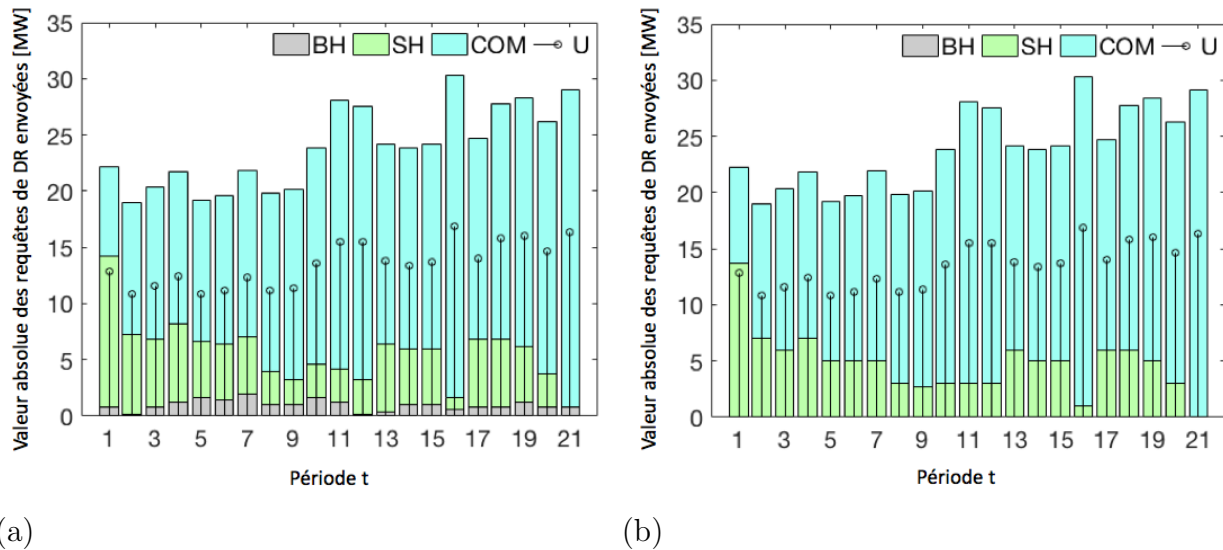


Figure 3.10 Répartition des requêtes de DR envoyées à chaque sous-ensemble de secteur pour (a) l'étude de cas 1 et (b) l'étude de cas 3.

de ces programmes. Pour être profitable, ces coûts d'installation doivent être faibles par rapport aux profits anticipés par les programmes. La participation des clients ayant une maison de base est analysée pour voir si l'agrégateur tire un profit de leur participation. Une troisième étude de cas est créée pour analyser cet impact. Les paramètres sont les mêmes que le cas de base, mais le sous-ensemble *BH* est retiré de l'ensemble des clients. La figure 3.8 montre que les secteurs commercial et résidentiel avec maison intelligente ont compensé le sous-ensemble *BH*. Les coûts totaux du cas de base passent de 501 768 \$ à 502 491 \$ à l'étude de cas 3. Ceci correspond à une augmentation de 0,41 % ce qui n'est pas significatif. Dans ces conditions, un agrégateur pourrait décider de ne pas installer l'équipement chez les clients ayant une maison de base.

CHAPITRE 4 DISCUSSION GÉNÉRALE

Le modèle mathématique développé lors de cette recherche répond bien aux objectifs principaux des programmes de DR établis en revue de littérature. Grâce aux programmes de DR, la consommation totale d'électricité est réduite ou augmentée de l'ordre d'une dizaine de MW. La réduction de consommation permet de diminuer la production électrique en heure de pointe. Les centrales d'appoint ne sont plus nécessaires puisque les clients adaptent leur consommation. L'augmentation de la demande conformément à l'énergie disponible supporte l'augmentation de la production par énergie renouvelable. Cependant, la prévision de la production par énergie renouvelable pourrait rendre le modèle plus réaliste. En effet, cette production varie énormément en fonction des conditions météorologiques. Une étude plus approfondie sur la prédiction de la production éolienne et solaire pourrait permettre une meilleure prédiction de la requête d'utilité. Dans ce modèle, la requête d'utilité est calculée seulement en prenant un pourcentage de la consommation prédite. En incluant la production par énergie renouvelable dans ce calcul, la requête d'utilité serait plus fidèle à la réalité.

Grâce au modèle d'optimisation à contraintes probabiliste, l'incertitude de la réponse a été incluse lors de la distribution des requêtes. Ceci aide l'agrégateur à assurer une stabilité au réseau avec un certain niveau de confiance. La méthode proposée s'adapte pour permettre une modélisation des probabilités adéquates. Les facteurs qui influencent la réponse d'un client, listés dans l'étude de [2] et décrit en revue de littérature, ont été intégrés au modèle. En effet, le modèle permet aux probabilités d'être différentes d'une période à l'autre. Elles sont également influencées par le nombre de requêtes reçues pendant la semaine. Certains clients sont sensibles aux fréquences des requêtes et d'autres clients qui demeurent insensibles. Cette relation est également prise en compte dans le modèle. De plus, la direction de la requête est un facteur inclus dans le modèle. Comme un modèle est résolu pour une augmentation de la charge et un second modèle est résolu pour une diminution de la charge, les probabilités peuvent différer pour les deux directions de requêtes. Finalement, certains facteurs n'ont pas été pris en compte lors de cette recherche. La température extérieure en est un. Dans un contexte d'hiver québécois, il serait intéressant d'en étudier son effet. En temps de grand froid, l'utilité cherche à réduire la demande d'électricité pour limiter la production. Par contre, si la température extérieure est très basse, les clients seraient potentiellement moins enclins à changer la température d'une pièce et répondre à la requête de DR. La durée de la requête a également été négligée dans cette recherche, la durée étant égale à une heure pour toutes les requêtes. L'incitatif reçu par le client est aussi un facteur qui a été omis dans le modèle. Son influence sur la participation des clients est expliquée dans ce chapitre.

Finalement, le modèle inclut beaucoup de facteurs pour caractériser le plus fidèlement la réponse des clients. Il pourrait cependant être amélioré en incluant les facteurs manquants. Une autre façon d'améliorer la caractérisation de la réponse des clients est de faire un projet pilote au Québec en hiver. Puisque c'est dans ces conditions que le modèle a été développé, il faudrait faire un projet pilote avant de l'implanter et d'en analyser les résultats. Ainsi, les probabilités de chaque secteur pourraient être mieux estimées.

Les modèles de prévision de la consommation présentés dans la revue de littérature offrent de bons résultats dans un contexte d'hiver québécois. Ces méthodes peuvent s'adapter, mais doivent être modifiées pour rendre les modèles précis selon les locations et saisons. La consommation électrique en été est surtout due à la climatisation. Le taux d'humidité doit donc être pris en compte lors de la création des modèles. Également, les profils de consommation diffèrent en été. La température étant plus élevée en milieu de journée, c'est à ce moment que la consommation d'électricité est élevée. Ce sont des modifications à amener dans les modèles de prévision pour obtenir des prédictions précises en été.

Ayant un modèle non-linéaire avec des variables binaires, le temps de résolution dépend fortement du nombre de variables. Un agrégateur ayant un grand nombre de clients doit pouvoir résoudre le problème d'optimisation dans un temps raisonnable. Comme l'agrégateur distribue les requêtes de DR pour l'heure suivante, le temps de résolution ne doit pas excéder 20 minutes. Si c'est le cas, une méthode d'agrégation des clients est proposée. En agrégeant les clients en préservant les caractéristiques de chacun, le nombre de variables diminue considérablement. Ainsi, l'agrégation peut résoudre le problème en quelques secondes.

Finalement, cette recherche comporte quelques limitations. Premièrement, la méthode développée ne considère pas le futur. Ayant une connaissance des conditions à venir, l'agrégateur pourrait vouloir réserver une certaine ressource et l'utiliser plus tard. L'étude de cas 2 montre cette limitation puisque tous les clients ayant un faible coût sont utilisés dès le début. À la fin de la semaine, les coûts sont beaucoup plus importants qu'en début de semaine. Un modèle dynamique pourrait permettre une planification de la distribution des requêtes. Ceci ajouterait cependant beaucoup de variables au modèle et augmenterait de façon considérable le temps de résolution. L'agrégation de charge est d'autant plus importante dans un modèle dynamique pour réduire le nombre de variables et diminuer le temps de résolution. Un modèle dynamique impliquerait également de modifier les modèles de prévision de la charge. En effet, les modèles développés lors de cette étude utilisent les consommations des heures précédentes pour prédire la consommation de l'heure suivante. Un modèle faisant la planification sur une semaine se doit d'avoir un modèle de prévision à plus long terme. Une nouvelle analyse de performance des modèles devrait être faite pour faire la prévision à moyen terme.

De plus, une étude plus approfondie sur les marchés d'électricité devrait être faite pour déterminer le montant des incitatifs donnés aux clients. Comme présenté en revue de littérature à la figure 2.10, une négociation entre l'agrégateur et le client est faite pour déterminer le montant des incitatifs. L'objectif du client est de maximiser ses bénéfices à travers les programmes de DR et l'agrégateur tente de minimiser ses coûts. Une optimisation bi-niveau pourrait permettre d'exprimer les objectifs de chacun des partis de la négociation. De plus, le projet pilote en Espagne a établi que la participation des clients dépendait de l'incitatif reçu. Ces deux paramètres sont interreliés. L'incitatif donné à un client est plus important si la probabilité du client est grande. Par contre, la probabilité de réponse du client augmente aussi si l'incitatif reçu est plus grand. L'agrégateur vise toujours à réduire ces coûts, mais désire toutefois avoir une bonne réponse de la part du client. Un compromis doit donc être fait entre la probabilité de réponse du client et l'incitatif donné. Également, la figure 2.9 montre la structure hiérarchique de l'agrégateur au sein du réseau. L'agrégateur reçoit un incitatif remis par l'utilité et le distribue ensuite parmi les clients. L'agrégateur vise donc à maximiser ses profits qui sont définis par la différence entre les incitatifs reçus et les incitatifs distribués. Le modèle développé dans cette recherche ne prend pas en compte les incitatifs reçus de l'utilité. Un modèle plus réaliste devrait l'inclure et faire une étude du marché d'électricité pour déterminer la valeur de l'incitatif.

L'équipement nécessaire aux programmes de DR montré en revue de littérature nécessite une installation chez le client. D'emblée, un client ayant une maison de base peut sembler moins enclin à vouloir participer aux programmes de DR. L'agrégateur peut donc vouloir analyser l'impact de ce type de clients sur les coûts. Si l'inclusion de ce groupe de clients réduit significativement les coûts, l'agrégateur peut vouloir envisager l'installation d'équipement chez ces clients. Cette analyse peut se faire pour tous les types de clients et secteurs. Le modèle développé peut aider à la prise de décision d'inclure un certain type de client. Un agrégateur peut vérifier l'impact d'un certain secteur sur les coûts totaux. Il aide également à observer les proportions des différents sous-ensembles sollicités et analyser l'impact sur les coûts.

CHAPITRE 5 CONCLUSION ET RECOMMANDATIONS

Pour conclure, un rappel sur la méthodologie du travail est fait dans la section 5.1. Les limitations de la solution proposées sont décrites avec certaines améliorations futures proposées.

5.1 Synthèse des travaux

L'agrégateur en tant qu'intermédiaire entre l'utilité et les clients vise à minimiser ses coûts tout en distribuant des requêtes de DR parmi les clients. Ces requêtes de DR doivent satisfaire la requête d'utilité pour assurer une stabilité du réseau électrique. La réponse des clients face aux requêtes de DR étant incertaine, un modèle mathématique à contrainte probabiliste est développé. Grâce à ce modèle, les requêtes de DR satisfont toujours la requête d'utilité avec un certain niveau de confiance. Dans cette méthode, l'agrégateur vise à réduire la consommation totale des clients en heure de pointe et à augmenter la consommation totale des clients lorsque la production par énergie renouvelable est élevée. La méthode proposée pour évaluer la requête d'utilité s'appuie sur la prévision de la consommation à court terme. Trois méthodes de prévision ont été comparées et la méthode non-paramétrique a été choisie, car elle offre les résultats les plus précis. Lorsque la prévision de la consommation est réalisée, la requête d'utilité est calculée en multipliant un certain pourcentage β . L'agrégateur vise donc à augmenter ou diminuer la consommation totale de ce pourcentage β . Finalement afin de réduire le nombre de variables dans le modèle, une méthode de regroupement des clients est proposée. Le regroupement sert à réduire le temps de résolution, mais permet de garder les caractéristiques des clients.

5.2 Limitations de la solution proposée

Ce projet comporte plusieurs limitations. Comme présenté au chapitre 4, le modèle non dynamique est limité. La prise de décision n'est pas anticipée en début de semaine ce qui peut créer une forte augmentation des coûts en fin de semaine. Un modèle dynamique pourrait remédier à cette limitation. Par contre, le temps de résolution pourrait augmenter fortement, car le nombre de variables augmente considérablement dans un modèle dynamique. La méthode d'agrégation de clients pourrait s'avérer très utile dans un modèle dynamique.

Une autre limitation de ce projet réside dans la méthode de prévision de la consommation. Les méthodes ont été développées avec des données en hiver québécois. Les facteurs qui influencent la consommation diffèrent d'une saison à l'autre. Les méthodes développées lors

de cette recherche ne peuvent pas s'appliquer à n'importe quelles régions et saisons.

5.3 Améliorations futures

Le modèle peut être amélioré de plusieurs façons. Afin de caractériser plus fidèlement les clients, un projet pilote devrait être fait. Ainsi, les probabilités estimées seraient plus fiables. Les facteurs négligés dans cette recherche mériteraient d'être analysés pour rendre le modèle encore plus réaliste. Ces facteurs sont la température extérieure et l'incitatif reçu par le client.

L'incitatif reçu par le client nécessite une plus grande analyse, car une étude du marché de l'électricité doit être faite. Comme discuté au chapitre 4, une négociation entre le client et l'agrégateur doit être faite afin de déterminer le coût des requêtes. Une optimisation bi-niveau peut permettre de fixer ce coût. L'incitatif que l'utilité envoie à l'agrégateur doit également être inclus dans le modèle pour respecter la structure hiérarchique de l'agrégateur. Le montant de cet incitatif nécessite aussi une étude du marché de l'électricité.

Finalement, la détermination de la requête d'utilité peut être améliorée. En effet, l'objectif des programmes de DR est d'équilibrer la production et la consommation d'électricité. La production par énergie renouvelable varie selon les conditions météorologiques. Une prévision de cette production pourrait permettre une meilleure estimation de la requête d'utilité.

RÉFÉRENCES

- [1] U.S. Energy Information Administration, “Annual Energy Outlook 2014,” *US Department of Energy*, vol. 0383, p. 1–269, 2014.
- [2] M. Vallés, A. Bello, J. Reneses et P. Frías, “Probabilistic characterization of electricity consumer responsiveness to economic incentives,” *Applied Energy*, vol. 216, n°. September 2017, p. 296–310, 2018. [En ligne]. Disponible : <https://doi.org/10.1016/j.apenergy.2018.02.058>
- [3] F. Rahimi et A. Ipakchi, “Smart Grid Paradigm,” *IEEE Transactions on Smart Grid*, vol. 1, n°. 1, p. 82–88, 2010. [En ligne]. Disponible : http://ieeexplore.ieee.org/xpls/abs{__}all.jsp?arnumber=5454394
- [4] J. S. Vardakas, N. Zorba et C. V. Verikoukis, “A Survey on Demand Response Programs in Smart Grids : Pricing Methods and Optimization Algorithms,” *IEEE Communications Surveys and Tutorials*, vol. 17, n°. 1, p. 152–178, 2015.
- [5] L. Gkatzikis et I. Koutsopoulos, “The Role of Aggregators in Smart Grid Demand,” vol. 31, n°. 7, p. 1247–1257, 2013.
- [6] Q. Li, Q. Meng, J. Cai, H. Yoshino et A. Mochida, “Applying support vector machine to predict hourly cooling load in the building,” *Applied Energy*, vol. 86, n°. 10, p. 2249–2256, 2009. [En ligne]. Disponible : <http://dx.doi.org/10.1016/j.apenergy.2008.11.035>
- [7] K. Cheng, Z. Lu, Y. Wei, Y. Shi et Y. Zhou, “Mixed kernel function support vector regression for global sensitivity analysis,” *Mechanical Systems and Signal Processing*, vol. 96, p. 201–214, nov 2017. [En ligne]. Disponible : <http://linkinghub.elsevier.com/retrieve/pii/S0888327017301991>
- [8] (2016, juin) 94. what is the interest in energy storage? - qnovo. [En ligne]. Disponible : <https://qnovo.com/94-interest-energy-storage/>
- [9] U.S. Dept. Energy, “Benefits of Demand Response in Electricity Markets and Recommendations for Achieving Them,” report to the United States Congress, Washington, DC, USA, Rapport technique February, 2009.
- [10] M. Eissa, “Demand side management program evaluation based on industrial and commercial field data,” *Energy Policy*, vol. 39, n°. 10, p. 5961–5969, 2011.
- [11] E. Santacana, G. Rackliffe, L. Tang et X. Feng, “Getting smart,” *IEEE Power and Energy Magazine*, vol. 6, n°. 2, p. 38–45, 2008.

- [12] S. Mohagheghi, J. Stoupis, Z. Wang, Z. Li et H. Kazemzadeh, "Demand Response Architecture : Integration into the Distribution Management System," *2010 First IEEE International Conference on Smart Grid Communications*, p. 501–506, 2010. [En ligne]. Disponible : <http://ieeexplore.ieee.org/document/5622094/>
- [13] Y. Yan, Y. Qian, H. Sharif et D. Tipper, "A survey on smart grid communication infrastructures : Motivations, requirements and challenges," *IEEE Communications Surveys and Tutorials*, vol. 15, n^o. 1, p. 5–20, 2013.
- [14] X. Fang, S. Misra, G. Xue et D. Yang, "Managing smart grid information in the cloud : opportunities, model, and applications," *IEEE Network*, vol. 26, p. 32–38, 2012.
- [15] J. Liu, Y. Xiao, S. Li, W. Liang et C. L. Chen, "Cyber security and privacy issues in smart grids," *IEEE Communications Surveys and Tutorials*, vol. 14, n^o. 4, p. 981–997, 2012.
- [16] D. T. Ton et M. A. Smith, "The u.s. department of energy's microgrid initiative," *The Electricity Journal*, vol. 25, n^o. 8, p. 84 – 94, 2012. [En ligne]. Disponible : <http://www.sciencedirect.com/science/article/pii/S1040619012002254>
- [17] Q. Dong, L. Yu, W. Z. Song, L. Tong et S. Tang, "Distributed demand and response algorithm for optimizing social-welfare in smart grid," *Proceedings of the 2012 IEEE 26th International Parallel and Distributed Processing Symposium, IPDPS 2012*, p. 1228–1239, 2012.
- [18] J. L. Mathieu, M. G. Vaya et G. Andersson, "Uncertainty in the flexibility of aggregations of demand response resources," *IECON Proceedings (Industrial Electronics Conference)*, p. 8052–8057, 2013.
- [19] P. H. Chen et H. C. Chang, "Large-scale economic dispatch by genetic algorithm," *IEEE Transactions on Power Systems*, vol. 10, n^o. 4, p. 1919–1926, 1995.
- [20] A. Zakariazadeh, S. Jadid et P. Siano, "Electrical Power and Energy Systems Smart microgrid energy and reserve scheduling with demand response using stochastic optimization," *International Journal of Electrical Power and Energy Systems*, vol. 63, p. 523–533, 2014. [En ligne]. Disponible : <http://dx.doi.org/10.1016/j.ijepes.2014.06.037>
- [21] J. R. Birge et F. Louveaux, *Introduction to Stochastic Programming*. Springer, 2006.
- [22] M. Manickavasagam, M. F. Anjos et W. D. Rosehart, "Sensitivity-based chance-constrained Generation Expansion Planning," *Electric Power Systems Research*, vol. 127, p. 32–40, 2015. [En ligne]. Disponible : <http://dx.doi.org/10.1016/j.epsr.2015.05.011>
- [23] P. Kall et S. W. Wallace, *Stochastic Programming*, 2^e éd. John Wiley and Sons, 1994.

- [24] D. Lazos, A. B. Sproul et M. Kay, "Optimisation of energy management in commercial buildings with weather forecasting inputs : A review," *Renewable and Sustainable Energy Reviews*, vol. 39, p. 587–603, 2014. [En ligne]. Disponible : <http://dx.doi.org/10.1016/j.rser.2014.07.053>
- [25] H. S. Hippert, C. E. Pedreira et R. C. Souza, "Neural networks for short-term load forecasting : A review and evaluation," *IEEE Transactions on Power Systems*, vol. 16, n^o. 1, p. 44–55, 2001.
- [26] N. I. Sapankevych et R. Sankar, "Time series prediction using support vector machines : A survey," *IEEE Computational Intelligence Magazine*, n^o. May, p. 24–38, 2009.
- [27] S. Humeau, T. K. Wijaya, M. Vasirani et K. Aberer, "Electricity load forecasting for residential customers : Exploiting aggregation and correlation between households," *Sustainable Internet and ICT for Sustainability (SustainIT)*, p. 1–6, Oct 2013.
- [28] W. Charytoniuk, M.-S. Chen et P. Van Olinda, "Nonparametric regression based short-term load forecasting," *Power Systems, IEEE Transactions*, vol. 13, n^o. 3, p. 725–730, 1998.
- [29] Y. Chetouani, "Using ARX approach for modelling and prediction of the dynamics of a reactor-exchanger," *ICHEME*, n^o. 154, 2008.
- [30] P. P. N. Mathieu, Johanna L, S. Kiliccote et M. A. Piette, "Quantifying Changes in Building Electricity Use , With Application to Demand Response," vol. 2, n^o. 3, p. 507–518, 2011.
- [31] (2018, juill.) Glossary - climate - environment and climate change canada. [En ligne]. Disponible : http://climate.weather.gc.ca/glossary_e.html
- [32] T. K. Wijaya, M. Vasirani, S. Humeau et K. Aberer, "Cluster-based Aggregate Forecasting for Residential Electricity Demand using Smart Meter Data," *IEEE International Conference on Big Data (Big Data)*, p. 879–887, 2015.
- [33] G. D. Ruxton, "The unequal variance t-test is an underused alternative to Student's t-test and the Mann-Whitney U test," *Behavioral Ecology*, vol. 17, n^o. 4, p. 688–690, 2006.

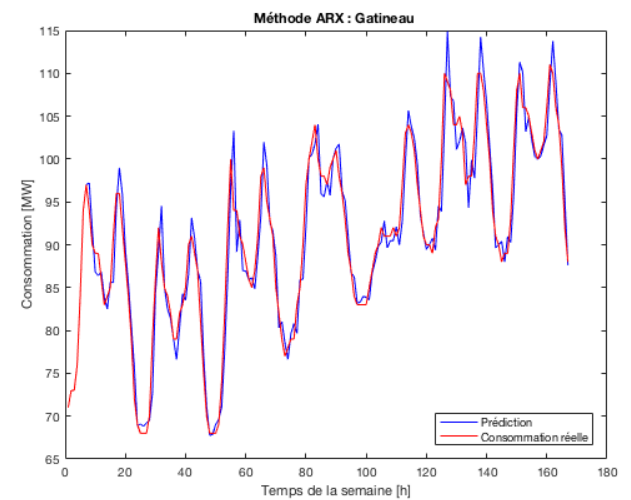
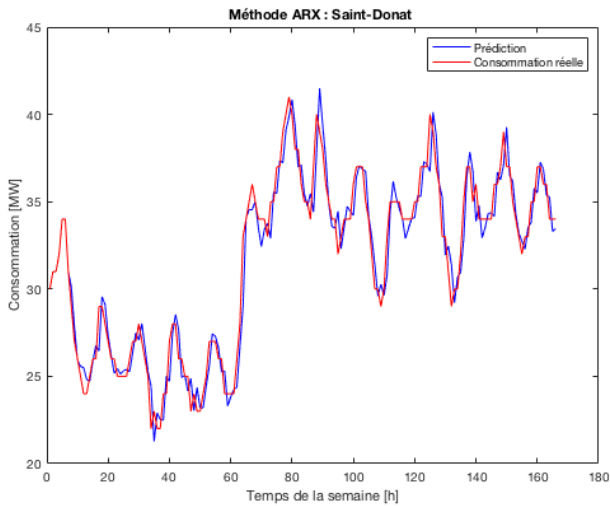
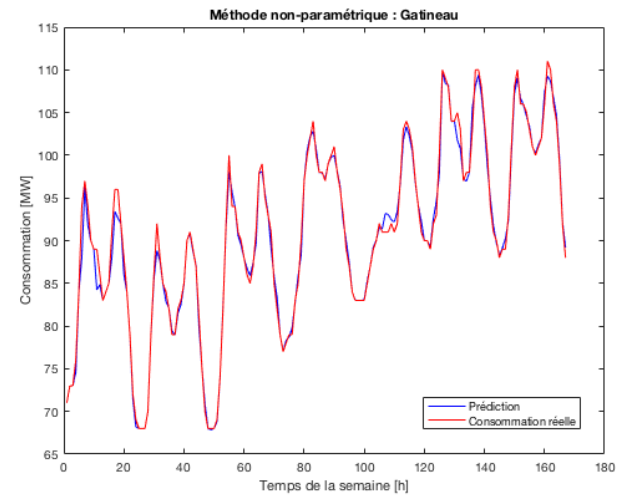
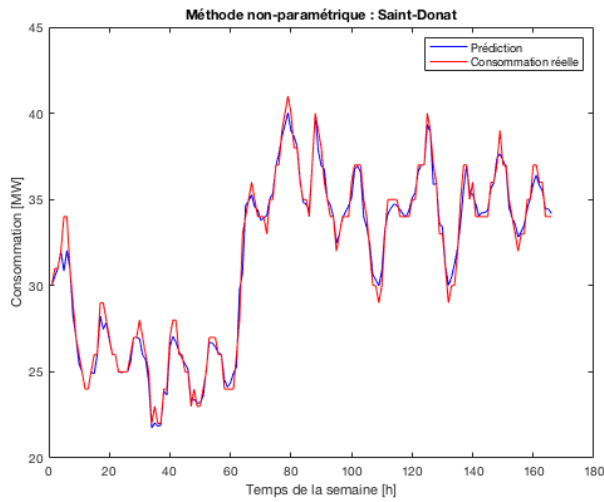
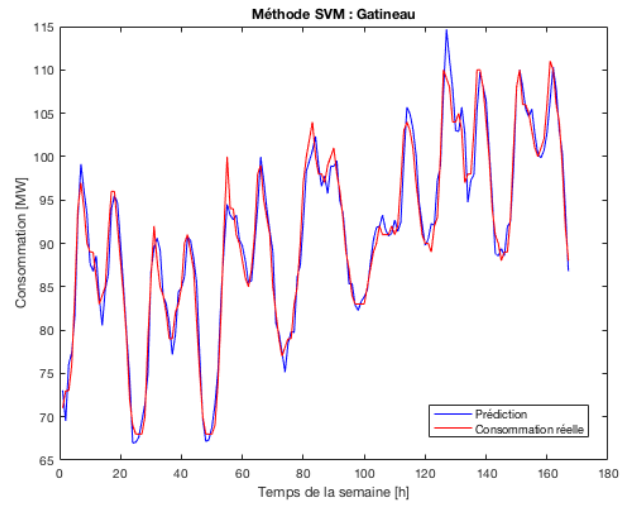
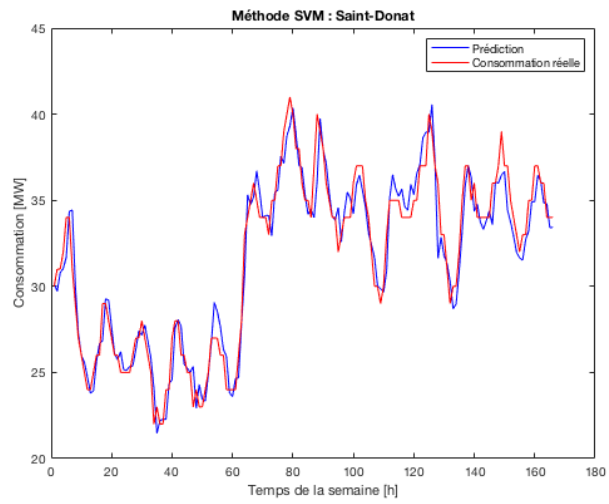
ANNEXE A RÉSULTATS DE LA PRÉVISION DE LA CONSOMMATION

Tableau A.1 Résultats des tests statistiques de chaque sous-station

	Méthode	S1	S2	S3	S4	S5	S6	S7	S8	S9
Test de Fisher Valeur p	SVM	0,78	0,74	0,90	0,68	0,97	0,91	0,67	0,75	0,48
	NP	0,99	0,93	0,87	0,95	0,89	0,78	0,93	0,93	0,88
	ARX	0,99	0,87	0,99	0,91	0,86	0,94	0,91	0,84	0,90
Statistique F	SVM	1,04	1,05	1,02	1,07	1,01	1,02	1,07	1,05	1,12
	NP	1,00	1,01	0,97	1,01	1,02	1,04	1,01	1,01	1,02
	ARX	1,00	1,02	1,00	0,98	0,97	0,99	1,02	1,03	1,02
Test de Student Valeur p	SVM	0,97	0,96	0,99	0,81	0,96	0,95	0,85	0,70	0,49
	NP	0,79	0,78	0,77	0,81	0,85	0,78	0,82	0,52	0,81
	ARX	0,90	0,94	0,92	0,92	0,94	0,90	0,92	0,82	0,93
Statistique T	SVM	-0,03	0,05	-0,01	0,25	-0,06	0,06	0,19	-0,38	0,69
	NP	0,27	0,28	0,29	0,24	0,19	0,28	0,23	0,64	0,24
	ARX	0,12	0,08	0,10	0,10	0,08	0,13	0,10	0,23	0,09

Ici, les valeurs ne peuvent pas être comparées. Elles sont montrées simplement pour prouver que les deux hypothèses nulles ne sont pas rejetées. À titre de rappel, les deux hypothèses nulles sont l'égalité des moyennes et l'égalité des variances. Celles-ci sont rejetées si la valeur p est plus petite que 0,05.

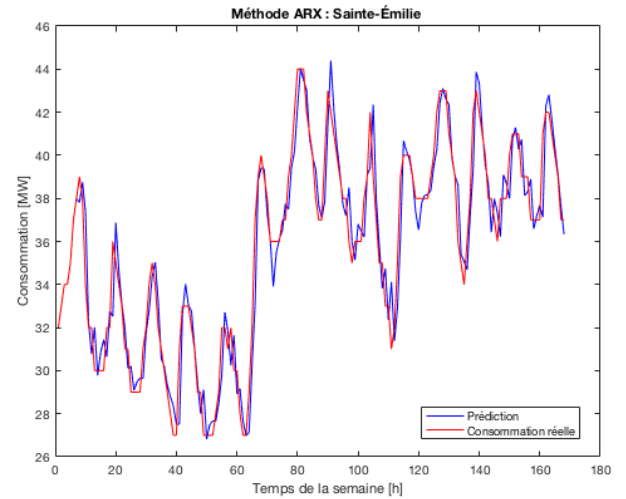
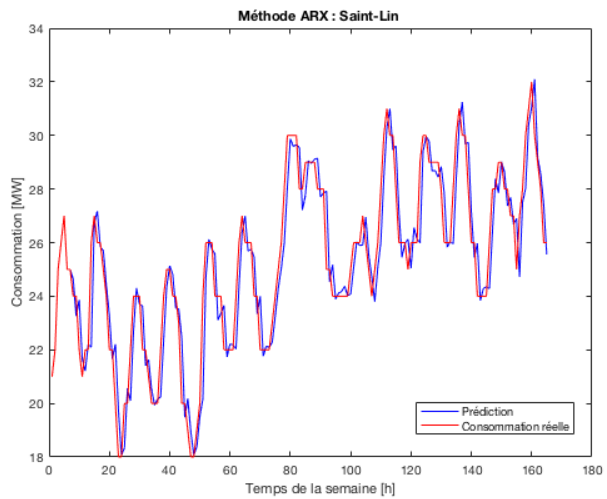
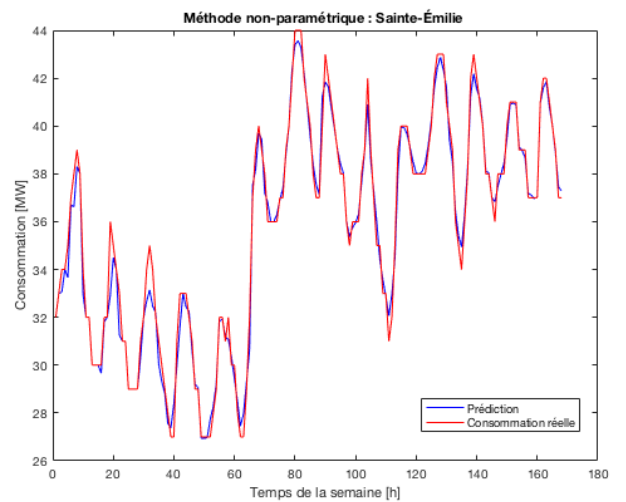
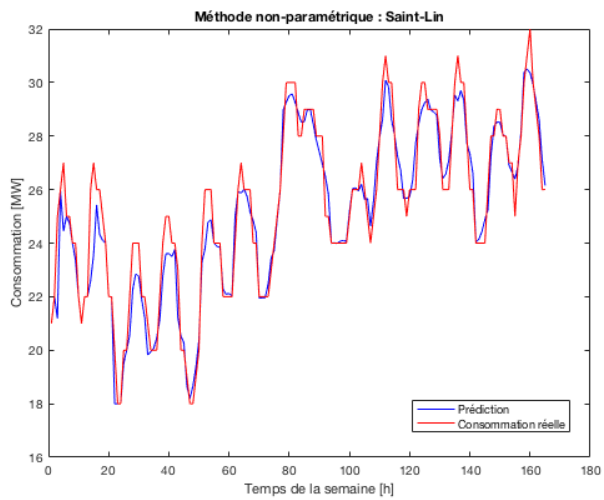
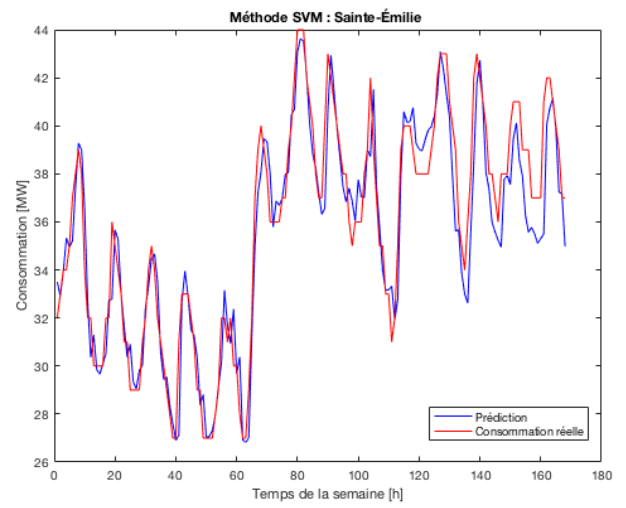
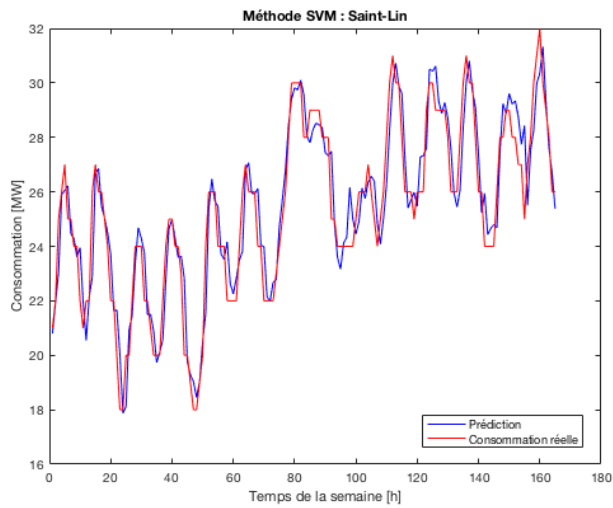
Tableau A.2 Courbe de consommation réelle et prédite par les trois méthodes aux station (a) Saint-Donat et (b) Gatineau



(a)

(b)

Tableau A.3 Courbe de consommation réelle et prédite par les trois méthodes aux station (a) Saint-Lin et (b) Sainte-Émilie



(a)

(b)

ANNEXE B RÉSULTATS DU MODÈLE D'OPTIMISATION

Le serveur en ligne NEOS est utilisé pour résoudre les problèmes à l'aide du solveur Gurobi. La limite de temps de résolution est de 8 heures et la limite de mémoire est de 3 GB de RAM.

Tableau B.1 Résultats des sous-stations Buckingham, Cheneville et Gamelin pour 30 000 clients et $\beta = 0,05$

	Buckingham	Cheneville	Gamelin
α	Temps (s)	Temps (s)	Temps (s)
0.90	Limite de mémoire atteinte	Limite de temps atteinte	5899
0.95	Limite de mémoire atteinte	Limite de mémoire atteinte	Limite de mémoire atteinte
0.99	Limite de temps atteinte	Limite de mémoire atteinte	Limite de mémoire atteinte

Tableau B.2 Résultats des sous-stations Buckingham, Cheneville et Gamelin pour 30 000 clients et $\beta = 0,10$

	Buckingham	Cheneville	Gamelin
α	Temps (s)	Temps (s)	Temps (s)
0.90	Limite de mémoire atteinte	Limite de mémoire atteinte	1273
0.95	Limite de mémoire atteinte	Limite de temps atteinte	Limite de temps atteinte
0.99	Limite de mémoire atteinte	Limite de mémoire atteinte	Limite de temps atteinte

Tableau B.3 Résultats des sous-stations Buckingham, Cheneville et Gamelin pour 20 000 clients et $\beta = 0,05$

	Buckingham	Cheneville	Gamelin
α	Temps (s)	Temps (s)	Temps (s)
0.90	1103	Limite de temps atteinte	459
0.95	1275	Limite de temps atteinte	277
0.99	Limite de temps atteinte	Limite de temps atteinte	4968

Tableau B.4 Résultats des sous-stations Buckingham, Cheneville et Gamelin pour 20 000 clients et $\beta = 0, 10$

	Buckingham	Cheneville	Gamelin
α	Temps (s)	Temps (s)	Temps (s)
0.90	1226	871	639
0.95	1158	1173	629
0.99	2668	Limite de temps atteinte	2219

Tableau B.5 Résultats du modèle des charges agrégées des sous-stations de Buckingham, Cheneville et Gamelin avec $\beta = 0, 05$

α	a	b	V	Buckingham		Cheneville		Gamelin	
				Temps (s)	Coût (k\$)	Temps (s)	Coût (k\$)	Temps (s)	Coût (k\$)
0.90	50	5	1950	115	10,17	72	5,25	70	30,47
0.95	50	5	1950	250	10,23	407	5,29	72	30,70
0.99	50	5	1950	-	-	-	-	72	31,10
0.90	50	10	1200	132	10,19	30	5,25	9	30,36
0.95	50	10	1200	97	10,25	43	5,29	2	30,61
0.99	50	10	1200	252	10,39	52	5,36	17	31,04
0.90	100	10	975	5	10,60	8	5,22	8	30,14
0.95	100	10	975	5	10,60	7	5,24	7	30,29
0.99	100	10	975	12	10,60	15	5,30	7	30,57

Tableau B.6 Résultats du modèle des charges agrégées des sous-stations de Buckingham, Cheneville et Gamelin avec $\beta = 0, 10$

Station				Buckingham		Cheneville		Gamelin	
α	a	b	V	Temps (s)	Coût (k\$)	Temps (s)	Coût (k\$)	Temps (s)	Coût (k\$)
0.90	50	5	1950	412	20,48	65	10,53	67	61,61
0.95	50	5	1950	522	20,60	118	10,60	83	62,52
0.99	50	5	1950	297	20,85	129	10,74	98	64,07
0.90	50	10	1200	90	20,49	42	10,55	5	61,08
0.95	50	10	1200	135	20,64	47	10,61	5	61,81
0.99	50	10	1200	90	20,91	33	10,76	7	63,14
0.90	100	10	975	3	20,284	5	10,46	2	60,83
0.95	100	10	975	10	20,36	9	10,50	5	61,54
0.99	100	10	975	20	20,55	14	10,61	2	62,66

ANNEXE C ARTICLE 1 : DEMAND RESPONSE VIA LARGE-SCALE CLUSTERING UNDER UNCERTAINTY OF RESOURCE AVAILABILITY

Authors

Émilie Chénier, Miguel F. Anjos, Dalal Asber, Laurent Lenoir

Submitted to:

Electric Power Systems Research

Abstract

Demand Response (DR) helps to stabilize the grid, but DR programs have to be implemented correctly to ensure their efficiency. Aggregators distribute the DR requests among the customers to satisfy utility requests. We propose a two-stage optimization-based approach that incorporates the uncertainty of the customers' responsiveness. First, we estimate the utility request by forecasting the total load consumption. Three forecasting methods are presented and compared. We use a chance-constrained formulation to account for the uncertainty of the responsiveness, and we test the approach using typical profiles of several substations from North America.

C.1 Introduction

Demand Response (DR) programs are valuable resources that help utilities to balance load consumption and production. DR programs that allow the change in the demand profile to follow the available supply are especially important in regions with a high penetration of renewable resources [4]. Aggregators help the utility to manage a large number of charges and to distribute the DR requests among the customers; Gkatzikis & Koutsopoulos [5] discuss the role of aggregators in the smart grid. We present an optimization model for the aggregator, and we aim to minimize its total cost.

Several techniques can be used to handle uncertainties in an optimization model. Manickavasagam et al. [22] formulate a chance-constrained optimization (CCO) model that includes the uncertainty of the load consumption. We use CCO to include the uncertainties of the

resource availability. We transform the chance constraints into nonlinear constraints using probabilistic laws.

To evaluate the utility requests (URs), the aggregator forecasts the total load consumption. Various forecasting techniques in the commercial sector are discussed in [24], while [27] uses the support vector machine (SVM) to forecast the load consumption in the residential sector. Nonparametric regression [28] is another effective technique for short-term load forecasting. We compare the SVM method, the nonparametric method, and the ARX (autoregressive exogenous) method. We use metrics from the literature to evaluate the methods.

This paper is organized as follows. Section C.2 presents a literature review. Section C.3 presents the approach and the context in which the optimization model is used. Section C.4 describes the experimental set-up, and Section C.5 presents the results of the load prediction and the CCO model. Section C.6 provides concluding remarks.

C.2 Literature Review

Vardakas et al. [4] present the DR scheme and the four main objectives of DR. First, DR reduces the total power consumption, which benefits both utilities and customers [10]. Second, as a consequence it reduces the power generation necessary [9]. The activation of power plants during peak periods can be avoided, and utilities can meet their pollution obligations [9]. Third, DR is an important resource in regions with a high penetration of renewable production. The customers can adapt their load profiles to follow the production profile [11]. Finally, the overload in the distribution system can be reduced or eliminated via near-real-time decisions that maintain the stability of the grid [12].

Gkatzikis & Koutsopoulos [5] describe the role of aggregators in the smart grid in a day-ahead market. An aggregator is an intermediary between the utility and the customers. It receives incentives from the utility and dispatches incentives to the end-users. The authors present the optimization model for the utility, the aggregator, and the customers. The utility aims to maximize its profit, and its expenses include the purchase of electricity, the operational costs, and the DR incentives given to aggregators. The aggregator aims to maximize the difference between the incentives received and those distributed to customers. Finally, the customers' goal is to maximize the net payoff. In a day-ahead market, there is a negotiation between the aggregators and the end-users, and the aggregators compete with each other to obtain incentives from the utilities. We develop an optimization model for the aggregator.

Vallés et al. [2] study the responsiveness to DR programs. They report the results of a pilot DR program conducted in Spain and propose a quantile regression for a probabilistic

characterization of the demand flexibility. They identify several external factors that affect the responsiveness of the clients to incentives. Mathieu et al. [18] investigate the impact of a false estimation of the customers' responsiveness on the grid. If overestimation occurs, the aggregator may be unable to satisfy the URs, which jeopardizes the stability of the grid. Underestimation leads to underutilisation of the resources and missed opportunities.

Sapankevych & Sankar [26] explore time series prediction using an SVM, which is claimed to be an accurate forecasting technique for load consumption prediction. They compare this method with the nonparametric method and the ARX method using two metrics from [32]. They also present a statistical analysis of the methods.

Several techniques can be used to handle uncertainty. Zakariazadeh et al. [20] use a two-stage formulation to include the uncertainty of renewable production in a DR schedule. At the first stage, they make decisions without full information on the stochastic parameters. At the second stage, some of the uncertainty is revealed, and they update the decisions [21].

We used the CCO approach; see, e.g., [22]. It guarantees the satisfaction of a constraint with a given level of confidence; the statistical distributions of the parameters can be approximated. The CCO model developed in this research can be viewed as an economic dispatch problem [19].

C.3 Our Approach

Aggregators act as intermediaries between utilities and customers; the communication is two-way. The utility specifies the total load increase or decrease, called the UR (U), and provides incentives to the aggregators. The aggregators receive the UR and dispatch DR requests (ΔP) to the customers, providing incentives (c). The customers receive the DR requests and adapt their load consumption accordingly. Customers register their consumption via smart meters, and the aggregators forecast the total load consumption (L_t) from historical data; the utility receives the total consumption. We include customers in both the residential and commercial sectors. Figure C.1 shows the hierarchical structure and the interaction between the three levels.

The aggregator makes three adjustments each day: two to reduce the load at the peak times (7 a.m. and 6 p.m.) and one to increase the load at noon. The increased use of solar panels can create a peak in production at noon, when the irradiance of the sun is at its most intense, but consumption dips at that time in winter. The aggregator therefore sends DR requests to increase the consumption to match the production. We focus on the winter consumption in Quebec, but our approach can easily be adapted to other load profiles. To allow the

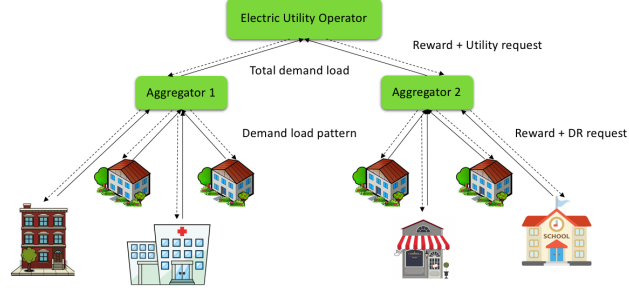


Figure C.1 Hierarchical structure [5].

parameters to vary over the week, we introduce a set T of 21 periods. At the beginning of each adjustment t is set and the parameters are selected as a function of t .

The aggregators handle both load increases ($U \leq 0$) and decreases ($U \geq 0$). We assume that the load is shifted during off-peak periods so it does not affect the predicted load during peak periods. The algorithm iterates over the 21 time periods, and after each iteration it adjusts the number of DR requests sent to a customer (n). After a week, this parameter is reset to zero. Each customer has a probability p of responding to the DR request; this value is determined by several factors and is updated at each time period.

The algorithm is as follows:

1. Initialize n , t , and p
2. Forecast the total load demand (L_t) at time t
3. Evaluate the UR
4. Solve the optimization model
5. Update n , t , and p
6. Go to step 2 until $t = 21$
7. Go to step 1

We discuss each step in the following subsections.

C.3.1 Forecasting Techniques

The period t is initialized at step 1, and L_t is forecast for the preceding hour (step 2). The forecast is then used to estimate the UR (step 3). The UR is evaluated as follows:

$$\beta L_t = U \quad \text{for a reduction} \quad (\text{C.1})$$

$$-\beta L_t = U \quad \text{for an increase} \quad (\text{C.2})$$

where β is the total load increase or decrease as a percentage. Several short-term forecasting techniques are used in the literature. We compare the SVM, nonparametric, and ARX methods. We describe the SVM method in the following subsection; for the nonparametric method see [28] and for the ARX method see [29].

Support Vector Machine Method

As in [27], the load consumption can be forecast using the SVM method. This method aims to approximate the output y as a function of the input parameters, also called the predictors, x :

$$y = f(x) = w * \phi(x) + b. \quad (\text{C.3})$$

The objective is to find the optimal weights w and the threshold b . These parameters can be calculated by minimizing the “flatness” of the weights and the empirical risk. The flatness is calculated via the Euclidean norm, $\|w\|^2$, and the empirical risk, $R_{emp}(f)$, is the error generated by the estimation process.

The overall objective is to minimize the regularized risk:

$$R_{reg}(f) = R_{emp}(f) + \frac{1}{2}\|w\|^2. \quad (\text{C.4})$$

The SVM optimization model is:

$$\min R_{reg}(f) = \min R_{emp}(f) + \frac{1}{2}\|w\|^2 \quad (\text{C.5})$$

$$R_{emp}(f) = \frac{1}{N} \sum_{i=1}^N L_{\epsilon}(y_i, f(x_i)) \quad (\text{C.6})$$

With the ϵ -incentive loss function, the problem becomes:

$$\min \frac{1}{2}\|w\|^2 + C \sum_{i=1}^N L_{\epsilon}(y_i, f(x_i)) \quad (\text{C.7})$$

$$L_\epsilon(Y_i, f(X_i)) = \begin{cases} 0 & |y_i - f(x_i)| \leq \epsilon \\ |y_i - f(x_i)| - \epsilon & \text{otherwise} \end{cases} \quad (\text{C.8})$$

To make the problem feasible, we introduce slack variables ζ_i and ζ_i^* :

$$\min_{\zeta_i, \zeta_i^*, w, b} \quad \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\zeta_i + \zeta_i^*) \quad (\text{C.9})$$

$$\text{s.t.} \quad y_i - w\phi(x_i) - b \leq \epsilon + \zeta_i \quad i = 1 \dots N \quad (\text{C.10})$$

$$w\phi(x_i) + b - y_i \leq \epsilon \zeta_i^* \quad i = 1 \dots N \quad (\text{C.11})$$

$$\zeta_i, \zeta_i^* \geq 0 \quad i = 1 \dots N \quad (\text{C.12})$$

Since the problem is convex, it is simpler to solve the dual by using the Lagrange multipliers:

$$\max_{\alpha_i, \alpha_i^*} \quad -\frac{1}{2} \sum_{i,j=1}^N (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) \langle x_i, x_j \rangle \quad (\text{C.13})$$

$$- \epsilon \sum_{i=1}^N (\alpha_i - \alpha_i^*) + \sum_{i=1}^N y_i (\alpha_i - \alpha_i^*) \quad (\text{C.14})$$

$$\text{s.t.} \quad \sum_{i=1}^N (\alpha_i - \alpha_i^*) = 0 : \alpha_i, \alpha_i^* \in [0, C] \quad (\text{C.15})$$

The approximation $y = f(x)$ becomes

$$f(x) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) \langle x, x_i \rangle + b. \quad (\text{C.16})$$

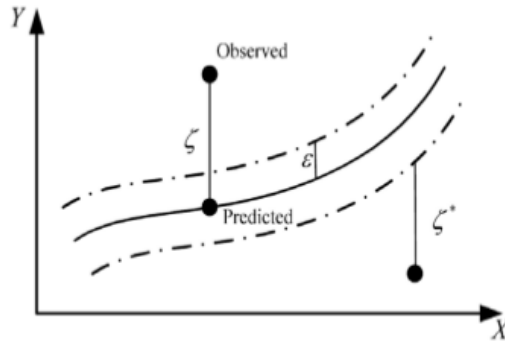


Figure C.2 Soft margin of SVR [6].

To deal with nonlinearity, we use a kernel function to map the input space X into a higher dimension. A kernel function is a function that satisfies Mercer's condition,

$$k(x_i, x_j) = \langle \phi(x_i), \phi(x_j) \rangle, \quad (\text{C.17})$$

and can be substituted back into the approximation $f(x)$:

$$f(x) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) k(x_i, x_j) + b. \quad (\text{C.18})$$

The Gaussian kernel function is widely used:

$$k(x_i, x_j) = \exp(-\lambda \|x_i - x_j\|^2). \quad (\text{C.19})$$

The data points on or outside the ϵ -tube, with nonzero Lagrange multipliers α , are called support vectors. The optimal parameters minimize the prediction error and are typically computed empirically. We use a stepwise search method. The predictors are the loads of the preceding five hours, the adjusted temperature, and the time period.

C.3.2 Chance-Constrained Optimization

Aggregator Model

With a forecast of the total load consumption, the aggregator can solve the optimization model with the given UR. At step 4, the aggregator distributes the DR requests to the customers in order to meet the UR. The UR constraint can be written:

$$\sum_{i \in I} \Delta P_i = U \quad (\text{C.20})$$

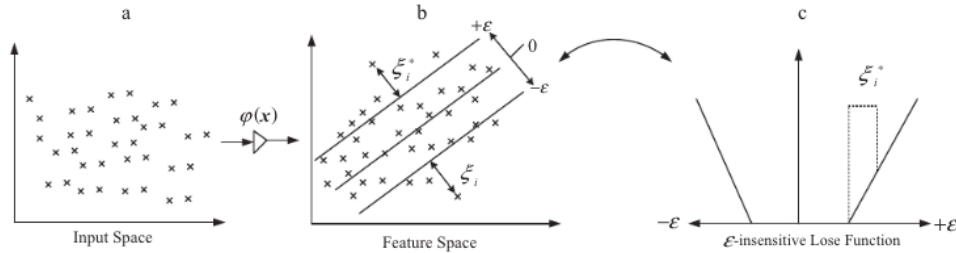


Figure C.3 Kernel transformation [7].

However, with probability p_i client i will not respond to the DR request. We assume that the response is either zero or ΔP_i . The response of the clients (ΔP^*) can then be approximated by a Bernoulli law:

$$E[\Delta P_i^*] = \Delta P_i p_i \quad \forall i \in I; \quad (\text{C.21})$$

$$\text{Var}[\Delta P_i^*] = p_i(1 - p_i)\Delta P_i^2 \quad \forall i \in I. \quad (\text{C.22})$$

The aggregator must ensure that the total response (R^*) is greater than or equal to the UR (if positive) or less than or equal to the UR (if negative):

$$\sum_{i \in I} \Delta P_i^* = R^* \geq U, \quad U \geq 0; \quad (\text{C.23})$$

$$\sum_{i \in I} \Delta P_i^* = R^* \leq U, \quad U \leq 0. \quad (\text{C.24})$$

The aggregator wants to accept sufficient DR requests at a minimum cost while ensuring sufficient backup capacity to mitigate uncertainty. To deal with the uncertainty of the resource availability, we use CCO. We ensure that the UR constraint is satisfied at a certain level of confidence (α):

$$\text{Prob}(R^* \geq U) \geq \alpha, \quad U \geq 0; \quad (\text{C.25})$$

$$\text{Prob}(R^* \leq U) \geq \alpha, \quad U \leq 0. \quad (\text{C.26})$$

R^* is unknown but can be approximated; we assume that all the clients are independent. Using the central limit theorem, the total response can be approximated by

$$R^* \sim \mathcal{N}(\mu, \sigma^2) \quad (\text{C.27})$$

$$\mu = \sum_{i \in I} \Delta P_i p_i \quad (\text{C.28})$$

$$\sigma^2 = \sum_{i \in I} p_i(1 - p_i)\Delta P_i^2. \quad (\text{C.29})$$

Constraints (C.25) and (C.26) can be transformed into nonlinear constraints:

$$-U \geq Z_\alpha \sqrt{\sigma^2} - \mu, \quad U \geq 0 \quad (\text{C.30})$$

$$U \geq Z_\alpha \sqrt{\sigma^2} + \mu, \quad U \leq 0 \quad (\text{C.31})$$

where Z_α is the inverse cumulative density function of the standard normal distribution calculated at α .

It is difficult to approximate the response probability of each client. As [2] suggested, the response is influenced by many external factors. We take into account the time of day, the day of the week, the frequency, and the direction of the requests. We propose three groups of clients with low, moderate, and high response probabilities. The week is divided into 21 periods, and each period can have a different probability. The probabilities can also depend on whether the load is increased or decreased. Finally, the probability is a function of the number of requests received earlier in the week: $p_i = f(n_i) \forall i \in I$. The parameter n_i is updated after each iteration and reset at the beginning of the week. The parameter n_{max} is the maximal number of DR requests allowed by a client within a week.

The function $f(n_i)$ is also hard to approximate, and we define two categories of customers. CAT_1 is not influenced by the frequency of the requests, and CAT_2 depends linearly on the frequency:

$$p_i^+ = p_{it}^+ \quad \forall i \in CAT_1 \quad (C.32)$$

$$p_i^- = p_{it}^- \quad \forall i \in CAT_1 \quad (C.33)$$

$$p_i^+ = p_{it}^+ - \frac{p_{it}^+}{n_{max}^i} n_i \quad \forall i \in CAT_2 \quad (C.34)$$

$$p_i^- = p_{it}^- - \frac{p_{it}^-}{n_{max}^i} n_i \quad \forall i \in CAT_2. \quad (C.35)$$

Equations (C.34) and (C.35) indicate that when a customer reaches n_{max} during the week, his/her response probability becomes zero for the rest of the week. At the beginning of each week, the probabilities are reset.

The model solved by the aggregator depends on whether the UR is positive or negative. The model is solved once for each period t . If $U \geq 0$, the model solved is (P1):

$$\min_{\Delta P, \mu, \sigma, w} \sum_{i \in I} c_{it}^+ \Delta P_i \quad (C.36)$$

$$\mu = \sum_{i \in I} p_i^+ \Delta P_i \quad (C.37)$$

$$\sigma^2 = \sum_{i \in I} p_i^+ (1 - p_i^+) \Delta P_i^2 \quad (C.38)$$

$$-U \geq Z_\alpha \sqrt{\sigma^2} - \mu \quad (C.39)$$

$$\underline{\Delta P}_i^+ w_i \leq \Delta P_i \leq \overline{\Delta P}_i^+ w_i \quad \forall i \in I \quad (C.40)$$

$$n_i + w_i \leq n_{max}^i \quad \forall i \in I \quad (C.41)$$

$$w_i \in \{0, 1\} \quad \forall i \in I \quad (C.42)$$

If $U \leq 0$, the model solved is (P2):

$$\min_{\Delta P, \mu, \sigma, w} - \sum_{i \in I} c_{it}^- \Delta P_i \quad (\text{C.43})$$

$$\mu = \sum_{i \in I} p_i^- \Delta P_i \quad (\text{C.44})$$

$$\sigma^2 = \sum_{i \in I} p_i^- (1 - p_i^-) \Delta P_i^2 \quad (\text{C.45})$$

$$U \geq Z_\alpha \sqrt{\sigma^2} + \mu \quad (\text{C.46})$$

$$\underline{\Delta P}_i^- w_i \leq \Delta P_i \leq \overline{\Delta P}_i^- w_i \quad \forall i \in I \quad (\text{C.47})$$

$$n_i + w_i \leq n_{max}^i \quad \forall i \in I \quad (\text{C.48})$$

$$w_i \in \{0, 1\} \quad \forall i \in I \quad (\text{C.49})$$

The binary variable w_i is equal to 1 if the client i receives a DR request, and 0 otherwise. Constraints (C.40) and (C.47) express the DR capacity of each client; this is the load that can be shifted or reduced. A DR request to a client must be between the client's minimum and maximum DR capacity. Constraints (C.41) and (C.48) ensure that the number of DR requests does not exceed the client's maximal number.

At optimality, the parameters n and t are updated via $n_i = n_i + w_i$ and $t = t + 1$, and p is updated via Equations (C.32)–(C.35). The load consumption is now forecast for the new period, and the process starts again.

Second-Order Cone Reformulation

To solve this problem more efficiently, we can transform the model into a second-order cone problem (SOCP). The nonlinear constraint must have the form

$$\sum_{i \in I} x_i^2 \leq y^2 \quad (\text{C.50})$$

with $y \geq 0$.

The (P1) constraints

$$\mu = \sum_{i \in I} p_i^+ \Delta P_i \quad (\text{C.51})$$

$$\sigma^2 = \sum_{i \in I} p_i^+ (1 - p_i^+) \Delta P_i^2 \quad (\text{C.52})$$

$$-P_u \geq Z_\alpha \sqrt{\sigma^2} - \mu \quad (\text{C.53})$$

are transformed to

$$\mu = \sum_{i \in I} p_i^+ \Delta P_i \quad (\text{C.54})$$

$$y = \frac{\mu - P_u}{Z_\alpha^2} \quad (\text{C.55})$$

$$x_i = k_i \Delta P_i \quad \forall i \in I \quad (\text{C.56})$$

$$y^2 \geq \sum_{i \in I} x_i^2 \quad (\text{C.57})$$

$$y \geq 0. \quad (\text{C.58})$$

The variables $y \in \mathbb{R}^+$ and $x \in \mathbb{R}^{1 \times n}$ are added to the model, and $k = \sqrt{p^T(\mathbb{1} - p)}$ becomes a parameter $k \in \mathbb{R}^{1 \times n}$. The constraints of (P2) are identical except for constraint (C.55), which is replaced by

$$y = \frac{P_u - \mu}{Z_\alpha^2}. \quad (\text{C.59})$$

Any SOCP solver can now be used to solve the problem; we used Gurobi.

C.4 Experimental Set-up

C.4.1 Real-World Data

We divide the set I of n_c clients into three sectors, BH , SH , and COM , with different DR capacities. Sector BH contains the basic homes with no smart appliances or electric vehicles; adjustments to the water heater and thermostat can reduce the load. Sector SH contains so-called smart homes: they have smart appliances and/or electric vehicles. Finally, sector COM is the commercial sector, including restaurants, hotels, and schools. The DR capacity of a commercial client is defined by the percentage η of the peak load; we set $\eta = 0.05$.

We used the eShapes_National package to simulate commercial data based on data generated hourly in 2001 in New England, USA. The software simulates the load consumption in W/pi^2 for nine types of building; Table C.1 gives their estimated sizes. We simulated the data by varying the size by $\pm 20\%$; we assume that we have the same number of each building type.

Figure C.4 shows an example of the load profiles.

We use the simulated data to calculate the DR capacity in the commercial sector. We then combine the commercial customers into h groups, created by minimizing the sum of the distances from the points to the centroid. The squared Euclidean distance is used to calculate the distance. We set $h = 5$, and the DR capacity of each group is defined to be the mean

Building type	Size	Building type	Size	Building type	Size
Apartment building	75	College	240	School	60
Restaurant	3	Hotel	36	Small office	1
Medium office	100	Large office	150	Store	10

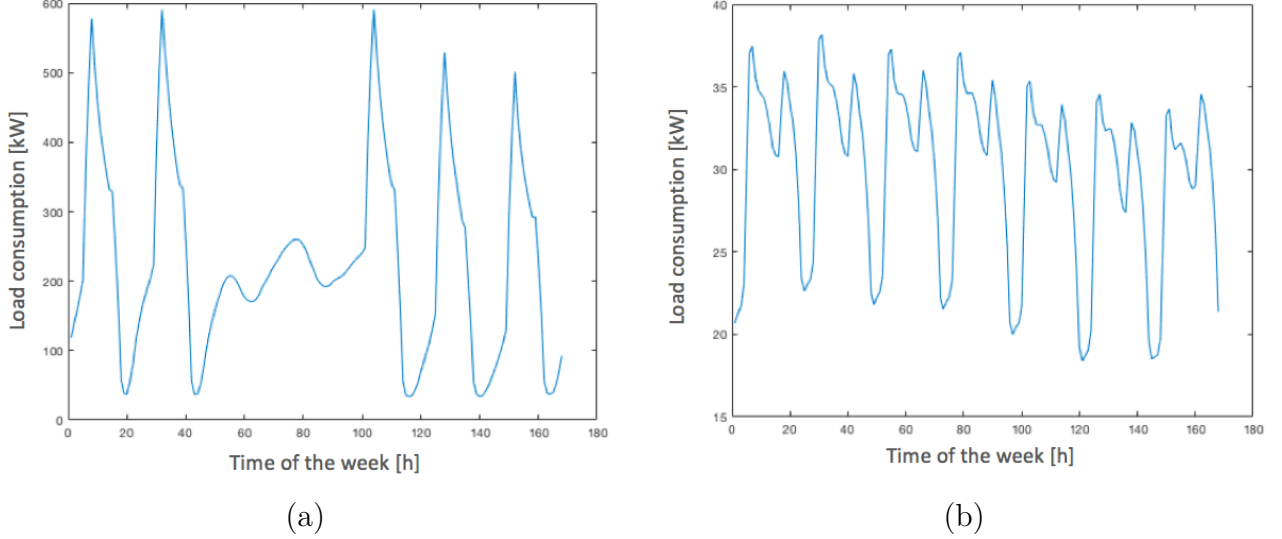
Table C.1 Estimated size of each building type in kpi^2 

Figure C.4 Load profile of (a) school and (b) restaurant over one week.

of the DR capacities of the clients in the group. Table C.2 gives the results of the grouping and the DR capacity of each subset. We considered 30,000 clients with 75% residential and 25% commercial. We assume that $\underline{\Delta P}_i^+ = 1$ and $\overline{\Delta P}_i^- = -1, \forall i \in I$. We also assume that $\underline{\Delta P}_i^- = -\overline{\Delta P}^+, \forall i \in I$.

Table C.2 DR capacities of 30,000 customers

Subset	$\overline{\Delta P}^+$ (kW)	Cardinality
BH	2	11250
SH	10	11250
COM1	3	2250
COM2	107	2100
COM3	36	530
COM4	152	1667
COM5	70	953

We next divide the clients according to response probability: *LOW* (probability range 0.4 to 0.6), *MOD* (0.6 to 0.8), and *HIGH* (0.8 to 0.99). We assign a third of the clients to each

subset. To help the solver, each client has a different probability within the corresponding range. The cost of each request is defined by the response probability. A higher probability implies a better price for the client, so the cost will be higher, and we set the cost to 1 for *LOW*, 2 for *MOD*, and 3 for *HIGH*.

Finally, we divide the N clients into two categories, CAT_1 and CAT_2 , as discussed in Section C.3.2. Each subset has 50% of the clients. We set the maximal number of requests to 21 for CAT_1 and 7 for CAT_2 .

C.4.2 Clustering

The problem with 30,000 clients takes too long to solve, so we combine clients with similar characteristics. Let RA be the set of residential clusters and CA the set of commercial clusters. Let a be the level of clustering in the residential sector (i.e., a clients are clustered) and b be the level in the commercial sector. Figure C.5 illustrates the clustering of the clients in category 1 with basic homes and low probability. Each customer is represented by a square.

We now have $V < n_c$ clusters, and the aggregator can distribute the DR requests to the V clusters. To respect the probabilistic constraint, we must analyze the expected value and variance for each cluster i :

$$E[\Delta P_i^*] = \Delta P_i p_i \quad \forall i \in I \quad (C.60)$$

$$Var[\Delta P_i^*] = \frac{p_i(1-p_i)\Delta P_i^2}{a} \quad \forall i \in BH \cup SH \quad (C.61)$$

$$Var[\Delta P_i^*] = \frac{p_i(1-p_i)\Delta P_i^2}{b} \quad \forall i \in COM. \quad (C.62)$$

The DR capacity of a residential (commercial) cluster is the DR capacity of its clients multi-

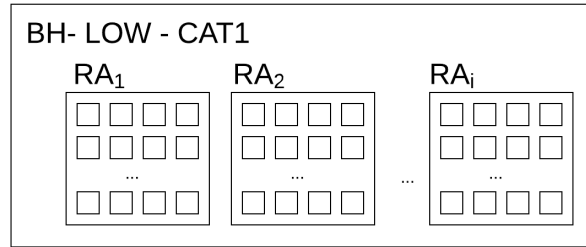


Figure C.5 Example of clustering for clients $i \in BH \cup LOW \cup CAT_1$.

plied by a (b). We assume that when a cluster receives a DR request, it is equally distributed among the clients of the cluster. This is illustrated in Figure C.6.

C.5 Results and Discussion

C.5.1 Load Prediction

We tested our model with real-world data. The total load consumptions of nine residential and commercial substations in Quebec were collected every hour from December 2005 to February 2006; the temperature and wind speed were also collected. In each case the nearest weather station was used.

For the SVM method, the best parameters found are $C = 300$, $\epsilon = 0.1$, and $\lambda = 5$. We use 20 folds to avoid overfitting. We use the data collected during the last week of February as the testing set, and the earlier data forms the training set. Figure C.7 shows the load profiles for the last week of February at substation 1.

As in [32], we compare the forecasting methods using the mean absolute percentage error (MAPE) and the normalized root mean squared error (NRMSE). Let the time series $S = \{s_1, s_2, \dots, s_n\}$ be the actual load consumption and let $\tilde{S} = \{\tilde{s}_1, \tilde{s}_2, \dots, \tilde{s}_n\}$ be the load prediction. The MAPE is

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{s_i - \tilde{s}_i}{s_i} \right| \quad (C.63)$$

and the NRMSE is

$$NRMSE = \sqrt{\frac{\sum_{i=1}^n (s_i - \tilde{s}_i)^2}{\sum_{i=1}^n s_i^2}}. \quad (C.64)$$

NRMSE is scale-independent and robust: all the values s_i must approach zero to make the NRMSE undefined. Table C.3 gives the MAPE and NRMSE values for each method and each substation, calculated for the last week of February.

Table C.3 Comparison of load prediction methods at each substation

	Method	S1	S2	S3	S4	S5	S6	S7	S8	S9
MAPE (%)	SVM	3.84	3.12	3.28	2.37	1.95	3.28	3.05	3.40	3.03
	NP	1.37	1.51	1.328	1.12	0.73	1.32	1.43	2.30	1.16
	ARX	3.92	3.05	3.29	2.34	2.17	3.69	2.93	3.37	2.70
NRMSE (%)	SVM	4.77	3.81	4.16	3.01	2.40	3.93	3.91	4.25	4.02
	NP	2.04	2.17	2.02	1.60	1.23	2.10	2.04	3.46	1.68
	ARX	4.94	3.80	4.09	3.21	2.87	4.72	3.64	4.42	3.54

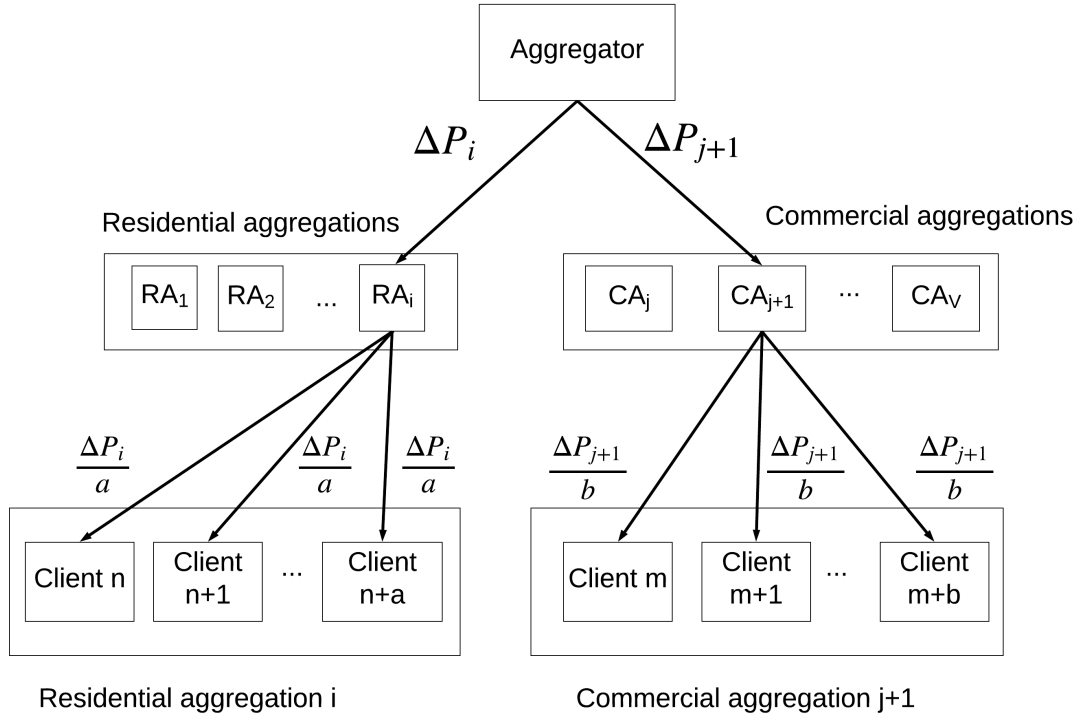


Figure C.6 Hierarchical structure of clustering.

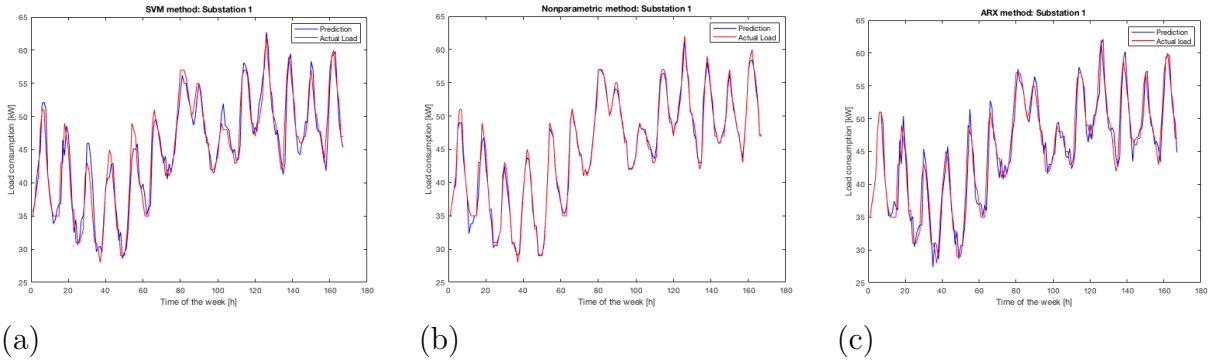


Figure C.7 Comparison of actual load collected during the last week of February at substation 1 and predicted load calculated by (a) SVM method, (b) nonparametric method, and (c) ARX method.

Figure C.8 shows the frequency distribution of the load consumption at substation 1 for the actual load and each method. The histograms show that the load consumption can be approximated by a normal distribution. We therefore introduce two further tests to compare the methods: they compare the distribution $\mathcal{N}(\mu_a, \sigma_a^2)$ of the actual load and the distribution $\mathcal{N}(\mu_j, \sigma_j^2)$, $j \in b, c, d$ of the three predicted loads.

The first test is the Student's t-test, which determines if the mean values of two data sets are significantly different. The null hypothesis is that the means are equal, and if the p-value of the test is below the threshold α_t , the null hypothesis is rejected. The variances are not assumed to be equal, and the data sets are assumed to be independent (see [33]). Under these hypotheses, the test is also called Welch's test. The T statistic for two independent data sets with unequal variance is

$$T = \frac{\overline{X_a} - \overline{X_j}}{s_{\Delta}^-} \quad \forall j \in \{b, c, d\} \quad (\text{C.65})$$

$$s_{\Delta}^- = \sqrt{\frac{s_a^2}{n_a} + \frac{s_j^2}{n_j}} \quad \forall j \in \{b, c, d\}. \quad (\text{C.66})$$

The test statistic can be approximated via a Student's t-distribution with the degrees of freedom (d.f.) calculated by the Welch–Satterthwaite equation:

$$d.f. = \frac{\left(\frac{s_a^2}{n_a} + \frac{s_j^2}{n_j}\right)^2}{\frac{(s_a^2/n_a)^2}{n_a-1} + \frac{(s_j^2/n_j)^2}{n_j-1}} \quad \forall j \in \{b, c, d\}. \quad (\text{C.67})$$

$\overline{X_a}$ is the observed mean value of the actual load, and $\overline{X_j}$ is the observed mean value of the predicted load calculated by each method; n_a and n_j are the number of loads observed, which

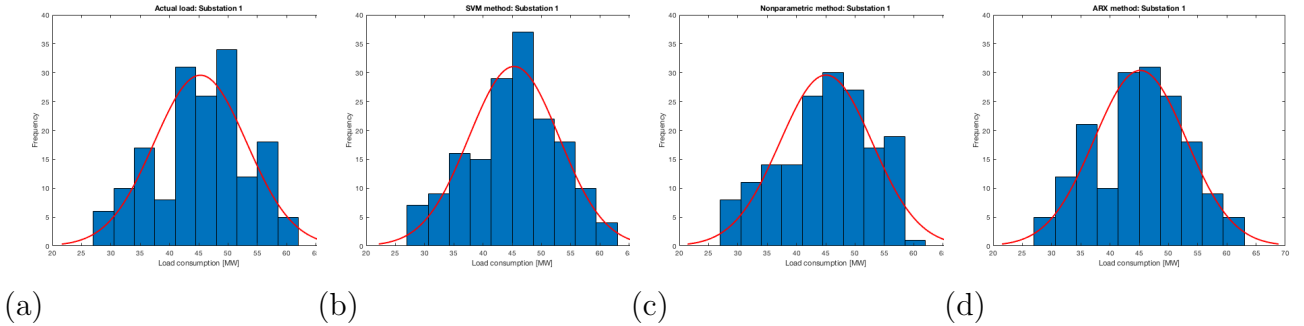


Figure C.8 Frequency distribution of load consumption of testing data at substation 1 using (a) actual load, (b) SVM method, (c) nonparametric method, and (d) ARX method.

are equal in this case; s_a^2 and s_j^2 are the unbiased estimators of the variance of the data sets. With the threshold $\alpha_t = 0.05$, the null hypothesis is not rejected for any method.

The second test is the Fisher F-test, which determines if the variances of two data sets are significantly different. The null hypothesis is that the variances are equal, and if the p-value of the test is below the threshold α_t , the null hypothesis is rejected. The F statistic can be calculated via

$$F = \frac{s_a^2}{s_j^2} \quad \forall j \in \{b, c, d\}. \quad (\text{C.68})$$

With the threshold $\alpha_t = 0.05$, the null hypothesis is not rejected for any method. Based on these results, we develop two statistical approaches. They use the data of December and January as the training set and evaluate the forecasting methods on each week of February.

Figure C.9 shows the frequency distribution of the load consumption at substation 1 using E intervals. We create a histogram for each substation for the four weeks of February. The first approach compares the frequency of each interval of the actual load consumption with those of the predicted loads. The number of bins for an interval represents the number of data points in that interval. This approach determines the difference between the number of bins for the actual load (n_a) and the number for the predicted load (n_j) for each interval z . We set $j = b$ for the SVM method, $j = c$ for the nonparametric method, and $j = d$ for the ARX method. We calculate the difference Δn_{jq} for each week (q) of February. A prediction is considered to be good if $n_{az} - n_{jz} < \rho$ where we use $\rho = 2$:

$$\delta_{jzq} = \begin{cases} n_{azv} - n_{jzq} & n_{azv} - n_{jzq} \geq \rho \\ 0 & \text{otherwise.} \end{cases} \quad (\text{C.69})$$

The total difference for one week is

$$\Delta n_{jq} = \sum_{z=1}^{E-1} \delta_{jzq} \quad \forall j \in \{b, c, d\}, \quad \forall q \in \{1, \dots, Q\}. \quad (\text{C.70})$$

The total number of incorrect predictions n_{wp} is

$$n_{wpj} = \sum_{q=1}^Q \Delta n_{jq} \quad \forall j \in \{b, c, d\}. \quad (\text{C.71})$$

The method with the fewest incorrect predictions is the most accurate. Table C.4 gives the results; the nonparametric method is preferred for every substation except substation 8, for which the ARX method is preferred.

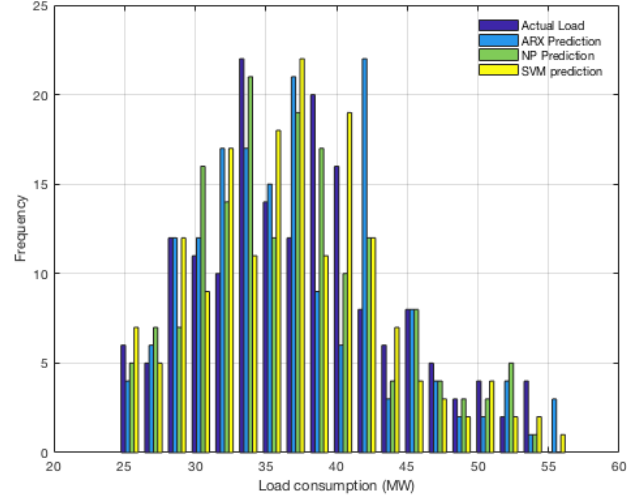


Figure C.9 Actual and predicted loads for first week of February at substation 1.

Table C.4 Number of incorrect predictions n_{wp} calculated for four weeks at the nine substations

Method	S1	S2	S3	S4	S5	S6	S7	S8	S9
SVM	202	305	164	172	118	190	226	371	219
NP	133	259	106	119	111	133	183	344	126
ARX	165	311	148	164	116	196	216	299	166

Table C.5 Total number of rejected loads n_{tot} calculated for four weeks at the nine substations

Method	S1	S2	S3	S4	S5	S6	S7	S8	S9
SVM	30	34	25	25	25	37	35	35	25
NP	25	38	31	27	18	26	35	15	30
ARX	34	31	38	37	32	42	42	25	36

The second approach is based on the normal distribution of the actual load, which can be expressed as $\mathcal{N}(\mu_a, \sigma_a^2)$. We consider a threshold $0 < \phi < 1$. With $\phi = 0.05$, we calculate the critical load (cl) for each week q :

$$cl_q = F_q^{-1}(\phi) \quad (C.72)$$

where F_q^{-1} is the inverse cumulative function of the normal distribution of the actual load for week q . The critical load is used to compare the three methods, given a time series $\tilde{S} = \{\tilde{s}_1, \tilde{s}_2, \dots, \tilde{s}_T\}$. Every prediction \tilde{s}_t that is above the critical load is rejected. The vector r represents the rejected load:

$$r_{jtq} = \begin{cases} 1 & \tilde{s}_{jtq} > cl_q \\ 0 & \text{otherwise.} \end{cases} \quad (C.73)$$

The number of rejected loads n_r for each week q is

$$n_{rjq} = \sum_{t=1}^T r_{jtq} \quad \forall j \in b, c, d \quad \forall q \in 1, \dots, Q. \quad (C.74)$$

The most accurate model is that with the minimum total number of rejected loads (n_{tot}) for the Q weeks:

$$n_{totj} = \sum_{q=1}^Q n_{rjq} \quad \forall j \in b, c, d. \quad (C.75)$$

Table C.5 presents the results of the second approach for the nine substations. The metrics and statistical approaches used to compare the methods show that the nonparametric method is best at all nine substations. The UR for each substation and each period is calculated with the forecast load consumption. Table C.6 shows the maximum and minimum U for each substation as well as the absolute mean (AM) of U . Substation 4 has the highest UR, and we use it to test the optimization model.

Table C.6 UR calculated by nonparametric method

β	U (kW)	S1	S2	S3	S4	S5	S6	S7	S8	S9
0.10	Max.	6170	3039	7266	16914	10973	8416	3935	3039	4246
	Min.	-5600	-2601	-7065	-15477	-10335	-8294	-3811	-2957	-4092
	AM	4675	2318	5896	13509	9443	6919	3152	2586	3602

Table C.7 Parameters for case studies

Case	c_i (\$/kW) $i \in LOW$	c_i (\$/kW) $i \in MOD$	c_i (\$/kW) $i \in HIGH$	n_{max}^i $i \in CAT_1$	n_{max}^i $i \in CAT_2$	Sector
Base case	1	2	3	21	7	<i>BH, SH, COM</i>
Case study 1	1	1.5	1.75	21	7	<i>BH, SH, COM</i>
Case study 2	1	2	3	1	1	<i>BH, SH, COM</i>
Case study 3	1	2	3	21	7	<i>SH, COM</i>

Table C.8 Results of case studies

Case	CPU Time (s)	Total cost (\$)
Base case	2	501,768
Case study 1	1	500,458
Case study 2	2	732,523
Case study 3	1 2	502,491

C.5.2 Optimal Clustering

We explored three case studies at substation 4 with the UR given in Table C.6 over one week. For all three case studies, we clustered the initial set of 30,000 clients with $a = 100$ and $b = 10$. The set of 30 000 clients is reduced to a set of 975 clusters, and we can find the optimal solution in less than 10s. We set $\alpha = 0.95$ and $\beta = 0.10$ for all the case studies. The parameters are listed in Table C.7.

Case Study 1

Figure C.10 shows that only the clients in the *LOW* category are used in the base case. The aggregator finds it cheaper to distribute more DR requests at a lower price than fewer DR requests at a higher price. As shown in Figure C.11, the cost per kW of reduction or increase in case study 1 is between 1.73 and 1.81 \$/kW when only the clients in *LOW* are used. The costs of *MOD* and *HIGH* are higher, so the aggregator has no interest in distributing DR requests to them.

Ultimately, the aggregator wants the clients to accept requests with a probability approaching 1, and so the aggregator must prioritize the *HIGH* category. Case study 1 analyzes the impact of the cost of the request on the category selected. The costs are listed in Table C.7, and the results are given in Figure C.10. The *HIGH* category is now requested. The overall weekly cost for case study 1 is \$501,768 and for case study 2 is \$500,458. The overall cost is not significantly different between the base case and case study 1, but the aggregator may want to prioritize the *HIGH* category to ensure grid stability.

Case Study 2

Figure C.11 presents the weekly cost per kW of reduction or increase for each case study. Case study 2 shows the limitation of the model: when a client has only one request per week, the cost varies from \$1.73 to more than \$3. As illustrated in Figure C.10, the distribution of the DR requests in case study 2 varies. The model uses the *LOW* category until it is no longer available, then the *MOD* category, and finally the *HIGH* category. To avoid this problem, we could develop a dynamic model that minimizes the total weekly cost. Decisions made early in the week would take into account the situation later in the week. This would require a medium-term forecasting method, since the UR has to be forecast for the whole week.

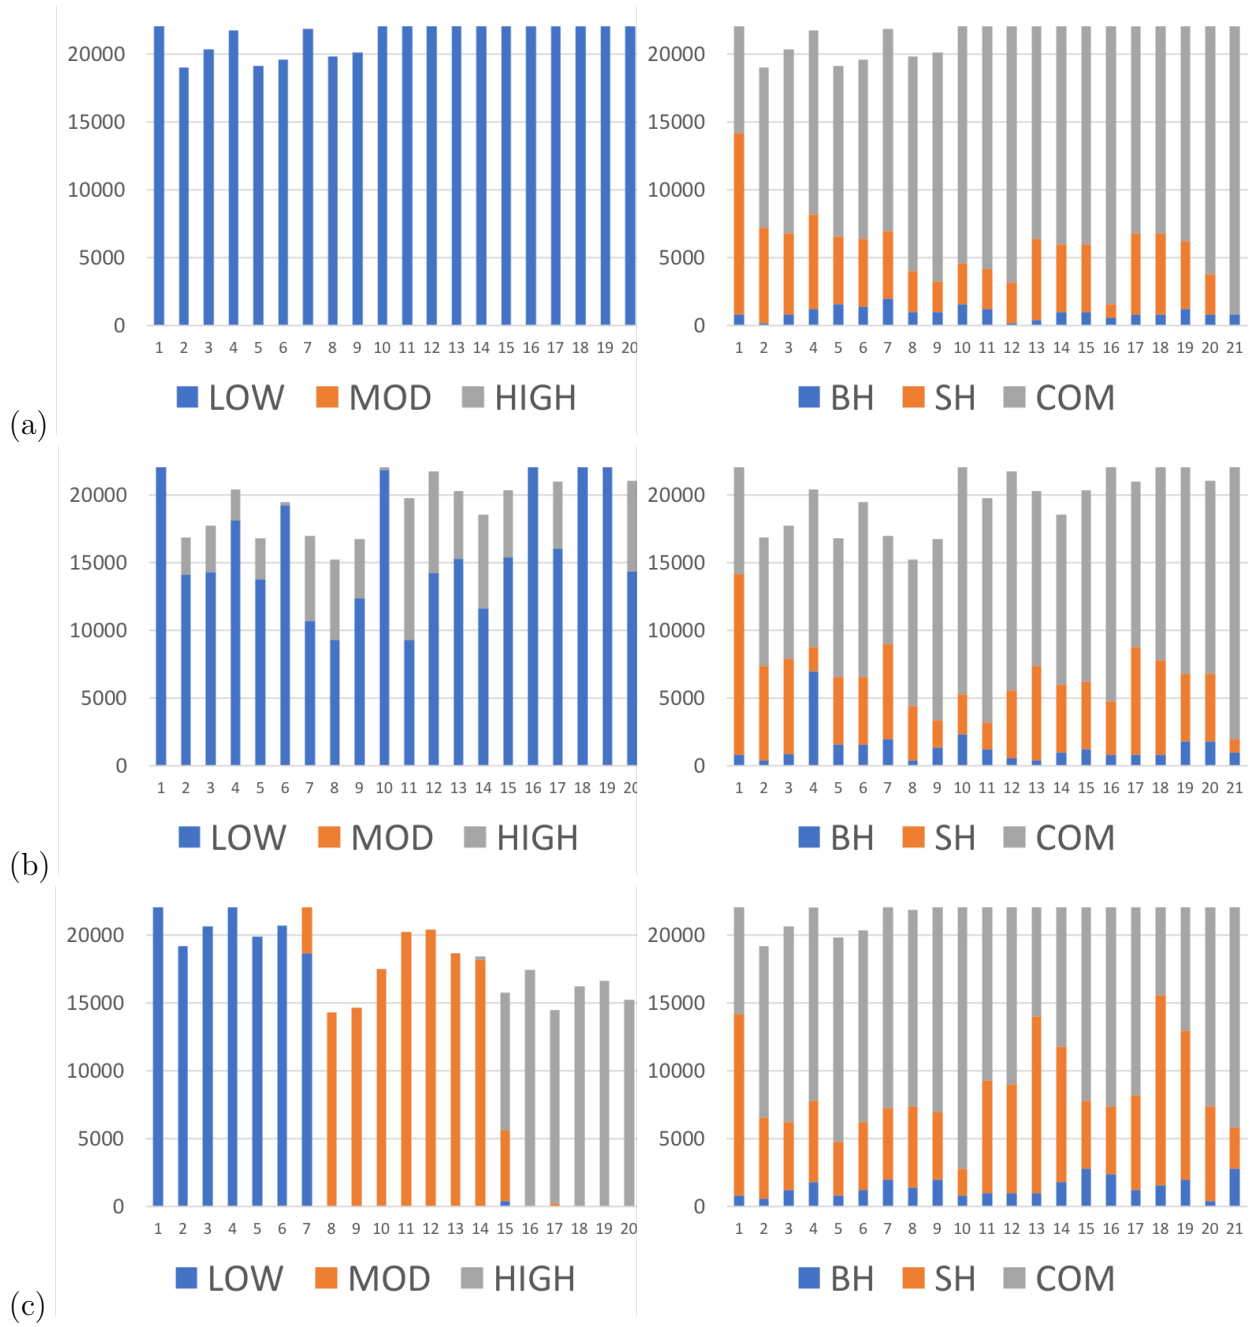


Figure C.10 Distribution of DR requests for each probability level and each sector in (a) Base case, (b) Case study 1, and (c) Case study 2.

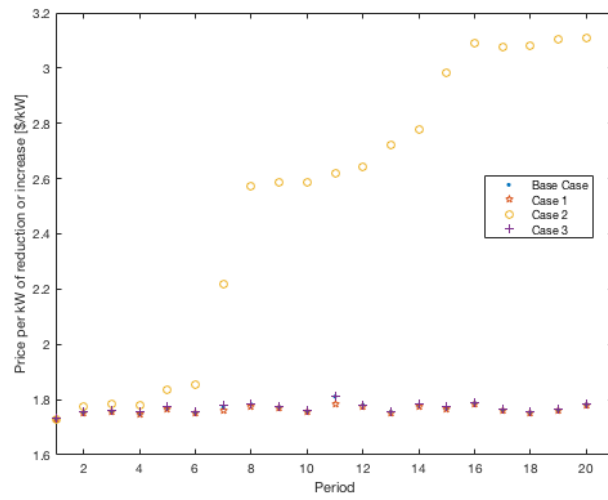


Figure C.11 Weekly cost per kW of reduction or increase (\$/kW).

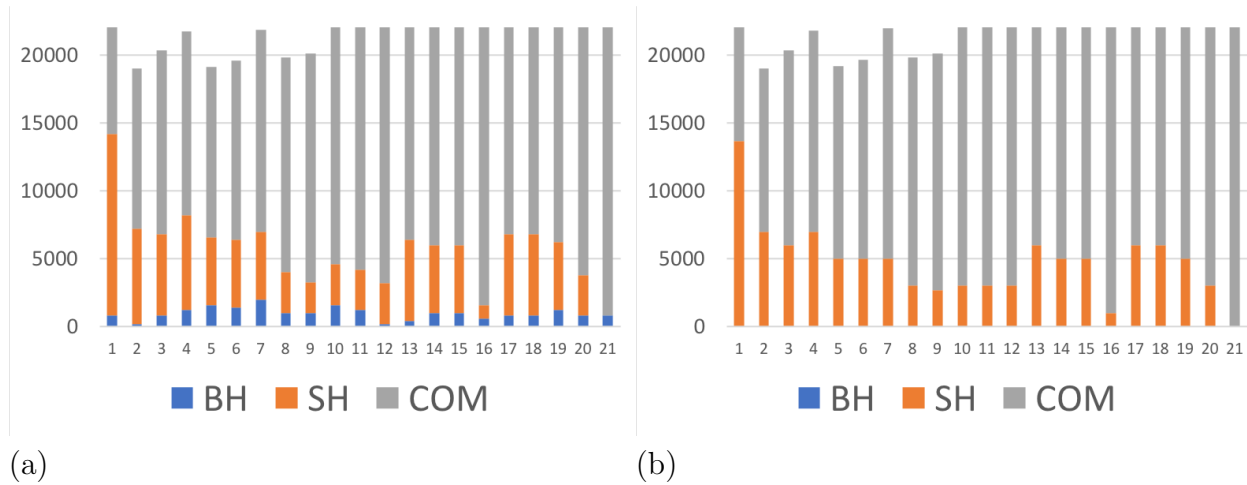


Figure C.12 Distribution of DR request for each sector in (a) Base case and (b) Case study 3.

Case Study 3

It is hard to convince customers with basic homes to participate in DR since they do not have smart equipment. Equipment must be installed: is it worthwhile to do so? Figure C.10 shows the utilization of the *BH* group in the optimal solution. In the third case study, we used the base case parameters and omitted *BH*. Figure C.12 shows that the *COM* and *SH* groups absorb the DR requests from *BH*. The overall cost for a week in the base case is \$501,768. Without *BH*, the overall cost is \$502,491, an increase of 0.41%. Equipment installation is therefore not worthwhile.

C.6 Conclusion

Aggregators can adapt the total load consumption to follow the available power while guaranteeing the stability of the grid. We have shown that the nonparametric method can help the aggregator to estimate the UR. The CCO formulation can guarantee the satisfaction of the UR with a specified level of confidence. We tested the approach using data from winter in Quebec, showing that the aggregator can satisfy the utility's DR requests.

C.7 Acknowledgement

This research was supported by the NSERC-Hydro-Québec-Schneider Electric Industrial Research Chair on Optimization for Smart Grids.