



Titre: Lissage optimal de la charge électrique en présence de sources d'énergies renouvelables via le pilotage de la consommation des chauffe-eau
Title:

Auteur: Adham Ismail Tammam
Author:

Date: 2016

Type: Mémoire ou thèse / Dissertation or Thesis

Référence: Tammam, A. I. (2016). Lissage optimal de la charge électrique en présence de sources d'énergies renouvelables via le pilotage de la consommation des chauffe-eau [Thèse de doctorat, École Polytechnique de Montréal]. PolyPublie.
Citation: <https://publications.polymtl.ca/2254/>

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

URL de PolyPublie: <https://publications.polymtl.ca/2254/>
PolyPublie URL:

Directeurs de recherche: Miguel F. Anjos, & Michel Gendreau
Advisors:

Programme: Génie industriel
Program:

UNIVERSITÉ DE MONTRÉAL

LISSAGE OPTIMAL DE LA CHARGE ÉLECTRIQUE EN PRÉSENCE DE SOURCES
D'ÉNERGIES RENOUVELABLES VIA LE PILOTAGE DE LA CONSOMMATION DES
CHAUFFE-EAU

ADHAM ISMAIL TAMMAM
DÉPARTEMENT DE MATHÉMATIQUES ET DE GÉNIE INDUSTRIEL
ÉCOLE POLYTECHNIQUE DE MONTRÉAL

THÈSE PRÉSENTÉE EN VUE DE L'OBTENTION
DU DIPLÔME DE PHILOSOPHIÆ DOCTOR
(GÉNIE INDUSTRIEL)
JUILLET 2016

UNIVERSITÉ DE MONTRÉAL

ÉCOLE POLYTECHNIQUE DE MONTRÉAL

Cette thèse intitulée :

LISSAGE OPTIMAL DE LA CHARGE ÉLECTRIQUE EN PRÉSENCE DE SOURCES
D'ÉNERGIES RENOUVELABLES VIA LE PILOTAGE DE LA CONSOMMATION DES
CHAUFFE-EAU

présentée par : TAMMAM Adham Ismail

en vue de l'obtention du diplôme de : Philosophiæ Doctor

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

M. FRAYRET Jean-Marc, Ph. D., président

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

M. GENDREAU Michel, Ph. D., membre et codirecteur de recherche

M. EL HALLAOUI Issmaïl, Ph. D., membre

M. KAMWA Innocent, Ph. D., membre externe

DÉDICACE

*À mes parents, à mon frère
et à mes amis . . .*

REMERCIEMENTS

Je tiens tout d'abord à remercier mon directeur de recherche, Miguel F. Anjos, et mon co-directeur, Michel Gendreau, pour le soutien qu'ils m'ont apporté, le temps qu'ils m'ont accordé malgré leurs responsabilités ainsi que la patience dont ils ont fait preuve tout au long de mon doctorat. Qu'ils trouvent ici l'expression de mon profond respect et de ma gratitude. J'exprime aussi mes remerciements à Roland P. Malhamé pour ses suggestions fructueuses et les échanges scientifiques que nous avons eus.

Un immense merci à Arman Kizilkale qui n'a ménagé aucun effort pour m'aider à mener cette thèse à terme. J'aimerais également remercier chaleureusement Mohamed Amine Hachani avec qui j'ai eu beaucoup de plaisir à travailler à la troisième partie de la thèse. Je remercie les membres du jury d'avoir accepté de faire partie de mon jury de thèse et de l'avoir enrichie par leurs commentaires pertinents.

Un grand merci à tous mes amis sans exception pour les moments inoubliables que j'ai partagés avec eux durant la période que j'ai passée au sein de l'École polytechnique de Montréal.

Je tiens également à remercier le personnel du GERAD, en particulier Francine Benoît, Pierre Girard et Edoh Liagros Logo pour l'aide quotidienne qu'ils apportent aux étudiants.

RÉSUMÉ

La lutte contre le réchauffement climatique arrive en tête des préoccupations actuelles de la communauté internationale. De nombreux mouvements politiques poussent les gouvernements des pays industrialisés à mettre en place des législations favorisant l'adoption d'énergies renouvelables et diminuant leur dépendance à des sources d'énergie issues des combustibles fossiles. Cette transition énergétique comporte des enjeux, entre autres, sur le plan de la gestion du réseau électrique en raison de l'intermittence des sources d'énergie renouvelables. Le développement des programmes de la gestion de la charge dans les *smart grid* permet aux opérateurs des réseaux électriques de contrôler des charges résidentielles dispersées sur l'ensemble du réseau de façon à atténuer l'intermittence de la production des sources d'énergie renouvelables. Le projet **smartDESC** répond à ce besoin en proposant une méthodologie innovatrice de gestion de la capacité de stockage d'énergie thermique des chauffe-eau résidentiels. Cette méthodologie est hiérarchique dans le sens où le contrôle de la charge des chauffe-eau se fait en deux phases. La première phase, dans laquelle s'inscrit cette thèse, consiste en une méthodologie de contrôle central d'un modèle agrégé d'une population de chauffe-eau de grande taille, tandis que la deuxième phase consiste en un ensemble de contrôleurs locaux qui contrôlent individuellement la consommation électrique des chauffe-eau. Ces contrôleurs locaux sont guidés par la politique optimale dictée par l'unité de calcul centrale.

Le contrôle central se fait au moyen d'un modèle d'optimisation qui calcule le profil de consommation électrique optimal des chauffe-eau à court terme, et ce, en tenant compte de l'incertitude de prévision de la production éolienne, qui est la source d'énergie renouvelable que nous traitons tout au long de cet ouvrage. Dans la première partie de la thèse, nous proposons une méthode de prévision de la production éolienne issue des prévisions d'ensemble que fournit *Environnement Canada*. Cette méthode consiste à projeter les prévisions d'ensemble calculées à très faible hauteur au-dessus du niveau du sol à la hauteur du moyeu des éoliennes au moyen d'un modèle de régression. Ce dernier a été entraîné sur des données fournies par notre partenaire industriel WPred. Cette méthode est efficace pour la représentation de l'erreur de prévision, rendant la prise de décision robuste face à l'incertitude de la production éolienne. Cette étape ouvre la voie à la deuxième partie, où nous présentons un modèle d'optimisation stochastique multi-étapes qui calcule le profil de consommation optimal d'un modèle agrégé de chauffe-eau à la lumière de ces prévisions de la production éolienne. Ce modèle est résolu sur un horizon de 24 heures en appliquant la technique de l'horizon glissant. Les résultats issues d'une simulation avec des données de prévisions sur 30 jours montrent que l'approche proposée permet de réaliser en moyenne une réduction quoti-

dienne de la fluctuation de la demande nette et de la pointe de charge dépassant 60% et 9% respectivement.

Étant donné que le modèle d'optimisation traite un modèle agrégé de chauffe-eau, la solution obtenue est parfois exigeante par rapport à la capacité réelle de stockage de chauffe-eau. La dernière partie de la thèse consiste donc à présenter la preuve de convergence d'un algorithme itératif qui corrige la solution issue de l'unité de calcul centrale selon la capacité de stockage que les contrôleurs locaux peuvent exploiter.

ABSTRACT

The impacts of global warming on the environment has led to constant efforts to reduce greenhouse gas emissions, mainly caused by burning fossil fuels for electricity generation. Thus, the emergence of renewable energy resources including wind power is strongly encouraged. This transition policy in energy generation comes at a price, as the intermittent nature of wind power raises new challenges for maintaining the balance between supply and demand. Demand side management programs are promising techniques to overcome those challenges. For example, those programs can be applied to compensate for wind power fluctuations by controlling the power consumption of thermostatically controlled loads such as electric water heaters, air conditioners, refrigerators, etc.

In order to mitigate the wind power variability and reduce the peak load, the project, **smart Distributed Energy Storage Controller (smartDESC)** proposes a hierarchical control architecture able to exploit the distributed thermal storage capacity of electric water heaters (EWHs) in households. The proposed control architecture is twofold. First, it involves a central unit that schedules the optimal power consumption for a large population of EWHs based on their aggregate dynamics. It computes a temporal power consumption profile that covers a short-range planning horizon and is robust against wind power uncertainty. The second phase consists of local control units guided by the optimal schedule. The local units control every EWH individually. This technique reduces the computational burden on the central unit since enforcement of security and comfort constraints becomes local.

The main focus in this dissertation is the first phase, mentioned above, which is to develop the central unit schedule. In this phase, the decision making process has to take into account the wind power prediction error, so as to produce power consumption profiles robust against wind power uncertainty. In the first part of the thesis, we propose a new methodology for generating ensemble wind power scenarios from numerical weather predictions (NWP) provided by *Environment Canada*. Such NWP are available at a lower height than the turbines hub height. Thus, we project the NWP to the turbines hub height by training a linear regression model using deterministic weather forecasts provided by our industrial partner WPred. The resulting weather predictions are used afterwards to generate wind power production scenarios for wind farm in Quebec.

The results show that the proposed method produces scenarios that represent well the forecast error for the short term. These results pave the way to model the power scheduling problem in a form of a multistage stochastic program as shown in the second part of the thesis. This

model is responsible for computing the optimal power consumption profile for an aggregate model of EWHs over a planning horizon of 24 hours. Simulation results conducted within **smartDESC** platform with data over one month show the capability of the proposed model to achieve up to 9% of mean daily peak load shaving and 60% of mean fluctuation reduction of the net demand.

The storage capacity of individual EWHs could be overestimated by the central unit schedule. This is because the optimization model considers the aggregate behavior of the EWH population. Thus, a sub-unit identifies the time slots where the target profile is unreachable by the local controllers, and computes bounds over the power that can be injected into the system. The optimization model computes a new temporal optimal consumption profile while considering the new bounds. This mechanism continues until it converges towards a feasible profile to the local controllers. The last part of the thesis presents the proof of convergence of this iterative algorithm.

TABLE DES MATIÈRES

DÉDICACE	iii
REMERCIEMENTS	iv
RÉSUMÉ	v
ABSTRACT	vii
TABLE DES MATIÈRES	ix
LISTE DES TABLEAUX	xii
LISTE DES FIGURES	xiii
LISTE DES SIGLES ET ABRÉVIATIONS	xiv
GLOSSAIRE	xv
CHAPITRE 1 INTRODUCTION	1
1.1 Généralités	1
1.2 Gestion de la charge électrique des moyens de stockage d'énergie	2
1.3 SmartDESC	3
1.4 Contenu de la thèse	5
CHAPITRE 2 REVUE DE LITTÉRATURE	7
2.1 Méthodes déterministes	8
2.1.1 Programmation dynamique	8
2.1.2 Programmation linéaire	10
2.1.3 Logique floue	12
2.1.4 Gestion de la charge et services auxiliaires	12
2.1.5 Réduction des pertes du système de distribution d'alimentation	13
2.2 Prévion des conditions météorologiques	14
2.3 Incertitude de la production des sources d'énergies renouvelables	15
2.3.1 Programmation dynamique stochastique	15
2.3.2 Programmation stochastique avec recours	16

CHAPITRE 3	ORGANISATION DE LA THÈSE	19
CHAPITRE 4	ARTICLE 1 : A METHODOLOGY FOR ENSEMBLE WIND POWER SCENARIOS GENERATION FROM NUMERICAL WEATHER PREDICTIONS	21
4.1	Introduction	21
4.2	Wind Speed Scenarios	22
4.3	Wind Power Predictions	23
4.4	Evaluation of the uncertainty estimation	25
4.5	Conclusion and Future work	27
CHAPITRE 5	ARTICLE 2 : BALANCING SUPPLY AND DEMAND IN THE PRE- SENCE OF RENEWABLE GENERATION VIA DEMAND RESPONSE FOR ELEC- TRIC WATER HEATERS	31
5.1	Abstract	31
5.2	Introduction	31
5.3	Aggregate model of EWHs	33
5.4	Stochastic model (Scheduler)	36
5.4.1	Mathematical model	37
5.5	Scenario generation	39
5.6	Case study and Results	39
5.6.1	Results	40
5.7	Conclusion	41
5.8	Acknowledgements	41
CHAPITRE 6	CONVERGENCE VERS UN PROFIL DE TEMPÉRATURE DE CONSIGNE RÉALISABLE POUR LE CONTRÔLEUR À CHAMP MOYEN	50
6.1	Introduction	50
6.2	Modèle déterministe	51
6.3	Correction du profil de température de consigne	52
6.4	Preuve de convergence	55
6.5	Résultats numériques	59
CHAPITRE 7	DISCUSSION GÉNÉRALE	62
7.1	Synthèse des travaux	62
7.2	Limitations de la solution proposée et améliorations futures	63
CHAPITRE 8	CONCLUSION ET RECOMMANDATIONS	66

RÉFÉRENCES	67
----------------------	----

LISTE DES TABLEAUX

Table 4.1	Error Measures of wind speed deterministic forecast [m/s]	24
Table 4.2	Comparison between different regression models	26
Table 5.1	Comparison between 3 cases of wind blow for 10% and 20% of wind power penetration during 3 days	42

LISTE DES FIGURES

Figure 1.1	Transition énergétique	1
Figure 1.2	Architecture de SmartDESC (Kizilkale et al., 2016)	6
Figure 2.1	Prévision d'ensemble (voir Pinson, 2006)	15
Figure 2.2	Arbre de peigne	17
Figure 4.1	Power curves	25
Figure 4.2	Linear Regression	26
Figure 4.3	Set Scenarios	27
Figure 4.4	Corrected Scenarios	28
Figure 4.5	Estimate of the standard deviation	29
Figure 4.6	Wind power scenarios	30
Figure 4.7	Uncertainty representation of wind speed	30
Figure 5.1	Population distribution near the lower bound	43
Figure 5.2	Population distribution near the upper bound	43
Figure 5.3	Population distribution at the middle of the comfort zone	43
Figure 5.4	Simulated bounds	44
Figure 5.5	Linear regression for the upper bound	44
Figure 5.6	Quadratic regression for the lower bound	45
Figure 5.7	Three-stage scenario tree	45
Figure 5.8	Case study with minimum wind power	46
Figure 5.9	Case study with average wind power	46
Figure 5.10	Case study with maximum wind power	47
Figure 5.11	Load shaving with low wind power	47
Figure 5.12	Load shaving with average wind power	48
Figure 5.13	Load shaving with high wind power	48
Figure 5.14	Reduction of Daily Fluctuation versus Wind Penetration	49
Figure 5.15	Mean Daily Peak Reduction versus Wind Penetration	49
Figure 6.1	Résultats déterministes (voir Kizilkale et al., 2016)	53
Figure 6.2	Profil de consigne inatteignable après la 1 ^{ère} itération (voir Losseau, 2016)	60
Figure 6.3	Bornes sup et inf sur la puissance après la 1 ^{ère} itération	60
Figure 6.4	Profil de consigne atteignable après la 2 ^{ème} itération (voir Losseau, 2016)	61
Figure 6.5	Lissages de la demande nette à chaque itération (voir Losseau, 2016)	61

LISTE DES SIGLES ET ABRÉVIATIONS

ARCH	Autoregressive conditional heteroskedasticity
ARIMA	Autoregressive integrated moving average
MAE	Mean absolute error
ME	Mean error
RMSE	Root mean square error

GLOSSAIRE


Charge	Demande électrique (MW)
Délestage	Suppression instantanée du courant électrique
Prévision déterministe	Prévision des conditions météorologiques reposant sur des modèles numériques de prévision du temps et un état initial de l'atmosphère. Elle fournit un seul scénario de l'évolution de l'état de l'atmosphère
Gestion de la charge (la demande)	Technique utilisée par les opérateurs de réseaux électriques leur permettant de changer le profil de demande électrique du côté client
Charge de reprise	Demande de puissance exercée par un dispositif après une coupure de courant pour retrouver son état
Schedular	Modèle d'optimisation stochastique présenté dans le chapitre 5
Profil de température de consigne	Courbe horaire constante par morceaux qui représente la température moyenne à atteindre par la population de chauffe-eau
Profil de consommation moyenne	Courbe horaire constante par morceaux calculée par le programme d'optimisation et qui représente la consommation électrique moyenne du modèle agrégé de chauffe-eau

CHAPITRE 1 INTRODUCTION

1.1 Généralités

L'importance de l'énergie tirée des ressources renouvelables (EnR), de type éolien et solaire, est en progression et leur taux de pénétration dans les réseaux électriques dits intelligents (*smart grid*) augmente chaque année en raison de plusieurs facteurs. En premier lieu, la hausse perpétuelle de la demande, notamment en raison de l'accroissement de la population et du développement économique. En second lieu, les engagements pris par de nombreux gouvernements d'adopter une politique de transition énergétique occasionnant une augmentation de la dépendance de leur approvisionnement électrique aux EnR, dans le but de réduire les émissions de gaz à effet de serre et de limiter les conséquences dévastatrices du changement climatique sur l'environnement. La Figure 1.1¹ illustre cette transition énergétique au Canada, où l'on constate une baisse remarquable de la capacité de production allouée aux sources à base de pétrole et de charbon, et une montée de la participation prévue des sources éoliennes et de l'énergie solaire.

Capacité de production 2012



Capacité de production 2035




Figure 1.1 Transition énergétique

Cette transition énergétique présente des défis, car ces sources d'énergie renouvelables sont

1. Source : Office national de l'énergie (Canada)

intrinsèquement *variables*, et la puissance qu'elles génèrent ne peut être contrôlée car elle est soumise à l'*incertitude* des conditions météorologiques. Ces caractéristiques limitent ainsi la capacité d'EnR que le réseau est capable de traiter, d'autant plus que les opérateurs des réseaux électriques s'engagent à maintenir en permanence et en temps réel l'équilibre entre la production et la demande afin d'éviter les risques de coupures électriques, et ce, sous des contraintes opérationnelles au niveau de la génération, notamment les rampes de démarrage, les durées minimales de fonctionnement, etc. Ces limites s'imposent pour plusieurs raisons ; la première étant que la nature intermittente des EnR augmente l'incertitude au niveau de la production, et même s'il existe une prévision parfaite de la production des sources renouvelables, leur variabilité demeure problématique du fait qu'elle échappe à tout contrôle de l'homme. Cela amène les opérateurs à prendre des mesures pour contrebalancer cette intermittence, par l'augmentation de la réserve tournante sur le réseau, dont le coût marginal de production est élevé (Papavasiliou, 2011). L'effet des changements dans l'allocation des unités de production en réponse aux variabilités brusques dans la production des EnR est non négligeable, car éteindre et allumer fréquemment des unités de production pourrait accélérer l'usure des machines. Finalement, l'énergie éolienne est parfois inversement corrélée à la demande ; ainsi, elle pourrait parfois être mise au rebut malgré son abondance (voir Loutan and Hawkins, 2007).

1.2 Gestion de la charge électrique des moyens de stockage d'énergie

Munir les *smart grid* de moyens de stockage d'énergie devient donc inévitable, et ce, afin d'absorber la variabilité dans la production des EnR et de lisser la courbe de charge, ce qui réduit les risques de coupures électriques. Avec une anticipation de la demande future, ces capacités de stockage seront capables d'absorber l'excès de production en cas de faible demande puis de l'acheminer en cas de forte consommation. L'exploitation des capacités de stockage thermique des chauffe-eau dans les programmes de gestion de la demande s'avère un moyen intéressant, car ces dispositifs sont déjà dispersés avec abondance sur l'ensemble du réseau électrique, ce qui fait qu'à grande échelle, des petites contributions par dispositif pourraient apporter un gain significatif au niveau de l'atténuation de la variabilité du vent et la réduction de la charge de pointe.

Par contre, gérer la demande d'un grand nombre de chauffe-eau comporte de nombreux défis. Premièrement, ces charges sont naturellement diversifiées, c'est-à-dire que leurs cycles marche-arrêt ne sont pas forcément simultanés, ils dépendent du comportement quotidien de chaque individu. Une politique de contrôle de la demande qui ne maintient pas la diversité de charge peut affecter négativement le confort des clients et entraîner des pics de puissance

importants durant la reprise de la charge. En plus, contrairement aux batteries rechargeables, l'énergie stockée dans les chauffe-eau ne peut être ni extraite et directement répartie sur le réseau, ni même délibérément vidée par le gestionnaire de charge, car le processus d'extraction de l'énergie du réservoir du chauffe-eau est soumis au comportement incertain de l'utilisateur, soit la consommation d'eau chaude qui est un processus stochastique.

En outre, gérer la demande des chauffe-eau de façon optimale, en tenant compte de l'incertitude dans la production électrique occasionnée par les EnR exige des méthodes d'optimisation adaptées à la stochasticité des paramètres du problème d'optimisation. La complexité de résolution de ces modèles est sensible, entre autres, au nombre de chauffe-eau qui participent aux programmes de gestion de charge, car plus le nombre de dispositifs sous contrôle est élevé, plus la taille du problème d'optimisation augmente, ce qui rend difficile la résolution d'un tel problème.

1.3 SmartDESC

Le projet **smartDESC**, *smart distributed energy storage controller*, présenté dans Kizilkale et al. (2016) tente de relever les défis mentionnés ci-dessus, et ce, en mettant en œuvre un système de contrôle hiérarchique capable de gérer la charge des chauffe-eau répartis sur le réseau électrique afin d'atténuer l'intermittence de la production éolienne. Ce projet multidisciplinaire regroupait dix-huit personnes – professeurs, chercheurs, étudiants de doctorat et de maîtrise – issus de différents domaines (génie électrique, systèmes de contrôle, recherche opérationnelle, télécommunication, programmation, etc.). En plus, trois entreprises partenaires ont collaboré avec l'équipe de projet en fournissant des données précieuses sur l'historique de la charge électrique, la prévision de la charge électrique, la prévision de la production éolienne pour différents endroits au Québec. Ces partenaires sont la Coopérative Régionale d'Électricité de Saint-Jean-Baptiste de Rouville, Artelys et WPred. La Figure 1.2 illustre l'architecture de **smartDESC**, qui est composée essentiellement de trois modules, dont le premier est l'**unité de calcul centrale** responsable du traitement des données de prévision de la vitesse du vent pour générer des scénarios de la production éolienne. Ces derniers sont ensuite utilisés par un programme d'optimisation stochastique, présenté dans la section 5.4, qui calcule le profil optimal de la consommation moyenne des chauffe-eau. Ce profil de consommation moyenne est ensuite traduit en un profil de température de consigne moyenne pour le groupe de chauffe-eau. Ce profil est calculé sur un horizon de temps de 24 heures selon un modèle mathématique qui décrit le comportement agrégé des chauffe-eau. Le deuxième module est la couche de **communication** responsable de transmettre le profil optimal de température de consigne de l'unité centrale vers la population de chauffe-eau et de renvoyer

au fur et à mesure à l'unité centrale des mises à jour portant sur l'état moyen actuel des chauffe-eau. Finalement, le **contrôleur local** est un module associé à chacun des membres de la population de chauffe-eau. Ce module est responsable de contrôler individuellement les chauffe-eau (c.e.) par la commande à champ moyen. Chaque contrôleur local i reçoit le profil optimal de température de consigne et, en fonction de l'état actuel du chauffe-eau calculé par l'observateur d'état (obs), il calcule la règle de commande optimale u_j^i menant la température actuelle du chauffe-eau à y_t^i , de sorte que la moyenne de la température local du chauffe-eau atteigne le profil de consigne calculé par l'unité centrale (voir Kizilkale and Malhamé, 2013; Kizilkale and Malhame, 2014; Kizilkale et al., 2016).

Le module de *Traitement des prévisions météo* vise à produire un nombre fini de scénarios de la production éolienne et de la charge représentant le mieux possible l'incertitude de ces deux composantes, et ce, afin que le profil optimal calculé par le programme d'optimisation stochastique soit robuste face à leur l'intermittence. Pour ce faire, nous nous servons de la prévision d'ensemble provenant d'*Environnement Canada*. Une prévision d'ensemble est une prévision probabiliste qui reflète l'incertitude dans l'état futur de l'atmosphère. Elle est constituée d'un faisceau de scénarios de prévision numérique du temps. Chaque scénario diffère des autres par de légères perturbations de ces conditions initiales de prévision et de paramétrage des modèles physiques de la dynamique de l'atmosphère. Cette prévision d'ensemble étant calculée à une altitude de 10 mètres au-dessus du niveau du sol, nous avons dû ajuster cette prévision d'ensemble en la projetant à la hauteur du moyeu des éoliennes à partir des prévisions déterministes de la vitesse du vent à la hauteur du moyeu que nous a fournies le partenaire industriel WPred. Nous avons ensuite utilisé cette prévision d'ensemble pour en déduire des scénarios de production électrique pour des parcs éoliens situés dans la province du Québec au Canada. Ce travail de collaboration avec WPred constitue une nouvelle étude qui n'existe pas à notre connaissance dans la littérature. De plus, un modèle de prévision de la charge nous a été fourni par Artelys, notre second partenaire industriel. Ce modèle a été entraîné à partir des données *SCADA* provenant de la Coopérative Régionale d'Électricité de Saint-Jean-Baptiste de Rouville (CoopSJB). Ce modèle prend en entrée la prévision du vent et de la température et calcule en sortie la prévision de la charge. Le but final du module de *Traitement des prévisions météo* est de générer un ensemble de scénarios dont chaque élément est constitué de deux valeurs, la production éolienne et la charge électrique, issues de la même prévision météorologique pour garder la corrélation entre ces deux composantes.

La contribution majeure de cette thèse consiste en un modèle d'optimisation stochastique multi-étapes (*Scheduler*) qui planifie la consommation électrique d'un modèle agrégé de chauffe-eau en tenant compte de l'aspect incertain de charge et de la production éolienne

au moyen des scénarios générés par le module de *Traitement des prévisions météo*. À notre connaissance, très peu d'études ont été effectuées sur le problème de gestion de la charge de chauffe-eau en tenant compte de l'aspect incertain des EnR et aucune parmi elles n'aborde ce problème dans le contexte d'une plateforme de contrôle hiérarchique.

1.4 Contenu de la thèse

La présente thèse est constituée de trois volets principaux. Dans le chapitre 2, nous ferons la revue de littérature critique du problème de gestion de la demande de chauffe-eau. Puis, les chapitres 4 à 6 formeront le cœur de cette thèse. Le chapitre 4 correspond à un article accepté dans une conférence internationale qui présente le traitement des données de la prévision d'ensemble. Le chapitre 5 est un article soumis à une revue scientifique qui présente le modèle d'optimisation stochastique multi-étapes calculant le profil optimal de température de consigne. Considérant que l'unité de calcul centrale résout le problème d'optimisation sous les contraintes d'un modèle agrégé qui reflète le comportement moyen de la population de chauffe-eau, une surestimation de leur capacité d'agir face à la variation de demande nette survient parfois sous forme de valeurs de consignes qui ne sont pas toujours atteignables par le contrôleur local. Une preuve de convergence vers un profil de température de consigne atteignable est ensuite présentée dans le chapitre 6. Finalement, le chapitre 8 conclut la thèse.




Figure 1.2 Architecture de SmartDESC (Kizilkale et al., 2016)

CHAPITRE 2 REVUE DE LITTÉRATURE

Les programmes de gestion de la demande sont souvent classés dans la littérature en deux catégories principales. La première est appelée *Price Based Demand Response*. Dans celle-ci, le prix de l'électricité change durant la journée en fonction des heures de pointe et des heures creuses, ou d'une tarification en fonction de l'heure de consommation (p. ex. un tarif en soirée moins cher que le tarif durant la journée), ou encore d'une tarification variable en temps réel en fonction de la demande actuelle et de la production disponible, ce qui amène l'utilisateur à réagir à ces prix de façon rationnelle en décalant la consommation de certaines charges électriques vers les périodes à bas prix afin d'éviter les périodes à hauts tarifs. La deuxième catégorie de programmes est appelée *Incentive Based Demand Response*. Ici, l'utilisateur accepte de donner à l'opérateur le contrôle de certaines de ses charges résidentielles en échange d'une prime de participation au programme ou de récompenses sous forme de crédits sur les factures d'électricité ou encore de rabais sur les prix de facturation.

Les articles (Albadi et al., 2008; Strbac, 2008; Balijepalli et al., 2011; Aghaei et al., 2013; Siano, 2014) présentent des revues détaillées des différents programmes de gestion de la charge ainsi que de leurs divers bénéfices potentiels, notamment en ce qui concerne les aspects suivants :

- transmission et distribution, où la gestion de la congestion est améliorée et les délestages électriques sont minimisés ;
- utilisateur, où la facture d'électricité est réduite dans le contexte d'un marché d'électricité à prix variable ou par les primes offertes par l'opérateur pour récompenser l'utilisateur de sa collaboration au programme de gestion de la demande ;
- génération de l'électricité, où de tels programme contribuent
 - à la réduction des pics de charge durant les heures de pointe,
 - au maintien de l'équilibre entre la production et la consommation électrique,
 - à l'augmentation de la capacité de pénétration des sources d'énergie renouvelables.

Le but de ce chapitre est d'exposer les différentes approches proposées dans la littérature qui se sont attaquées au problème de gestion directe des charges électriques, surtout celles contrôlées par thermostat comme les chauffe-eau résidentiels. Nous commençons par une revue des méthodes déterministes, puis nous passons aux méthodes qui prennent en compte l'incertitude dans la production des sources d'énergie renouvelables.

2.1 Méthodes déterministes

2.1.1 Programmation dynamique

Un grand nombre de modèles d'optimisation traitant le problème de gestion de la charge qui existent dans la littérature utilisent la technique de la programmation dynamique.

Un projet de gestion de la charge par la gestion de la capacité de stockage d'énergie des chauffe-eau résidentiels a été mené par Wisconsin Electric à la fin des années 1970. Une étude de ce projet a été présentée dans Bischke and Sella (1985). Cette étude indique que construire de nouvelles centrales électriques n'est pas toujours la meilleure solution pour répondre à la croissance continue de la charge, d'où le besoin d'une gestion intelligente de celle-ci afin d'exploiter le réseau d'une manière plus efficace. Un modèle de contrôle direct des chauffe-eau est adopté, contrairement à d'autres modèles de contrôle indirect qui encouragent les consommateurs à diminuer leur consommation d'énergie en leur proposant des taux réduits de facturation. Ce contrôle se fait à travers un système de communication bilatéral entre le gestionnaire de charge et les chauffe-eau : des signaux de contrôle sont envoyés aux chauffe-eau pour les éteindre. Les chauffe-eau redémarrent après $15 \text{ min} \pm 3 \text{ min}$ en cas d'absence d'un nouveau signal de contrôle.

Une prévision de la charge de 2 heures en avance, par pas de 5 minutes, est effectuée à travers une version discrète d'un *filtre de Kalman*. Un *filtre de Kalman* est un ensemble d'équations mathématiques qui fournissent un moyen récursif pour estimer l'état d'un processus à partir des mesures brouillées, de façon à minimiser le carré de l'erreur (Welch and Bishop, 2006). Ici, des données de la charge recueillies différents jours de tous les mois sont utilisées afin d'avoir une prévision robuste face aux changements de la demande durant les différentes saisons.

La technique utilisée est la programmation dynamique par chaînage avant. Dans ce modèle, les auteurs prennent en compte l'effet de la charge de reprise. La valeur de celle-ci dépend de la distribution de la demande diversifiée pendant la journée et elle augmente exponentiellement selon la durée de délestage. Cette charge de reprise diminue également de façon exponentielle avec le temps (Hastings, 1980). Leur étude montre qu'on réduit la valeur de la charge de reprise en divisant la population de chauffe-eau en groupes ; les chauffe-eau du même groupe reçoivent les mêmes contrôles en maintenant un *off-time* égal pour chacun des groupes.

Leur modèle a réussi à réduire la capacité de charge de $0,7 \text{ kW}$ /chauffe-eau pendant les heures de pointe en été et de 1 kW /chauffe-eau en périodes de pointe hivernale.

Kuliasha (1980) propose une autre méthode d'optimisation dérivée de l'optimisation dynamique standard pour résoudre le problème de gestion de la charge, appelée *Gradient Dynamic*

Programming. Cette méthode fonctionne comme suit :

Soit $U(x)$ le domaine de décisions pour un état x quelconque

1. La première itération de l'algorithme commence par un sous-ensemble de décisions $U^0(x) \in U(x)$.
2. Le problème est résolu avec la programmation dynamique standard, une politique optimale π^0 est calculée.
3. Un nouveau domaine de décision, noté $U^1(x)$, est calculé selon la politique optimale π^0 . Ce domaine considère les $u \in \pi^0$ ainsi que les décisions proches de π^0 , de façon à améliorer la solution.
4. Le problème est résolu encore une fois avec la programmation dynamique standard et l'algorithme procède ainsi jusqu'à ce que la variation de la valeur de la fonction objectif soit inférieure à un certain seuil prédéterminé.

La méthode met à jour le domaine de décision à explorer de façon à améliorer la valeur de la fonction objectif, ce que visent les méthodes de gradient qui prennent des pas dans la direction de descente de la fonction, d'où le nom de la méthode. L'avantage de ce modèle est que la longueur de la période de contrôle du chauffe-eau est déterminée par le programme. Par contre, les contraintes de la durée maximum d'arrêt (*off-time*) du chauffe-eau ainsi que la durée minimum entre deux intervalles d'arrêt ne sont pas prises en compte. Le modèle réussit à réduire le coût de production de 74\$/chauffe-eau durant l'hiver quand la charge totale des chauffe-eau connectés au réseau est de 500 MW.

L'approche présentée dans Cohen et al. (1988) vise à minimiser les pointes de charge en prenant en considération les contraintes de temps maximum d'arrêt et le temps minimum entre deux intervalles d'arrêt du chauffe-eau. Pour modéliser le problème sous forme d'un programme dynamique standard, la charge ainsi que le nombre d'unités de temps pendant lesquelles le chauffe-eau est activé/désactivé formeront les états. On se retrouve ainsi avec un nombre énorme d'états, un phénomène qu'on appelle la *malédiction de la dimension* et qui augmente de façon exponentielle le temps de résolution du problème (Bertsekas, 2007).

L'approche de la programmation dynamique vers l'avant est utilisée pour permettre l'intégration implicite des contraintes de temps maximum d'arrêt du chauffe-eau et de temps minimum entre deux arrêts dans la formulation du problème et diminuer ainsi la taille de l'espace d'états. Cette technique fait en sorte que le nombre d'étapes où le chauffe-eau a été activé/désactivé sera retenu jusqu'à l'étape k et que seules les transitions qui ne violent pas les contraintes seront permises à l'étape $k + 1$. Leur modèle réussit dans certains cas de figure à réduire les pointes de 622 *MWh* à 595 *MWh*.

La gestion de la charge d'un système électrique hybride composé d'une source d'énergie éolienne et d'une batterie reliées au réseau est présentée dans Zhang and Li (2013). En raison de la dynamique lente des batteries (leurs cycles charge/décharge demandent beaucoup de temps), la planification de sa charge à court terme pourrait être sous-optimale. Une planification à long terme s'avère donc plus bénéfique. Comme la prévision de la production éolienne ainsi que les prix d'électricité sont plus précis à court terme, la méthode d'optimisation utilisée est la programmation dynamique en deux phases.

L'objectif est de maximiser le profit issu de la différence entre le prix de vente de l'éolien, le prix de vente de l'énergie stockée dans la batterie au réseau et le coût d'achat de l'électricité à partir du réseau pour charger la batterie. En premier lieu, une planification du niveau de charge (NDC) de la batterie est effectuée selon une prévision à long terme (une prévision horaire sur un horizon de 24 heures) fondée sur les prix par heure de l'électricité ainsi que sur la puissance de l'énergie éolienne. Ensuite, l'horizon est divisé en créneaux de durée plus courte. Une prévision à court terme est effectuée au début de chaque créneau qui donne des informations plus précises sur les prix et la production éolienne. Une nouvelle planification est calculée selon cette prévision, et on se sert de la planification à long terme de NDC comme d'une trajectoire de référence que le modèle à court terme vise à atteindre à la fin de chaque créneau.

2.1.2 Programmation linéaire

Nous trouvons également d'autres approches de gestion de la charge de chauffe-eau qui font appel à la programmation linéaire en faisant l'hypothèse que le nombre de scénarios admissibles d'interruptions de charge des chauffe-eau est fini. Un scénario d'interruption est une série prédéfinie de contrôles qui respecte certains critères tels que le confort du client et les contraintes opérationnelles du dispositif. Le critère de confort consiste à garder la température d'eau chaude dans le réservoir du chauffe-eau entre deux bornes, une borne maximum pour la sécurité de l'utilisateur et une borne minimum pour maintenir le confort du client et empêcher la contamination bactérienne, en particulier la *legionella pneumophila* qui est souvent présente dans les eaux douces et qui peut entraîner la légionellose (voir Lacroix, 1999). Les critères liés aux contraintes opérationnelles des chauffe-eau sont le temps maximum de contrôle et un temps minimum entre deux périodes de contrôle.

Dans l'article de Lee and Wilkins (1983), les auteurs visent à minimiser les pics de charge par la gestion de la charge des chauffe-eau. Les chauffe-eau homogènes (p. ex. ayant la même capacité de stockage, puissance nominale, etc.) sont agrégés dans des groupes. Le nombre de chauffe-eau ainsi que les scénarios d'interruptions choisis pour chaque groupe sont calculés

au moyen du problème d’optimisation.

L’article de Laurent et al. (1995) applique la méthode de génération de colonnes au problème de gestion de la charge des chauffe-eau dans le but de réduire la charge de pointe en se basant sur le modèle physique de chauffe-eau présenté dans l’article de Laurent et al. (1994). Le modèle considère un ensemble fini de scénarios admissibles d’interruption de chauffe-eau, où un tel scénario est celui pour lequel la probabilité que la température de l’eau chaude dans le réservoir descende en dessous du niveau de confort ne dépasse pas 1%. L’idée est d’attribuer à chaque chauffe-eau un scénario admissible, et ce pour chaque période de l’horizon de planification. Ce grand nombre de scénarios augmente la taille du problème et le rend difficile à résoudre, d’où le choix de la méthode de génération de colonnes.

Dans l’article de Laurent et al. (1995), le problème maître (PM) est résolu par un sous-ensemble de scénarios d’interruption. Le sous-problème (SP) est modélisé sous forme d’un problème de réseau dont les nœuds représentent l’état d’un groupe de chauffe-eau (c.-à-d. une fraction de chauffe-eau *allumés* ou *éteints*) et dont un chemin dans le réseau correspond à un scénario admissible d’interruption. Le SP résout le problème du plus court chemin, et si le coût est négatif, le scénario admissible d’interruption associé à ce coût ainsi que le groupe de chauffe-eau traversé par ce scénario seront ajoutés au PM, car c’est un chemin qui pourrait éventuellement réduire le pic de charge.

Les résultats montrent qu’une réduction de la charge de pointe de 33% est atteinte par le modèle. Bien que ce modèle soit flexible en ce qui a trait au nombre de variables, soit les scénarios d’interruption admissibles, ces scénarios d’interruption doivent par contre être prédéterminés.

L’article de Klaassen et al. (2012) vise à aplatir la courbe de charge à travers la gestion de la charge des chauffe-eau. Pour ce faire, l’horizon de planification est divisé en créneaux horaires de 15 minutes et l’objectif est de minimiser la différence de charge entre ces créneaux et de la garder aussi proche que possible de la charge moyenne. Les chauffe-eau sont agrégés dans des groupes dont chacun est activé pour une période de 4 heures maximum pendant les heures à bas tarifs. Le problème est formulé sous forme d’un programme linéaire en nombres entiers où les variables binaires indiquent l’état de chaque groupe de chauffe-eau (c.-à-d. activé/désactivé) dans chaque créneau horaire. Les résultats de cet article montrent que plus il y a de groupes de chauffe-eau, meilleur est le lissage de la courbe de charge. Cela est dû au fait qu’en augmentant le nombre de groupes (c.-à-d. en diminuant le nombre de chauffe-eau par groupe), on réduit les pointes créées par la charge de reprise.

2.1.3 Logique floue

Une autre approche basée sur la logique floue est décrite dans LaMeres et al. (1999), où des règles de contrôle de chauffe-eau sont prédéfinies. Le modèle choisit la règle optimale à appliquer au temps (t) selon les données de la température actuelle des chauffe-eau et les informations sur la demande de charge qu'il reçoit. Les mesures de la température de l'eau dans le chauffe-eau et de la demande de charge passent par des applications, appelées fonctions d'appartenance, qui les transforment en des valeurs réelles entre $[0, 1]$. Ces valeurs déterminent le degré d'appartenance de la demande et de la température à 5 classes de demande (basse, élevée, moyenne, au-dessus de la moyenne, en dessous de la moyenne) et à 5 classes de température (froide, chaude, moyenne, au-dessus de la moyenne, en dessous de la moyenne) respectivement. Le contrôleur à logique floue choisit la règle de contrôle optimale parmi un nombre fini d'actions selon la classe de la demande et de la température de l'eau dans le chauffe-eau. Une règle détermine le niveau de la puissance auquel les chauffe-eau vont fonctionner. Les résultats montrent une réduction de la demande d'un chauffe-eau souscontrôle de 0.5 kW. Cette approche est plus facile à mettre en place que les autres approches susmentionnées, mais elle diminue la latitude en matière de contrôle en réduisant de façon importante le nombre de contrôles applicables.

2.1.4 Gestion de la charge et services auxiliaires

Un atout important de la technique de la gestion de la charge est la possibilité de l'appliquer pour fournir des services auxiliaires de type réserve tournante qui sont nécessaires pour compenser le déséquilibre entre la production et la demande dû aux défections soudaines des unités de génération ou à une prévision sous-estimée de la charge.

Dans l'article de Rosario et al. (2011), les auteurs utilisent un algorithme basé sur la méthode heuristique d'optimisation par essais particuliers pour planifier l'opération des chauffe-eau afin de tirer le maximum de la réserve tournante.

L'optimisation par essais particuliers est un algorithme itératif dont le but est d'améliorer la solution à chaque itération selon des mesures de qualité. Une solution est modélisée sous la forme d'une particule caractérisée par deux vecteurs : un vecteur de position et un autre de vitesse. La procédure part d'une population de solutions candidates (c'est-à-dire les particules). Ces particules bougent ensuite dans l'espace de recherche selon une formule mathématique qui met à jour leur vitesse et leur position à chaque itération. La solution calculée ne garantit pas l'optimalité globale vu que les particules sont positionnées dans leur meilleure position locale par rapport à leur position initiale. Au bout d'un nombre prédéfini

d'itérations, l'algorithme s'arrête et la meilleure solution est retournée.

L'objectif du modèle est de gérer les chauffe-eau de façon à minimiser la différence entre la réserve demandée par l'opérateur et la consommation économisée quand les chauffe-eau sont éteints, tout en gardant la température de l'eau à l'intérieur d'une zone de confort. Un problème d'allocation optimale des ressources de production *Unit Commitment* est résolu avant et après le contrôle de la charge afin de calculer les économies d'argent réalisées grâce à l'approche proposée.

Un autre service auxiliaire dont la gestion de la charge est un fournisseur potentiel est la régulation de la fréquence du réseau, tel qu'il est démontré dans l'article de Short et al. (2007). Si la génération électrique dépasse la demande, la fréquence du réseau montera, et si la demande dépasse la génération, la fréquence baissera. Dans ces deux cas, l'opérateur du réseau est obligé de prendre des mesures instantanées face à cette variation de fréquence résultant de ce déséquilibre entre la génération et la demande électrique pour maintenir la fréquence à son niveau normal. Le contrôle dynamique de la demande des réfrigérateurs est ainsi examiné afin de stabiliser la fréquence du réseau pendant les montées brusques de demande ou la variation de génération causée par la fluctuation de la production éolienne dont la prévision est déterministe.

2.1.5 Réduction des pertes du système de distribution d'alimentation

Dans un système de distribution d'alimentation, environ 13% de la quantité totale de puissance générée est perdue lors de la distribution d'énergie (voir Salehfar et al., 2001). Cet article porte sur l'étude de la réduction des pertes par le choix du nombre optimal de chauffe-eau ainsi que de leurs meilleurs emplacements dans un réseau de distribution électrique où plusieurs câbles d'alimentation, dont le coût de perte varie, sont liés au générateur. Un modèle linéaire calcule la solution optimale de façon à minimiser trois termes :

1. Perte d'énergie durant la pointe de charge.
2. Perte d'énergie sur tout l'horizon de planification.
3. Coût d'achat des chauffe-eau additionnels.

La stratégie est d'installer des chauffe-eau additionnels chez les clients afin d'augmenter la capacité de stockage dans le réseau. On active ces chauffe-eau durant les périodes creuses pour y stocker de l'eau chaude qui sera utilisée par la suite pendant les heures de pointe, quand les chauffe-eau sous contrôle seront désactivés.

2.2 Pr vision des conditions m t orologiques

Dans le cadre du probl me de la gestion de la demande qui tient compte de la production  olienne, la qualit  de la pr vision de cette derni re influence la qualit  des solutions. Nous pr sentons dans cette sous-section diff rentes approches de pr visions   court terme qui figurent dans la litt rature.

La pr vision de la production  olienne est fortement li e   la pr vision m t orologique. Par cons quent, la premi re phase pour pr voir la production  olienne consiste   pr voir les param tres m t orologiques n cessaires. La deuxi me phase consiste   traduire la pr vision m t orologique en une pr vision de la production  olienne. La pr vision m t orologique est souvent bas e sur des mod les de pr vision num rique du temps (PNT). Ces mod les de PNT sont bas s sur des  quations mod lisant les lois physiques qui gouvernent l' volution de l'atmosph re. Avec une connaissance suffisante de l' tat actuel de l'atmosph re, la PNT est capable de pr dire les variables d' tat de l'atmosph re (c.- -d. la temp rature, la vitesse du vent, la densit  de l'air, etc.) dans le futur sur une grille spatiale de r solution qui varie entre quelques kilom tres et 50 km, une r solution temporelle entre 1 et 6 heures et une altitude de 10m (voir Kalnay et al., 1998). Cette r solution spatiale et cette altitude de la PNT sont insuffisantes pour mod liser l' tat atmosph rique   la hauteur des turbines des  oliennes, il est donc souvent n cessaire de pr traiter la PNT avant de la traduire en une pr vision de la production  olienne. Cette  tape de pr traitement consiste   extrapoler ces param tres   la hauteur des turbines (80-100 m au-dessus du niveau du sol). Les trois diff rentes approches d'extrapolation de la PNT qui figurent dans la litt rature sont :

- L'approche physique, o  la vitesse du vent est extrapol e   des hauteurs sup rieures selon la m canique des fluides num rique (MFN), et ce, en fonction de la g ographie du terrain (rugosit , obstacles, etc.) (voir Pinson, 2006).
- L'approche statistique qui, selon des donn es historiques de PNT ainsi que leur extrapolation   la hauteur de la turbine, entra ne des mod les d'apprentissage (p. ex. mod le de r gression, r seau de neurones, ARMA, mod le Box-Jenkins, etc.) (voir Fukuda., 2001; Zhang et al., 1998).
- L'approche hybride qui combine   la fois entre l'approche physique et statistique (p. ex., des mod les qui couplent la PNT et les r seaux de neurones) (voir Chang, 2014) .

Sachant qu'une PNT est sensible aux conditions initiales de l'atmosph re, une connaissance parfaite d'un tel  tat est souvent tr s difficile   atteindre. Par cons quent, il est risqu  de baser la gestion de la charge sur une seule pr vision dite d terministe puisque les d cisions prises ne seront pas robustes face   l'erreur de la pr vision. Donc, fournir un faisceau de pr visions au lieu d'une seule, qui diff rent dans leurs conditions initiales et dans leurs mod les physiques

de PNT, Figure 2.1, aide à prendre des décisions plus robustes face à l'incertitude.

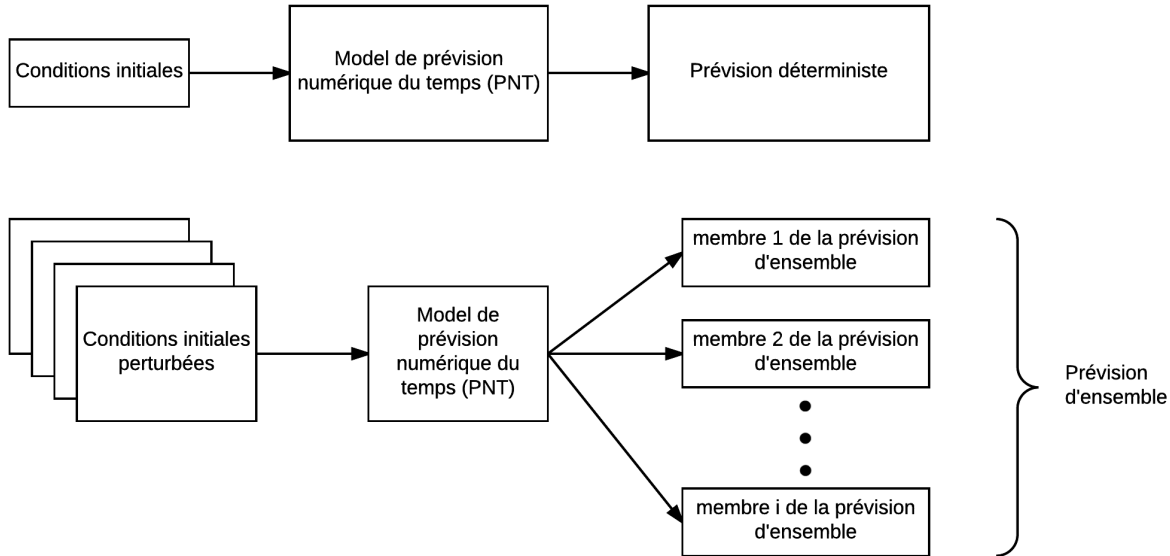


Figure 2.1 Prévision d'ensemble (voir Pinson, 2006)

Cette prévision d'ensemble est utile pour donner une meilleure représentation de l'incertitude de la prévision météorologique (voir Palmer, 2000).

2.3 Incertitude de la production des sources d'énergies renouvelables

Les méthodes de gestion de la charge présentées ci-dessus ne considèrent que des paramètres déterministes dans les problèmes traités, notamment en termes de prévision de charge ou de sources d'énergie renouvelables. Par conséquent, les solutions obtenues manquent de robustesse face à l'incertitude dans la prévision. Dans cette section, nous présentons des méthodes qui prennent en compte l'aspect incertain des paramètres dans le problème de gestion de la charge.

2.3.1 Programmation dynamique stochastique

Dans ce contexte, l'article de Papavasiliou and Oren (2010) utilise l'approche de la programmation dynamique stochastique pour résoudre le problème de gestion de charges contrôlables. L'objectif est de minimiser l'achat d'énergie par le marché spot nécessaire pour combler le reste de la demande non satisfaite par la production éolienne. L'article de He et al. (2013)

utilise la même méthodologie avec l'objectif de maximiser le profit de l'opérateur par une politique optimale des prix d'électricité poussant la charge contrôlable à ne pas s'écarter de la production éolienne supposée incertaine.

Dans la version stochastique de la programmation dynamique, la fonction de Bellman $J_{k-1}(x_{k-1})$ s'écrit sous la forme suivante :

$$\begin{aligned} J_K(x_K) &= g_K(x_K), \\ J_{k-1}(x_{k-1}) &= \inf_{u \in U_{k-1}(x_{k-1})} \mathbb{E}_\omega [g_{k-1}(x_{k-1}, u_{k-1}, \omega_{k-1}) + J_k(x_k)], \\ x_k &= f_{k-1}(x_{k-1}, u_{k-1}, \omega_{k-1}), \end{aligned} \quad (2.1)$$

où ω est la variable aléatoire par rapport à laquelle la fonction de coût espéré $J_{k-1}(x_{k-1})$ aux périodes $k-1, k, \dots, K$ est calculée. L'utilisation de l'approche de programmation dynamique stochastique est limitée par la taille du problème qui augmente de façon exponentielle avec la dimension des vecteurs d'états x_k et de contrôle u_k , tel qu'il est discuté dans la section 2.1.1.

2.3.2 Programmation stochastique avec recours

Une autre approche qui traite des problèmes ayant des paramètres incertains est la programmation stochastique avec recours. Cette approche d'optimisation se base sur l'hypothèse que : (i) chaque vecteur aléatoire $\{\xi_t : t = 1, \dots, T\}$ est supposé avoir un nombre fini de réalisations possibles, (ii) la distribution de probabilité de ξ_t est indépendante des variables de décisions. Cela permet de représenter le processus stochastique ξ_t à l'aide d'un arbre de scénarios dont chaque scénario, qui est un parcours commençant par le nœud racine et se terminant à une feuille, correspond à une réalisation possible du ξ_t pondéré par sa probabilité d'occurrence, et dont chaque nœud a un et un seul nœud père (voir Birge and Louveaux, 2011a; Carpentier, 2014).

La Figure 2.2 illustre un arbre de scénarios à 2 étapes, également connu sous le nom d'arbre de peigne, où chaque nœud représente une valeur possible du processus stochastique, et chaque niveau vertical de nœuds est associé à un pas de temps t de l'horizon de taille T . Une probabilité conditionnelle d'occurrence est associée à chaque nœud en fonction du nœud père. Au nœud racine, les valeurs futures du processus stochastique sont incertaines car plusieurs scénarios peuvent être réalisés. Par contre, au deuxième pas de temps, chaque scénario devient déterministe, autrement dit, si l'on connaît la valeur du processus stochastique au deuxième pas de temps, on pourra prédire avec certitude la valeur du processus stochastique jusqu'à la fin de l'horizon. Pour ce type d'arbre de scénarios, les variables de décisions sont divisées en




Figure 2.2 Arbre de peigne

deux catégories, les variables de première étape et variables de deuxième étape. Les variables de première étape sont celles prise au nœud racine, tandis que les variables de deuxième étape sont celles calculées après la révélation de l'incertitude, d'où le nom "arbre de scénario à 2 étapes". Cette approximation du processus stochastique permet de reformuler le programme stochastique original (PS) en un programme équivalent déterministe (ED), où x est la variable de la première étape, et y est celle de la deuxième étape.

$$(PS) \quad \min_{x,y} c^T x + \mathbb{E}_{\xi} [q(\xi)^T y(\xi)]$$

sous les contraintes

$$\begin{aligned} Ax &= b, \\ Wy(\xi) &= h(\xi) - T(\xi)x, \quad \xi \in \Xi \\ x &\geq 0, \\ y &\geq 0 \end{aligned} \tag{2.2}$$

$$(ED) \quad \min_{x,y} c^T x + \sum_{i=1}^m P[\xi = \xi_i] q(\xi_i)^T y(\xi_i)$$

sous les contraintes

$$\begin{aligned} Ax &= b, \\ Wy(\xi_i) &= h(\xi_i) - T(\xi_i)x, \quad \forall i \in \{1, \dots, m\} \\ x &\geq 0, \\ y &\geq 0 \end{aligned} \tag{2.3}$$

Dans un arbre de scénarios contenant d'autres ramifications dans les pas de temps futurs, nous sommes face à un programme stochastique multi-étapes, dont la résolution est plus difficile car des **contraintes de nonanticipativité** s'ajoutent au problème. En d'autres termes, pour deux scénarios, ξ_t^1 et ξ_t^2 , $t = 1, \dots, T$, si pour $k = 1, \dots, t$ tel que $t < T$ nous avons $\xi_k^1 = \xi_k^2$ deux scénarios qui partagent les mêmes valeurs pour $k \leq t$, les **contraintes de nonanticipativité** imposeront que $x_k^1 = x_k^2$, où x_k^i est la variable de décision calculée au pas de temps k pour le scénario i . Autrement dit, les **contraintes de nonanticipativité** garantissent qu'une décision x_k ne peut dépendre que de l'information ξ_1, \dots, ξ_k disponible à la période k .

Scott et al. (2013) propose un modèle d'optimisation stochastique avec recours à 2 étapes, qui est une approximation du modèle multi-étapes. L'objectif est de minimiser le coût de consommation électrique d'une maison en contrôlant de façon optimale sa charge électrique sur un horizon discret. La charge est composée de charges thermostatiques de type chauffage, ventilation et climatisation (CVC) et chauffe-eau électrique, ainsi que des charges reportables de type machine à laver, sèche-linge et lave-vaisselle, et ce dans le cadre d'un marché d'électricité supposé avoir des tarifications, les conditions météorologiques et de profils de consommation électrique incertains. Pour construire l'arbre de scénarios, on utilise les prévisions météorologiques disponibles auprès du *Bureau of Meteorology* australien, de la vitesse du vent et de la température maximum et minimum pour calculer une prévision de la production renouvelable et de la charge électrique. Une prédiction du prix est calculée en fonction de la quantité de puissance que les générateurs thermiques doivent fournir pour couvrir la demande électrique.

CHAPITRE 3 ORGANISATION DE LA THÈSE

Cette thèse a pour but de développer des modèles mathématiques visant la gestion de la consommation électrique de chauffe-eau dans les réseaux électriques dits intelligents (*smart grid*). Ces derniers étant munis de sources d'énergie renouvelables, la gestion de charge des chauffe-eau servira à atténuer l'intermittence de la production et de réduire la consommation électrique durant les heures de pointes. Parmi les différentes méthodologies de gestion de charge proposées dans la littérature au chapitre 2, peu de travaux ont traité l'aspect incertain de la production renouvelable. Le travail effectué dans cette thèse tient compte de l'incertitude de la production éolienne et de la charge électrique. Cette gestion de la consommation de chauffe-eau est faite dans le cadre du projet smartDESC qui propose une architecture hiérarchique de la gestion de charge, comme discuté dans le chapitre 1.

La première contribution de cette thèse, présentée au chapitre 4, traite la question de la génération de scénarios de production éolienne à partir de la prévision d'ensemble provenant de Environnement Canada. Ce chapitre présente une méthode d'extrapolation de la prévision d'ensemble calculée à des basses altitudes vers la hauteur des turbines des éoliens, et ce en se servant des données de prévisions fournies par le partenaire industriel WPred. Le but de cette approche est de fournir aux gestionnaires de réseaux électriques un ensemble de scénarios probables de production éolienne au lieu d'une seule prévision déterministe de production. Ceci permet de prendre des décisions robustes face à l'intermittence de la production éolienne. Les résultats obtenus montrent qu'à travers cette méthode, nous obtenons des scénarios de production éolienne représentatifs de l'incertitude des conditions météorologiques à court terme.

La deuxième contribution, exposée au chapitre 5, consiste à développer un modèle d'optimisation stochastique qui, dépendamment de la prévision d'ensemble, calcule le profil optimal de la consommation électrique d'un modèle agrégé de chauffe-eau. Ce dernier est calculé de façon à lisser la courbe de demande nette et à atténuer l'intermittence des éoliens en exploitant la capacité de stockage thermique de chauffe-eau. Ceci nous permet d'absorber l'excès de la production durant les heures creuses pour réduire la demande durant les heures de pointe. Ce profil de consommation électrique est traduit par la suite en un profil de température de consigne vers lequel la température moyenne de la population de chauffe-eau converge, et ce via les contrôleurs locaux qui appliquent la loi de commande à champ moyen. Des résultats numériques montrent l'efficacité de cette approche à réduire la fluctuation ainsi que la pointe de la demande nette via le pilotage de la consommation électrique de chauffe-eau.

Au chapitre 6, nous traitons le problème de convergence du profil de température du modèle agrégé du chauffe-eau vers un profil atteignable par les contrôleurs locaux à champ moyen. Une preuve mathématique de convergence d'un algorithme de correction de profil est présentée. Les résultats numériques démontrent l'atteignabilité du profil corrigé par le contrôleur à champ moyen.

Finalement, les limites des travaux de cette thèse sont présentées dans le chapitre 8, suivies d'une conclusion.

CHAPITRE 4 ARTICLE 1 : A METHODOLOGY FOR ENSEMBLE WIND POWER SCENARIOS GENERATION FROM NUMERICAL WEATHER PREDICTIONS

Auteurs: Adham I. Tammam, Christophe S. Watters, Miguel F. Anjos, Michel Gendreau.

Accepté à: 2016 IEEE Power & Energy Society General Meeting.

Abstract

Electric utilities have been using wind power to an increasing extent in order to provide clean energy. However, this resource depends on the intermittency of wind, and this makes balancing supply and demand challenging for the system operator. In this paper we propose a downscaling approach yielding daily probabilistic wind speed scenarios for the turbine hub height, thus making them useful for generating possible wind power scenarios that could be used to maintain the network balance in light of these possible outcomes.

4.1 Introduction

Wind power is an emerging source of renewable energy with more than 51 GW installed during 2014, taking its global total capacity to almost 370 GW. This increase is not only because of environmental considerations, but also because of its speed of deployment and cost stability GWEC (2014). Utilities managing electric grids with large-scale wind power operation have to take into account its intermittency to be able to balance supply and demand. An accurate forecast of possible wind power scenarios is important for applications like unit commitment or demand side management by system operators and profit maximization by electricity traders (Falsafi et al., 2014; Papavasiliou et al., 2011; Wang et al., 2011).

Three approaches are used for short-term prediction: 1) The physical approach based on numerical weather prediction (NWP) uses meteorological conditions to forecast the wind speed, 2) the statistical approach based on applying learning algorithms (i.e. regression, neural networks, etc.) to historical data without considering meteorological conditions, 3) a hybrid approach that mixes both approaches (Giebel et al.; Wang et al., 2011).

Because a deterministic forecast is sensitive to initial forecast conditions that can affect significantly its final outcome, decisions that rely on a single deterministic forecast could result in misleading strategies Pinson (2006). Therefore we are interested in this paper in generating scenarios of wind power based on wind speed ensemble forecast, where each

member of the ensemble differs in its initial conditions and/or atmosphere modeling. Such an ensemble gives the decision maker a better idea about the wind power uncertainty and results in a more robust strategies. The available NWP for wind speed are calculated at 10m above ground level (a.g.l.), yet the hub height is at a higher altitudes. Extrapolating wind speed at 10m to a higher altitude is a common approach in meteorology, where physical models parameterized mainly by roughness length and atmospheric stability measured via the Monin–Obukhov length are used Garratt (1994). The approach presented in this paper is a hybrid one, as it downscales the NWP wind speed forecast calculated at low attitudes to hub height by training a linear regression model using both NWP data and deterministic forecasts at 100m, which we assume to be a good approximation to the hub height. Those adjusted wind speed scenarios are then converted to ensemble power production scenarios using wind turbine power curves.

4.2 Wind Speed Scenarios

Environment Canada (EC) provides several sets of NWP forecasts at 10m a.g.l. of excellent resolution, especially for Québec. The NWP database includes outputs of the ensemble solution, describing various possible outcomes of weather evolution anywhere in the world, with an average resolution of 100 km. Those data are generated according to the Global Environmental Model (GEM), an integrated forecasting and data assimilation system developed by the Canadian Meteorological Centre. The wind speed is calculated twice a day (at $T = 0\text{h}$ and $T = 12\text{h}$), over a horizon of 144 hours with temporal resolution of 6 hours. We denote by $V_{T+t,d}^F$ the wind speed forecast at time $T+t$ and at d meters of height. Multiple scenarios of wind speed forecast are generated according to perturbed initial states, as well as the different models used for variant atmospheric parameters (i.e., deep convection, precipitation, turbulence, roughness length, etc.) Canada (2014). We call those scenarios Global Ensemble Prediction (GEP). We only consider the forecast for $12 \leq t \leq 144$, which is assumed to be reliable, so the value at $T+6$ is omitted.

We need to have wind speeds at the hub height to generate the appropriate corresponding wind power scenarios, but the data provided by EC is for wind speed at 10m of height. Figure 4.3 gives an example of how significant the difference can be between the mean scenario of the EC forecast at 10m and the deterministic forecast, whence the need to correct those scenarios.

The deterministic forecast upon which the ensemble of 10m forecasts are adjusted, is an interpolation of the GEM NWP of EC with a temporal resolution of 15 minutes. This interpolation is provided by WPred, a service company of Montréal. Table 4.1 depicts some

error measures of the WPred deterministic forecast of wind speed, where ME, MAE and RMSE are the mean error, mean absolute error and root-mean-square error respectively. The results shows a small error standard deviation that increases with time with a maximum value of 2.79 for five days ahead. In this section we show how we used both wind speed forecasts of GEP and WPred to extrapolate wind speed scenarios at the hub height using regression analysis, by applying the following expression:

$$V_{T+t,100}^F = a * V_{T+t,10}^F. \quad (4.1)$$

The offset of the linear equation in (4.1) has been omitted because of its insignificant improvement, and to avoid having negative values for wind speed which is absurd Watters and Leahy (2012).

We collected GEP and WPred data for both Montreal and Quebec City from mid-July 2015 until October 2015. $V_{i,T+t,10}^{arch}$ denotes the i^{th} scenario of the archived GEP wind speed forecast at time $T+t$ and 10m height, where $i \in \mathfrak{I} = \{1, 2, \dots, I\}$. $V_{T+t,100}^{arch}$ denotes the archived deterministic forecast for wind speed at time $T+t$ and 100m of height.

We compute the optimal value of the coefficient a that minimizes the least squared error between the GEP mean wind speed scenario $\bar{V}_{T+t,10}^{arch}$ and $V_{T+t,100}^{arch}$. With $\mathfrak{T} = \{12, 18, 24, \dots, \mathcal{T}\}$, we have

$$a^* = \underset{a}{\operatorname{argmin}} E(a) := \left\{ \sum_{t \in \mathfrak{T}} (V_{T+t,100}^{arch} - a \times \bar{V}_{T+t,10}^{arch})^2 \right\}, \quad (4.2)$$

where

$$\bar{V}_{T+t,10}^{arch} = \frac{1}{I} \sum_{i=0}^I V_{i,T+t,10}^{arch}. \quad (4.3)$$

The optimization program (4.2) is a convex quadratic unconstrained problem and thus easy to solve.

4.3 Wind Power Predictions

We are able to generate wind speed scenarios at the hub height based on the EC forecast with a step-size of 6 hours via (4.1). We then apply a cubic spline interpolation to get hourly wind speed scenarios. To generate the wind power production scenarios, we use the power curve of wind turbines in Figure 4.1, adjusted for air density as in the International Electrotechnical Commission standard of wind turbines [IEC 61400-12].

Table 4.1 Error Measures of wind speed deterministic forecast [m/s]

Time	Error Measures	Value
Day+1	ME	-0.49
	MAE	2.03
	RMSE	2.60
Day+2	ME	-0.49
	MAE	2.011
	RMSE	2.56
Day+3	ME	-0.48
	MAE	2.06
	RMSE	2.64
Day+4	ME	-0.46
	MAE	2.08
	RMSE	2.66
Day+5	ME	-0.44
	MAE	2.16
	RMSE	2.79

Solving the optimization problem (4.2) gives the linear approximation of the relation between the mean scenario wind speed at 10m and the corresponding wind speed at 100m of the deterministic forecast shown in Figure 4.2. Applying this linear correction to the EC forecast gives wind speed scenarios as illustrated in Figure 4.4. Although the mean scenario of the corrected ensemble doesn't follow the deterministic forecast, the scenarios do cover the range of all possible values that the deterministic forecast predicts. In addition to the linear regression model presented so far, we also studied quadratic and cubic regression by solving (4.4) - (4.5) respectively to check if we can improve the correction. Figure 4.5 illustrates the estimate values of the standard deviation of the error in predicting a future observation for the three approximations and the results show that the linear one has the least max standard deviation error as indicated in Table 4.2, while the mean estimate of the standard deviation of the error in predicting are almost the same for the three models .

Using the approach above, we used historical sets of wind speed forecasts for the regions of Montréal and Quebec City, and we generated the corresponding total wind power scenarios for four farms: Montérégie and De l'Érable near Montréal, Massif du Sud and Seigneurie de Beauré near Quebec City. The former have turbines of type REpower and Enercon. Figure 4.6 gives an example of such ensemble wind power scenarios.




Figure 4.1 Power curves

$$b^* = \operatorname{argmin}_{b \in \mathbb{R}^2} E(b) := \left\{ \sum_{t \in \mathfrak{T}} \left[V_{T+t,100}^{arch} - (b_1 * (\bar{V}_{T+t,10}^{arch})^2 + b_2 * \bar{V}_{T+t,10}^{arch}) \right]^2 \right\} \quad (4.4)$$

$$c^* = \operatorname{argmin}_{c \in \mathbb{R}^3} E(c) := \left\{ \sum_{t \in \mathfrak{T}} \left[V_{T+t,100}^{arch} - (c_1 * (\bar{V}_{T+t,10}^{arch})^3 + c_2 * (\bar{V}_{T+t,10}^{arch})^2 + c_3 * \bar{V}_{T+t,10}^{arch}) \right]^2 \right\} \quad (4.5)$$

4.4 Evaluation of the uncertainty estimation

The objective of the proposed approach is to represent the short-term wind power in a form of ensemble wind power scenarios that can be used by decision-makers in order to take actions according to these possible sets of possible power outcomes. Thus, the evaluation of the approach's quality is not about how accurately it predicts the future intermittent wind power, but rather how well it represents the wind power's uncertainty. This quality measure is illustrated in Pinson (2006) by evaluating how the scenarios spread changes with the prediction uncertainty. The ensemble spread of an instance $n \in \mathfrak{N} = \{1, 2, \dots, N\}$ at time t is quantified by the standard deviation of ensemble members $\sigma_f^n(t)$, and the level of prediction uncertainty is given by the forecast error $e^n(t)$ between the ensemble forecast

Table 4.2 Comparison between different regression models

	Linear Model	Quadratic Model	Cubic Model
Max std of error	1.7937	1.8124	1.843
Mean std of error	1.7892	1.7878	1.787




Figure 4.2 Linear Regression

mean, denoted by \bar{V}_{T+t}^n and the real realization of wind speed V_{T+t}^n for instance n (4.6). Note that because we don't have access to real wind power production data, we conducted this quality evaluation test over wind speed scenarios and used the available real wind speed data for different regions in Canada on the EC website.

Figure 4.7 depicts in a form of a box plot the ratio $e^n(t)/\sigma_f^n(t)$, where the ideal case is when the median, represented by the red line within each box, equals 1 as this is the case where the ensemble spread better reflects the prediction error. The uncertainty is overestimated when the median is less than 1, and vice versa. The results show that predictions over the first 5 hours reflect relatively well the wind speed uncertainty, however starting from the 6th hour, wind forecast spread is most of the time underestimated. This less accurate representation of uncertainty over long horizons is maybe due to the lack of efficient NWP historical data, still the uncertainty over the first 5 hours is well represented. This can help decision-makers to make robust decisions over short periods, and correct those decisions over time by updating the generated scenarios when new information is available, as is done in

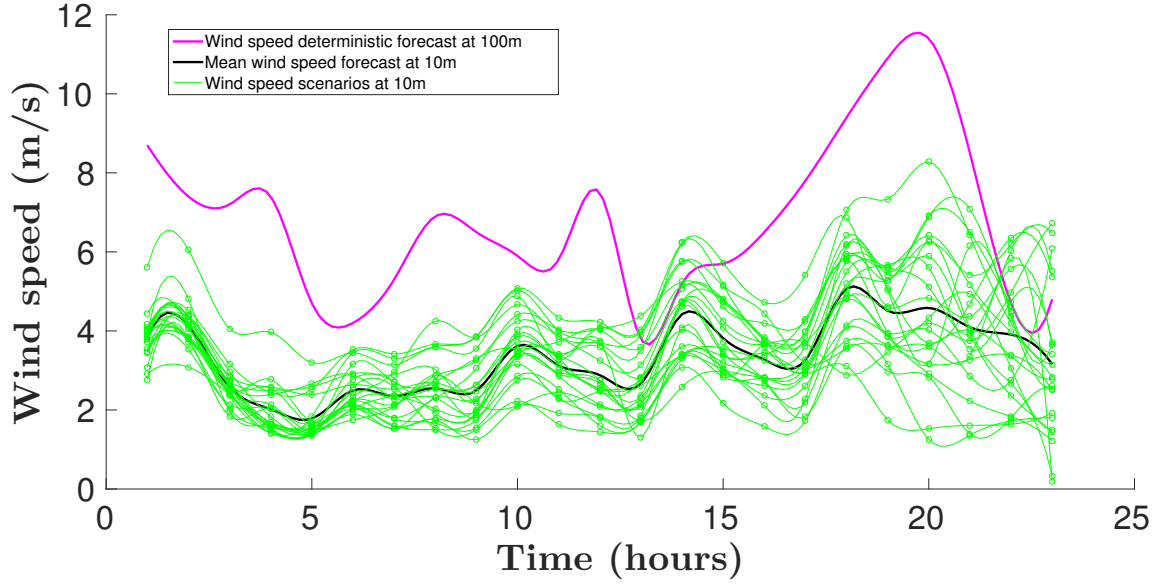


Figure 4.3 Set Scenarios

stochastic optimization with recourse.

$$e^n(t) = |V_{T+t}^n - \bar{V}_{T+t}^n| \quad \forall n \in \mathfrak{N}, \forall t \in \mathfrak{T} \quad (4.6a)$$

$$\sigma_f^n(t) = \left[\frac{1}{I} \sum_{i=1}^I (V_{i,T+t}^n - \bar{V}_{T+t}^n)^2 \right]^{\frac{1}{2}} \quad \forall n \in \mathfrak{N}, \forall t \in \mathfrak{T} \quad (4.6b)$$

$$\bar{V}_{T+t}^n = \frac{1}{I} \sum_{i=1}^I V_{i,T+t}^n \quad \forall n \in \mathfrak{N}, \forall t \in \mathfrak{T} \quad (4.6c)$$

4.5 Conclusion and Future work

In this paper we proposed an approach that generates ensemble wind power scenarios based on the NWP wind speed forecast. The approach uses a linear model, based on regression analysis, that downscales the NWP scenarios at 10m to a higher altitude using a deterministic forecast calculated at 100m a.g.l. The wind speed scenarios show a good ability in reflecting the wind uncertainty within a few hours, whereas this uncertainty reflection becomes less representative while going forward in time. The next step is to collect real power production data of certain wind farms and apply our approach to see how well it will reflect the power





Figure 4.4 Corrected Scenarios


intermittency.

Acknowledgment


This work was funded by an ECO Energy Innovation Initiative grant from Natural Resources Canada.



(a) Linear model



(b) Quadratic model



(c) Cubic model

Figure 4.5 Estimate of the standard deviation




Figure 4.6 Wind power scenarios




Figure 4.7 Uncertainty representation of wind speed

CHAPITRE 5 ARTICLE 2 : BALANCING SUPPLY AND DEMAND IN THE PRESENCE OF RENEWABLE GENERATION VIA DEMAND RESPONSE FOR ELECTRIC WATER HEATERS

Auteurs : Adham I. Tammam, Miguel F. Anjos, Michel Gendreau.

Soumis à : IEEE Transactions on Power Systems.

5.1 Abstract

With the increasing penetration of renewable energy sources in the electrical power grid, demand response via thermostatic appliances such as electric water heaters is a promising storage means to compensate the significant variability in renewable generation power. We propose a multi-stage stochastic optimization model that computes the optimal day-ahead target profile of the mean thermal energy contained in a large population of heaters, given various possible wind power production and uncontrollable load scenarios, where this optimal profile is calculated to make the variable net demand as flat as possible.

5.2 Introduction

Although renewable energy sources are considered an expensive source of energy in terms of equipments, installation and maintenance compared to thermal resources, their increasing use in electrical grids is mainly due to the desire to reduce greenhouse gases emissions from burning fossil fuels for electricity, heat, and transportation. Yet the intermittency of renewables creates challenges for system operators who must ensure the balance at all times between supply (constrained by its ramping limits) and demand.

Demand-side management of energy storage in the form of thermostatically controlled appliances (TCAs), such as water heaters, space heaters, or batteries of electric vehicles, whose load curve can be reshaped while respecting the end-user comfort constraints, is a promising means to counterbalance the intermittence of renewables and has been the focus of many studies. Dynamic programming models have been developed to minimize the peak load considering deterministic load demand (Bischke and Sella, 1985; Cohen et al., 1988; Zhang and Li, 2013). A control algorithm for TCAs to follow regulation signals in order to stabilize a network supplied with renewable resources was proposed in Kondoh et al. (2011). TCAs load shifting from peak to off-peak periods based on fuzzy logic control strategy can be found in Nehrir and LaMeres (2000); LaMeres et al. (1999).

In this paper, we focus on studying the potential for controlling the electric water heaters load because of their ability to store energy for a considerable amount of time due to their high thermal inertia. Their peak of demand coincides with the peak of total load demand, which means that a significant reduction of the peak of the load curve could be achieved (Sepulveda et al., 2010). Finally, according to Natural Resources Canada, the power consumption of water heaters in Canada is important and could go up to 21.7% of the total demand load (NRC, June 2004).

A deterministic linear optimization model which decides the number of water heaters to which one control scheme from a predefined set of schemes should be applied in order to reduce the peak load is proposed in Lee and Wilkins (1983). A column generation approach is applied to a load management problem where the objective is to minimize the maximum peak of a known load profile by choosing among a large set of admissible interruption scenarios established in advance (Laurent et al., 1995). A metaheuristic algorithm based on particle swarm optimization to operate the power consumption of water heaters in order to shave the load curve is proposed in Rosario et al. (2011); Sepulveda et al. (2010). Directly controlling the power consumption of residential water heaters could be used to reduce the power losses in an electric grid as in Salehfar et al. (2001).

The aforementioned studies deal with the problem parameters in a deterministic setting, yet in reality load demand and renewable supply are uncertain. In (Malik and Havel, 2014), a centralized direct load control of electric water heaters (EWHs) was proposed in order to reduce the peak imports and exports on the Czech electricity market. The presented approach takes into account the stochastic nature of load demand and renewable production, hence the dispatch of the EWHs is decided through a two-stage stochastic optimization program, where the first stage computes the overall EWH load, and the second stage rectifies the dispatch according to the actual power supply and demand.

Multiple challenges arise when trying to control a huge number of storage devices individually small in capacity but diversified in their state, and spread throughout a pervasive communication platform, because a control schedule applied indiscriminately can spoil their natural load diversity, inducing the payback phenomenon that may create new peak loads (Laurent et al., 1995). Moreover centrally controlling a large population of storage devices discriminately requires sophisticated mathematical models and significant computational power to solve them.

For those aforementioned reasons, we consider a demand response approach as a hierarchical control architecture in two phases. In the first phase, we optimally schedule the day-ahead load of a homogeneous aggregate model of the EWHs population, in the presence of two

stochastic parameters: (1) the uncontrollable load (the total load after excluding the controllable demand of EWHs) and (2) the renewable supply. We compute an optimal power profile (OPP) for this aggregate model, which is then translated into a temperature profile that specifies a series of hourly setpoints that the hot water is required to reach, in order to flatten the variable net load. In the second phase, a local control module sends instructions to individual EWHs so as to ensure that the mean thermal energy of the EWHs population follows the target from the OPP. This local controller proposed in Kizilkale and Malhame (2014) is based on the mean field theory and will be denoted by mean field controller (MFC). This second phase is out of the scope of this paper, and the reader is referred to Kizilkale and Malhame (2014); Kizilkale and Malhamé (2013) for more information.

We propose a multistage stochastic optimization model, denoted by *Scheduler* through the rest of the paper, that computes the OPP on a rolling time horizon basis. In this model, uncertainty in load demand and renewable supply is represented through scenario trees (see section 5.4 for more details). At the beginning, the scheduler receives the actual amount of energy stored in the EWHs, and information on the actual total demand as well as the wind production. It then computes the OPP that minimizes the mean variation of the net demand for the scenario tree over T time periods. The value of the OOP at the root node is sent to the MFC (the rest of OPP is not used in the rolling horizon strategy). At the next time step, a new scenario tree is built with the same time horizon, the scheduler receives an update of the actual energy capacity of the EWHs, the actual total demand and wind production at the previous time step, and computes a new OPP using the new scenario tree. These steps are repeated until the end of the time horizon is reached.

The rest of this paper is organized as follows. In Section 5.3 we introduce the aggregate model of EWHs that will be used throughout the paper and illustrate the way to maintain feasibility of the OPP for the MFC. In Section 5.4 we present the *Scheduler*. In section 5.6 we present a case study and the computational results. Section 5.7 concludes the paper.

5.3 Aggregate model of EWHs

Our optimization formulation is designed to work in conjunction with the mean field model proposed in Kizilkale and Malhame (2014), where each individual EWH is modeled by assuming that the reservoir is made up of n fully mixed equal volume layers, the cold water inlet is on the bottom layer and hot water is drawn from the top layer. Because the *Scheduler*'s formulation uses an aggregate model of EWHs by considering a group of homogeneous individual EWHs as one large thermal battery, modeling the EWHs as a single-layer large reservoir with a controllable mean water temperature gives a sufficiently good approximation

of the amount of energy that the EHW population is capable of absorbing as well as of the losses (mostly due to hot water draw events). Thermal energy conservation for the aggregate model of EWHs, also called the system dynamics, is expressed as:

$$e_{t+1} = e_t + x(e_t) - \ell(e_t) \quad (5.1)$$

where e_t is the stored energy in (J) (i.e., the system state) at time step t , $x(e_t)$ is the decision variable that represents the amount of energy one decides to inject into the reservoir, and which depends on the current system state, and it is in (J). $\ell(e_t)$ is the system loss due to heat transfer by conduction and the hot water extraction process.

The first component of the system loss term (i.e., heat transfer by conduction), denoted by $\ell_1(e_t)$ in (J), is defined as:

$$\ell_1(e_t) = KA \left(\frac{e_t}{C_p \rho V} + N_{ewh}(T_L - T_{env}) \right) \Delta t \quad (5.2)$$

where K is the thermal conductivity per unit length of EWHs in $(\text{J/s} \cdot \text{m}^2 \cdot \text{K})$, A is the summation of the surface areas of individual EWHs in (m^2) , C_p is the hot water specific heat in $(\text{J/kg} \cdot \text{K})$, ρ is the water density in (kg/m^3) , V is the summation of the volume of hot water in the EWHs in (m^3) , N_{ewh} is the number of individual EWHs represented in the aggregate model, T_L is the inlet water temperature in (K), and T_{env} is the environment temperature in (K).

Concerning the hot water extraction for an individual EWH, we adopted the model in Kizilkale and Malhame (2014) where water extraction is modeled as a continuous time Markov chain denoted by θ_t , $t \geq 0$, taking values in $\Theta = \{1, 2, \dots, \mathfrak{J}\}$, with the identical infinitesimal generator $\Lambda = \{\lambda_{ij}, i, j = 1, \dots, \mathfrak{J}\}$, where each state consists of different drawn water volumes depending on the type of event such as shower, hand washing, etc. Knowing the probability of occurrence of each state, denoted by \mathbf{p}_i and defined as:

$$\begin{aligned} \mathbf{p}_i &= \frac{\pi_i}{\sum_{k=0}^K \pi_k} \\ \pi_0 &= 1, \quad \pi_i = \frac{\lambda_{0,1} \lambda_{1,2} \dots \lambda_{i-1,i}}{\lambda_{1,0} \lambda_{2,1} \dots \lambda_{i,i-1}} \text{ for } i \geq 1, \end{aligned} \quad (5.3)$$

we can aggregate the losses due to hot water extraction by considering the expected flow of drawn hot water for each type of event i as follows:

$$\ell_2 = \rho C_p (T_{mix} - T_L) \sum_{i=1}^{\mathfrak{J}} N_{ewh} \mathbf{p}_i \dot{V}_i^{mix} \Delta t, \quad (5.4)$$

where we suppose that the end-user mixes hot and cold water together to have the desired flow, denoted by \dot{V}_i^{mix} in (m³/s), and temperature, denoted by T_{mix} in (K), depending on the type of extraction i . As the value of the parameter K is really small (0.473×10^{-6}), the term $\ell_1(e_t)$ is negligible compared to ℓ_2 , which means that most of the thermal losses are due to the water draw events.

The temperature within the reservoirs must be bounded below to prevent bacterial contamination (especially *Legionella pneumophila* whose growth potential is almost zero above 46°C (Lacroix, 1999, see)), and bounded above for end-user safety. The zone between those two bounds is the comfort zone, represented by the constraints (5.5):

$$\begin{aligned} e_{max} &= N_{ewh} \rho V C_p (T_{\max} - T_L) & \forall t, s \\ e_{min} &= N_{ewh} \rho V C_p (T_{\min} - T_L) & \forall t, s, \end{aligned} \tag{5.5}$$

where T_{\min} and T_{\max} are the lower and upper limits of the mean population's temperature respectively in (K). Therefore, the maximum amount of energy the system is able to absorb, $x(e_t)$, depends on the actual stored thermal energy in the EWH, which we call state throughout this paper, e_t , because the nearer its mean current state is to the upper bound, the less energy it is able to accept, and vice versa. Moreover the EWHs will consume a minimum amount of energy to prevent the system from going below the lower limit of the comfort zone.

To bound the aggregate power consumption of EWHs, we considered the MFC module developed in Kizilkale and Malhame (2014) as a black box and used it to calculate the maximum and minimum electric power that the EWH population can consume for all reachable values of e_t . It is important to note that, for a certain energy level, not all members of the EWH population under control reach this exact same energy level, but they are rather distributed around it with a certain variance and skewness, where this distribution cannot be considered as a normal distribution due to the comfort zone constraint which trims the tails of the probability density function; furthermore the variance and skewness depend on the control. In this paper, we conducted a study of the distribution of the EWH population state around a finite set of system state e_t , so that we can randomly generate initial states of EWHs following this pre-calculated probability density function.

For every possible discrete value of a target energy level e_t , we begin the simulation assuming that the EWH population follows a normal distribution with mean μ and variance 1, the MFC is then asked to control the EWH population to make its mean energy state reach e_t . Once the population's mean converges to e_t , we calculate its variance and skewness around e_t , we denote this density function by f_{e_t} . Second, for every e_t , the state of EWH population

is initialized so that its state distribution follows f_{e_t} . The MFC is then asked to get the mean population's temperature up to its lower and upper limits, T_{\min} and T_{\max} respectively, from which the lower and upper aggregate power consumption bounds are calculated.

Figures 5.1, 5.3 and 5.2 show the distribution of the thermal energy of the population when its mean moves towards the lower bound, middle and upper bound of the comfort zone respectively. One can notice two things: (1) the thermal energy distribution has a clear negative skewness due to the hot water draw events that result in thermal losses and in a large portion of the EWHs to reach a temperature below the population's mean temperature, and (2) the distribution's variance shrinks whenever the mean gets closer to the bounds, which affects the population's diversity.

Figure 5.4 shows the simulated results of the maximum and minimum power consumption for 200 EWHs. The feasible region of $x(e_t)$ is the region between the two monotonically non-increasing functions. A linear regression is applied to the upper bound, as shown in Figure 5.5. For the lower bound, we use a convex quadratic regression, as shown in Figure 5.6; the resulting quadratic function is then outer approximated by a piecewise linear function formed using supporting hyperplanes. The linear segments used to approximate the original quadratic function are obtained by taking tangent hyperplanes at chosen points.

5.4 Stochastic model (Scheduler)

Several optimization techniques have been developed to deal with problems that contain uncertain parameters, namely stochastic dynamic programming (Bertsekas, 2007), robust optimization (Ben-Tal and Nemirovski, 2000; Bertsimas et al., 2011; Bertsimas and Sim, 2004; Ferreira et al., 2012), chance-constrained optimization (Dorini et al., 2013), and stochastic optimization with recourse (Birge and Louveaux, 2011b). A review of different optimization approaches that solve problems having uncertain parameters can be found in Sahinidis (2004).

Uncertain parameters are usually modeled either by distributions or by stochastic processes. The former is used when the decision is to be made over one stage, and the latter when a series of decisions have to be taken over multiple stages (Kaut and Wallace, 2003). In our case, a series of decisions are to be taken for all hourly time steps in the planning horizon, and the two stochastic processes that we are dealing with are the uncontrollable demand and wind power production.

Stochastic optimization with recourse is our chosen approach. Except for certain special cases where the model is solvable directly with continuous distributions, most solution methods require discrete distributions of finite cardinality. The continuous random process therefore

has to be approximated by a discrete finite set of outcomes in a form of *scenario tree* that represents the diffusion of stochastic information into the future. The tree represents the multiple stages of observation of the possible outcomes of the random variables in time, and decisions are taken at different stages depending on the available data up the given stage, and regardless of future observations that are considered uncertain. As more observations are revealed, recourse decisions are made in order to rectify sub-optimal solutions that may result from decisions of previous stages.

Figure 5.7 illustrates an example of a scenario tree with three stages, where the root node is the value of the discrete stochastic process $\{\xi_t\}$ at $t = 0$ and considered deterministic (i.e., has a probability of occurrence equal to 1). Two possible outcomes at the next stage $t = 1$ are represented by two nodes with values ω_1 and ω_2 , each of which can lead to two other possible realizations of the random process, (ω_3, ω_4) and (ω_5, ω_6) respectively, with their conditional probabilities shown on the arcs of the tree. Note that the number of stages in a scenario tree does not necessarily reflect the number of time steps in the optimization problem but rather the number of times that new observations of the random process are revealed. The larger the size of the scenario tree, the better the representation of the uncertain stochastic process, but also the larger the optimization problem.

5.4.1 Mathematical model

The objective of the *Scheduler* is to flatten the net demand curve, denoted by p_n (in MW) and equal to the remaining demand after absorbing the renewable production that is dispatched with the highest priority. The means at our disposal is to compute the optimal electric power consumption of the controllable load of EWHs, denoted by $x_n(e_n)$ (in MWh), so that valleys are filled and peaks are shaved while respecting the end-user comfort. Net demand is expressed as

$$p_n = d(\omega_n) - r(\omega_n) + \frac{x_{\hat{n}}(e_{\hat{n}})}{\Delta t} \quad (5.6)$$

where $d(\omega_n)$, $r(\omega_n)$ are respectively observed values of the uncontrollable demand and the wind power production at node $n \in 1, \dots, N$ of the scenario tree with N nodes (both in MW), and Δt is the discrete time step size. To respect the nonanticipativity conditions, the decision $x_{\hat{n}}(e_{\hat{n}})$ is taken at the parent node of node n in the scenario tree, denoted by \hat{n} , before observing the realization of $d(\omega_n)$ and $r(\omega_n)$. At the root node d and r are deterministic (observed) parameters, where d is the actual total demand, and r is the actual wind power.

Flattening the net demand curve consists of minimizing the absolute value of the difference of

the net demands at two consecutive nodes in the scenario tree multiplied by their probability of occurrence:

$$\min_{z \in \mathbb{R}^n} \sum_{n=0}^N Pr_n z_n \quad (5.7)$$

where Pr_n is the absolute probability of occurrence of node n , and z_n is the absolute value of the difference between the net demands at node n and at its parent node \hat{n} . We can model this absolute value using the following linear formulation:

$$z_n \geq p_n - p_{\hat{n}}, \quad z_n \geq p_{\hat{n}} - p_n. \quad (5.8)$$

The resulting stochastic optimization model is:

$$\min_{z \in \mathbb{R}^n} \sum_{n=0}^N Pr_n z_n \quad (5.9)$$

$$\text{s.t.} \quad z_n \geq p_n - p_{\hat{n}} \quad \forall n \quad (5.10)$$

$$z_n \geq p_{\hat{n}} - p_n \quad \forall n \quad (5.11)$$

$$p_n = d(\omega_n) - r(\omega_n) + \frac{x_{\hat{n}}(e_{\hat{n}})}{\Delta t} \quad \forall n \quad (5.12)$$

$$e_n = e_{\hat{n}} + x_{\hat{n}}(e_{\hat{n}}) - \ell(e_{\hat{n}}) \quad \forall n \quad (5.13)$$

$$\ell_1(e_n) = KA \left(\frac{e_n}{C_p \rho V} + N_{ewh}(T_L - T_{env}) \right) \Delta t \quad \forall n \quad (5.14)$$

$$\ell_2 = \rho C_p (T_{mix} - T_L) \sum_{i=1}^J N_{ewh} \mathbf{p}_i \dot{V}_i^{mix} \quad (5.15)$$

$$\ell(e_{\hat{n}}) = \ell_1(e_n) + \ell_2 \quad (5.16)$$

$$e_o = N \rho V C_p (T_{init} - T_L) \quad (5.17)$$

$$e_n \leq N_{ewh} \rho V C_p (T_{\max} - T_L) \quad \forall n \quad (5.18)$$

$$e_n \geq N_{ewh} \rho V C_p (T_{\min} - T_L) \quad \forall n \quad (5.19)$$

$$x_n(e_n) \leq A_1(e_n) + B_1 \quad \forall n \quad (5.20)$$

$$x_n(e_n) \geq \underline{Q}(e^i) + \hat{\underline{Q}}(e^i)(e_n - e^i) \quad \forall n, i \quad (5.21)$$

$$x_n(e_n) \geq 0 \quad (5.22)$$

$$e_n \geq 0 \quad (5.23)$$

where we also included the bounds over $x_n(e_n)$ from the regression approximation.

5.5 Scenario generation

In this section we describe the steps to generate the multi-stage scenario tree for our stochastic optimization problem.

Artelys, a company specialized in optimization, decision-support and modeling, cooperated with us by developing a load forecast model trained over a set of historical data of power consumption from 2012 to 2014 provided by supervisory control and data acquisition (SCADA) of the Coopérative Régionale d'Electricité de Saint-Jean-Baptiste de Rouville (CoopSJB). The CoopSJB data are collected from five distribution substations in Mont Saint-Hilaire, a suburb of Montreal, for 6,819 houses. These data are normalized to get the mean power consumption per house. The forecast model takes as inputs the hourly wind speed and temperature of day d_k and the hourly forecast for day d_{k+1} , and outputs the hourly load demand forecast for d_{k+1} . Multiple load demand curves are generated using wind speed and temperature ensemble forecasts provided from Environment Canada that releases each day a set of 22 forecasts for the next 144 hours. The uncontrollable demand component is obtained by computing an estimate of the hourly consumption of EWHs using the data from CoopSJB, and subtracting this estimate from the total demand. Wind power scenarios are generated from the wind speed ensemble forecasts using the approach proposed in Tammam et al. (2015). Every uncontrollable load demand scenario is coupled with its correspondent wind power scenario resulting from the same wind speed forecast.

In this way, a fan of scenarios is constructed with 22 scenarios and 24 nodes per scenario for the 24-hour horizon, where each node has two (hourly) values: uncontrollable demand and wind power production. A fan of scenarios does not reflect well the future uncertainty as it omits its nonanticipative property. For this reason we apply the forward construction algorithm described in Heitsch and Römisch (2007) to the fan of scenarios to obtain a nonanticipative scenario tree.

5.6 Case study and Results

The results presented here come from a case study developed in the context of the project **smartDESC** (smart Distributed Energy Storage Controller), whose objective is to perform a proof of concept of a hierarchical control architecture to manage the power consumption of dispersed energy storage devices throughout the electric grid (such as electric water heaters, space heaters, or electric vehicles), in order to mitigate the intermittency in power production caused mainly by the increasing penetration of renewable energy resources. The reader is referred to (Kizilkale et al., 2016) for further information about the project architecture.

5.6.1 Results

The aggregate model used throughout this case study represents a population of 200 EHWs; however the depicted curves in this section are averaged over 200 houses. The planning horizon is 24 hours long with hourly time steps. The rolling horizon approach was applied: at every time step t , a new scenario tree, denoted by $\{\xi_t\}_{t \in T}$, is created depending on the available wind speed and demand forecasts. Only the optimal solution at the root node $\xi_{0,t}$ of the scenario tree is considered and the solution for the rest of the scenario tree is omitted, where the root node contains the values of total demand and wind production actually observed from the previous time step $t - 1$.

The wind power production scenarios are scaled so that the average of their maximum values over the planning horizon is equal to 10% of the average value of the maximum uncontrollable demand over the same horizon. This was done in order to test the load curve shaving the system can reach when the maximum wind power production is on average equal to 10% of the uncontrollable demand.

As previously mentioned, the root node of the scenario tree $\{\xi_t\}_{t \in T}$ contains the actual realization of the total demand and wind power, thus a deterministic observation of those two parameters has to be constructed over the planning horizon. We present three cases in which the mean uncontrollable demand forecast is considered as the observed uncontrollable demand, and this demand is coupled with three different wind power observations: maximum, average and minimum wind power. This is depicted in Figures 5.8, 5.9 and 5.10, where the upper curve is the uncontrolled demand, the lower curve is the net demand, and the region in cyan between them represents the magnitude of wind power.

Figures 5.11, 5.12 and 5.13 depict the load shaving curves with low, average and high wind penetration, where the total target power curve is the EWH optimal power consumption that the *Scheduler* computes, whereas the total simulated power curve is the real EWH power consumption the MFC is able to achieve. These graphs show that in general the target power consumption profile generated by the *Scheduler* is feasible with respect to the MFC (i.e., the EWH simulated power curve and the EWH target power curve are almost overlapped); however in some parts of the graph, the MFC power consumption deviates from the target power profile. A solution for this problem was developed and will be reported in a forthcoming paper.

Table 5.1 shows the peak reduction resulting from the direct control of the power consumption of the EWH population as a percentage of the peak of load in the thermostatic control mode (third column); the reduction in demand variance as a percentage of the demand with the

thermostatic control of EWHs (forth column); and the computational time required to solve the stochastic optimization problem with rolling horizon (last column). The reduction in demand variance is an estimate of how well the net demand curve is flattened. It is obvious that the more wind power is added to the grid, the greater the variation in the net demand, and the more challenging it is to manage the EWH load to reduce the demand fluctuation. This is illustrated by comparing the net demand variation reduction for every wind blow scenario when the mean wind penetration is 10% versus 20% in Table 5.1.

Two other observations are important to make. First, Figure 5.14 shows that when the wind power penetration to the grid increases, the net demand load curve fluctuation reduction decreases; this is because of the limited storage capacity of EWHs to absorb the wind power intermittence. On the other hand, Figure 5.15 illustrates how this increase in wind power permits the operator to reduce its peak of the load curve, though eventually this gain in peak reduction decreases as the penetration of renewables increases. These results were obtained with a participation of 100% of the population of EWHs in the demand response program.

5.7 Conclusion

In this article we proposed a multi-stage stochastic optimization model for load shaving in the presence of renewable resources attached to the grid, by mean of the storage capacity of residential electric water heaters. This model is a part of the project smartDESC that offers a hierarchical control architecture that controls dispersed controlled devices locally and more efficiently while achieving the global system operator goals of peak shaving and net demand flattening. The model shows the impact of renewable upon the variability of net demand curve which gives the system operator an idea about how much renewable power it can afford while maintaining a stable and servable demand.

5.8 Acknowledgements

This work was funded by an ECO Energy Innovation Initiative grant from Natural Resources Canada, and by the NSERC Energy Storage Technologies (NEST) Strategic Network.

Table 5.1 Comparison between 3 cases of wind blow for 10% and 20% of wind power penetration during 3 days

Wind Penetration	Wind blow	Peak Shaving (%)	Net Demand Variation Reduction (%)	Time (sec)
10%	High Wind	6.68	46.40	21.535
	Average Wind	7.85	49.42	21.471
	Low Wind	7.84	50.82	21.454
20%	High Wind	6.51	32.82	22.674
	Average Wind	8.57	42.60	21.849
	Low Wind	8.46	45.16	22.544




Figure 5.1 Population distribution near the lower bound




Figure 5.2 Population distribution near the upper bound




Figure 5.3 Population distribution at the middle of the comfort zone

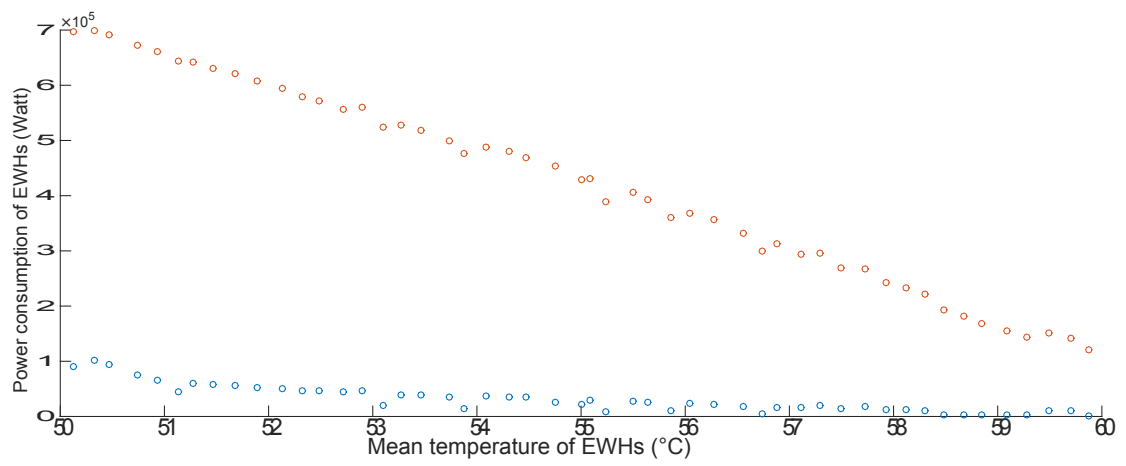


Figure 5.4 Simulated bounds




Figure 5.5 Linear regression for the upper bound

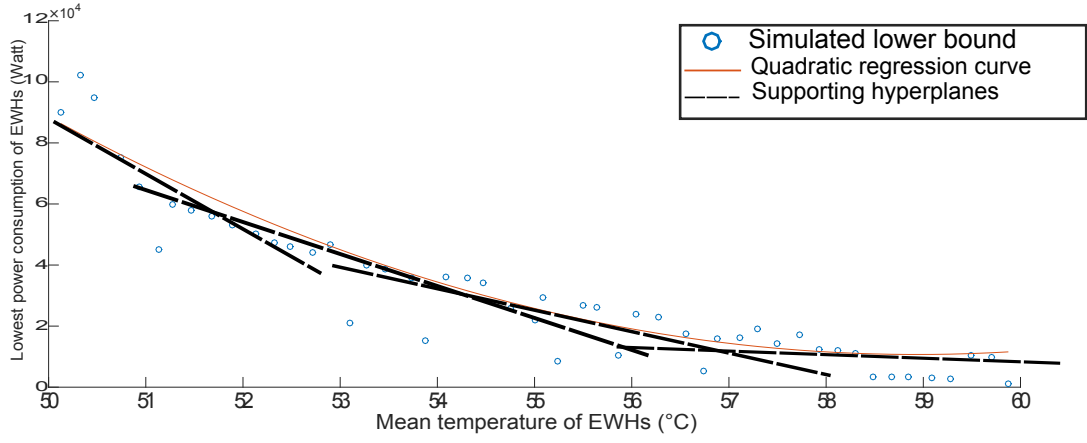


Figure 5.6 Quadratic regression for the lower bound




Figure 5.7 Three-stage scenario tree




Figure 5.8 Case study with minimum wind power




Figure 5.9 Case study with average wind power




Figure 5.10 Case study with maximum wind power




Figure 5.11 Load shaving with low wind power




Figure 5.12 Load shaving with average wind power




Figure 5.13 Load shaving with high wind power




Figure 5.14 Reduction of Daily Fluctuation versus Wind Penetration




Figure 5.15 Mean Daily Peak Reduction versus Wind Penetration

CHAPITRE 6 CONVERGENCE VERS UN PROFIL DE TEMPÉRATURE DE CONSIGNE RÉALISABLE POUR LE CONTRÔLEUR À CHAMP MOYEN

6.1 Introduction

Dans le chapitre 5, nous avons présenté un modèle stochastique, ci-après appelé *Scheduler*, dont l'objectif était de lisser la courbe de charge nette afin de minimiser les pointes quotidiennes de demande et de réduire la fluctuation occasionnée par la pénétration de sources d'énergie renouvelables, et ce, en mettant à disposition un nombre de chauffe-eau contrôlables. Ces derniers sont modélisés dans le programme d'optimisation sous forme d'un modèle agrégé qui reflète le comportement moyen d'une population de chauffe-eau ; ainsi ce modèle agrégé joue le rôle d'une immense batterie thermique ou d'un méga chauffe-eau. Le programme stochastique calcule le profil optimal de puissance électrique horaire constante par morceaux du modèle agrégé, qui est traduit par la suite en un profil de température de consigne et transmis aux contrôleurs locaux. Ces derniers appliquent à leur tour la commande à champ moyen (CCM) qui contrôle localement les chauffe-eau de façon à ce que la température moyenne de la population suive le profil de température de consigne.

Les résultats illustrés dans le chapitre précédent montrent le bon fonctionnement de cette approche. Cependant, comme le *Scheduler* considère le comportement moyen de la population de chauffe-eau, il surestime parfois leur capacité à suivre le profil de température prescrit, et ce, même en présence des bornes sur la puissance qui sont calculées en fonction de leur température moyenne actuelle. Ces bornes sont évaluées en supposant que la distribution de la température de chauffe-eau est connue selon leur température moyenne, tel que nous l'avons expliqué dans le chapitre précédent. Cette hypothèse s'avère simpliste, car la dynamique de chauffe-eau se révèle être un système avec mémoire, en d'autres termes, la distribution de la température des chauffe-eau au pas de temps t est déterminée en fonction de sa distribution au pas de temps précédent $t - 1$ ainsi que de la température de consigne à $t - 1$. Nous pouvons remarquer ce comportement sur les courbes de puissance dans les Figures 5.11, 5.12 et 5.13, où la courbe de puissance réalisée par le CCM s'écarte parfois de la courbe estimée par le *Scheduler*. Cet écart entre la puissance moyenne désirée et celle réalisée, sur une certaine période, implique qu'une divergence se produit entre la variation d'énergie demandée et celle réellement réalisable par le groupe de chauffe-eau durant cette période, car la température de consigne n'est pas atteignable par l'ensemble des chauffe-eau.

Dans le cadre du projet SmartDesc, Romain Losseau a développé un module qui reçoit du

Scheduler un profil de température de consigne constante par morceaux sur la journée et vérifie si ces consignes sont atteintes par le CCM. Quand des segments du profil de température de consigne ne sont pas atteignables, en d'autres termes, quand des valeurs de consigne surestiment la capacité réelle des chauffe-eau, ce module renvoie au *Scheduler* des bornes sur la puissance minimale et maximale plus serrées sur les segments en question. Le *Scheduler* recalcule à son tour un nouveau profil de température de consigne en tenant compte des nouvelles contraintes sur la puissance et retransmet ce nouveau profil au module susmentionné. Cette procédure continue ainsi jusqu'à ce que le système converge vers un profil de température dont tous les segments sont atteignables par le CCM. Nous appellerons ce module le *Générateur de Contraintes de Réalisabilité* (GCR).

Dans ce chapitre, nous présentons la preuve de convergence de cette technique, suivie de résultats numériques montrant les conséquences sur la qualité du lissage de la courbe de demande nette. La preuve présentée ci-après est développée dans le cadre d'un programme d'optimisation déterministe, c'est-à-dire que nous supposons que l'on dispose d'une prévision déterministe parfaite de la composante non contrôlable de la demande sur une journée, l'objectif étant de calculer la consommation optimale journalière des chauffe-eau contrôlables afin de lisser le plus possible la courbe de demande totale.

Dans les résultats présentés ci-après, nous omettrons la composante de la production des sources d'énergie renouvelables dans la demande nette, et ce, parce que la preuve de convergence est faite dans le contexte d'un programme d'optimisation linéaire dont tous les paramètres sont déterministes ; par conséquent, la conclusion issue de la preuve reste valide sans ou avec l'ajout d'une prévision déterministe des sources d'énergie renouvelables à la demande nette.

6.2 Modèle déterministe

Commençons par présenter la version déterministe du modèle d'optimisation (5.9) - (5.21) comme suit :

$$(PL) \quad \min_{z \in \mathbb{R}^n} \sum_{t=0}^T z_t \quad (6.1)$$

$$\text{s.t.} \quad z_t \geq p_t - p_{t-1} \quad \forall t \quad (6.2)$$

$$z_t \geq p_{t-1} - p_t \quad \forall t \quad (6.3)$$

$$p_t = d_t + \frac{x_t}{\Delta t} \quad \forall t \quad (6.4)$$

$$e_t = e_{t-1} + x_t - \ell(e_{t-1}) \quad \forall t \quad (6.5)$$

$$\ell_1(e_t) = KA \left(\frac{e_t}{C_p \rho V} + N_{ewh}(T_L - T_{env}) \right) \Delta t \quad \forall t \quad (6.6)$$

$$\ell_2 = \rho C_p (T_{mix} - T_L) \sum_{i=1}^J N_{ewh} \mathbf{p}_i \dot{V}_i^{mix} \quad (6.7)$$

$$\ell(e_{t-1}) = \ell_1(e_{t-1}) + \ell_2 \quad (6.8)$$

$$e_o = N \rho V C_p (T_{init} - T_L) \quad (6.9)$$

$$e_t \leq N_{ewh} \rho V C_p (T_{max} - T_L) \quad \forall t \quad (6.10)$$

$$e_t \geq N_{ewh} \rho V C_p (T_{min} - T_L) \quad \forall t \quad (6.11)$$

L'indice n dans le modèle stochastique indiquant un nœud dans l'arbre de scénario est remplacé par l'indice t qui désigne un pas de temps de 15 minutes d'un horizon de planification de taille T , d_t désigne la prévision déterministe de la composante non contrôlable de la demande au pas de temps t , et les deux bornes (5.20) et (5.21) sur la puissance sont relaxées parce que des nouvelles bornes seront générées au fur et à mesure par le GCR. Tel qu'il est illustré par la Figure 6.1, nous constatons que quelques segments du profil de puissance calculé par le modèle d'optimisation (6.1) - (6.11), indiqué sur la figure par *W-H target power*, sont parfois difficiles à réaliser par le CCM (la courbe indiquée par *W-H simulated power*), notamment sur les segments dans les troisième, sixième et septième journées. Dans cette simulation, le pas de temps est réduit d'une heure (comme dans le chapitre 5) à 15 minutes, car pour des segments d'une heure le champ moyen tente d'atteindre rapidement la consigne et s'y stabilise ensuite. Cela avait pour effet de générer des pointes de puissance au début du segment, alors nous réduisons ces effets de pointes avec des segments de 15 minutes.

6.3 Correction du profil de température de consigne

Le GCR corrige ce profil en calculant des bornes sur la puissance minimale et maximale pour les segments qui sont non atteignables par le CCM, et ce de façon itérative. Pour ce faire, au




Figure 6.1 Résultats déterministes (voir Kizilkale et al., 2016)

début de chaque itération le *Scheduler* envoie au GCR un vecteur de 96 valeurs représentant le profil de température de consigne constante par morceaux toutes les 15 minutes sur une journée, dénoté par $y_{t_k}, t = \{1, \dots, 96\}$, où k est l'indice de l'itération. Par abus de langage, nous nous permettons de parler de la variable de décision y_t car elle est calculée directement à partir de la variable de décision e_t du PL comme suit :

$$y_t = \frac{e_t}{N_{ewh} \rho V C_p} + T_L$$

Le GCR commence par supposer initialement une distribution normale des chauffe-eau de variance 1 centrée en une température quelconque, les bornes sur la puissance minimale $\tau_{\min_k}^t$ et maximale $\tau_{\max_k}^t$, pour le $t^{\text{ème}}$ segment à l'itération k , sont initialisées soit à 0 et P_{nominale} respectivement pour $k = 0$, soit par leurs valeurs provenant de l'itération précédente $k - 1$. Le GCR calcule la distribution de la population de chauffe-eau à la fin du segment t_k à partir de la consigne y_{t_k} et de la distribution calculée à la fin du segment précédent $t_k - 1$, la température moyenne réellement atteinte à la fin du segment t_k est donc connue, désignée par \tilde{y}_{t_k} . Trois scénarios sont donc possibles :

1. $|\tilde{y}_{t_k} - y_{t_k}| < \varepsilon$. Dans ce cas, la consigne générée par le *Scheduler* pour le segment t_k est facilement atteinte par le CCM ; par conséquent, les bornes restent inchangées par

rapport à celles obtenues à l'itération précédente

$$\tau_{\min_k}^t = \tau_{\min_{k-1}}^t$$

$$\tau_{\max_k}^t = \tau_{\max_{k-1}}^t$$

2. $\tilde{y}_{t_k} - y_{t_k} > \varepsilon$. Cela signifie que le CCM n'est pas capable de baisser la température moyenne des chauffe-eau au $t^{\text{ème}}$ segment comme désiré ; ainsi la borne inférieure sur ce segment devrait augmenter en prenant la valeur

$$\tau_{\min_k}^t = U_k^t$$

3. $y_{t_k} - \tilde{y}_{t_k} > \varepsilon$. Ici le *Scheduler* donne une température de consigne plus haute que ce qui est atteignable au $t^{\text{ème}}$ segment, et la borne supérieure sur ce segment est donc mise à jour avec la puissance que le CCM est capable de réaliser

$$\tau_{\max_k}^t = U_k^t$$

où U_k^t est la puissance moyenne développée par le CCM sur le segment t_k pour atteindre la température moyenne \tilde{y}_{t_k} à l'itération k .

À la fin de chaque itération de l'algorithme, les nouveaux vecteurs τ_{\min_k} et τ_{\max_k} sont renvoyés au *Scheduler* qui recalcule à son tour le nouveau profil de température de consigne en tenant compte des nouvelles bornes. Ce mécanisme procède ainsi jusqu'à converger vers un profil où $\|\tilde{y}_k - y_k\|_\infty = \max_{i_k} \{|\tilde{y}_{t_k} - y_{t_k}|\} \leq \varepsilon$. Les contraintes sur la puissance ne sont jamais relaxées d'une itération à une autre, autrement dit

$$\tau_{\min_k}^t = \max\{\tau_{\min_{k-1}}^t, \tau_{\min_k}^t\},$$

$$\tau_{\max_k}^t = \min\{\tau_{\max_{k-1}}^t, \tau_{\max_k}^t\}.$$

Cela a pour objectif de garder les bornes les plus dominantes sur chaque segment et de faire en sorte que le *Scheduler* ne génère pas le même profil de température pour deux itérations différentes entravant la convergence de l'algorithme. Bien entendu, cette approche conservatrice a comme désavantage de conserver des bornes qui pourraient être inutiles dans les itérations suivantes, car le calcul de bornes dépend uniquement de l'état initial et du profil de température de consigne et non pas des bornes antérieures. Le mémoire de maîtrise de Losseau (2016) explique de façon détaillée le mécanisme de fonctionnement du GCR.

6.4 Preuve de convergence

Dans ce chapitre, nous présentons la preuve de convergence de ce mécanisme itératif vers un profil atteignable par le CCM.

Commençons par faire une incartade du côté de la topologie :

Soit Ω un produit cartésien de n intervalles fermés et bornés dans \mathbb{R} , où $(\tau_{\min_k}; \tau_{\max_k}) \in \Omega \times \Omega$.

Puisque le produit cartésien fini de n intervalles fermés bornés de \mathbb{R} est un fermé borné de \mathbb{R}^n , alors Ω est un fermé borné de \mathbb{R}^n .

Tout au long de ce chapitre, nous utiliserons la métrique induite par la norme $\|\cdot\|_\infty$, définie par

$$x = (x_1, x_2, \dots, x_n) \mapsto \|x\|_\infty := \max_{1 \leq i \leq n} |x_i|.$$

Soit $g : \mathbb{R}^n \rightarrow \Omega \times \Omega$, une fonction qui prend en entrée le profil de température $y_k \in \mathbb{R}^n$ et renvoie en sortie le vecteur $\tau_k := \begin{pmatrix} \tau_{\min_k} \\ \tau_{\max_k} \end{pmatrix} \in \Omega \times \Omega$, où k est l'indice de l'itération.

Soit $f : \Omega \times \Omega \rightarrow \mathbb{R}^n$, une fonction qui prend en entrée les deux vecteurs $\tau_{\min_{k-1}}$ et $\tau_{\max_{k-1}}$, résout le programme d'optimisation linéaire (PL) et renvoie en sortie le vecteur de profil de température de consigne y_k à la k^{eme} itération.

Remarque 1 *En pratique, la fonction g n'est pas continue. Par exemple, $\tau_{\min_k}^t = 0$ tant que la consigne est atteinte sur le segment t à epsilon près. Au moment où la consigne devient trop basse pour être atteinte, $\tau_{\min_k}^t$ saute de 0 à U_k^t . Par contre, la fonction qui calcule U_k^t en fonction de la consigne est continue. En effet, cette discontinuité est due au fait qu'une consigne est considérée atteinte lorsque $|\tilde{y}_{t_k} - y_{t_k}| < \varepsilon$ pour $\varepsilon > 0$, or si $\varepsilon = 0$, g sera une fonction continue. Par conséquent, en considérant que ε est assez faible, nous pouvons supposer que la fonction g est continue sur un voisinage de y_k (disons une boule de centre y_k et de rayon $\hat{\varepsilon} > 0$).*

Remarque 2 *La fonction f renvoie la solution optimale d'un programme linéaire compte tenu des nouvelles bornes sur les variables de décisions. Le changement de la solution optimale est discontinu face au changement du second membre des contraintes, sauf dans le cas où ce dernier est assez faible comme nous dit l'analyse de sensibilité de programmes linéaires.*

On a donc

$$(g \circ f) \begin{pmatrix} \tau_{\min_{k-1}} \\ \tau_{\max_{k-1}} \end{pmatrix} = \begin{pmatrix} \tau_{\min_k} \\ \tau_{\max_k} \end{pmatrix}.$$

Nous voulons donc montrer qu'il existe un vecteur $\tau = \begin{pmatrix} \tau_{\min} \\ \tau_{\max} \end{pmatrix}$ tel que

$$(g \circ f)(\tau) = \tau.$$

Nous faisons l'hypothèse que pour tout k , il existe une et une seule solution optimale du PL ; dans le cas contraire, nous prenons la solution la plus grande au sens lexicographique. Nous faisons ces hypothèses car si pour une itération k , les bornes de puissance générées par le GCR (τ_k) rendent le PL non réalisable, le PL ne sera plus en mesure de fournir au CCM un profil de consigne atteignable et le mécanisme s'arrête. L'hypothèse de l'unicité de la solution optimale garantit la convergence dans la preuve présente.

Théorème 1 (Skandalis (2004)) *Tout fermé d'un espace complet est complet.*

Puisque Ω est un fermé de l'espace complet \mathbb{R}^n , alors Ω est complet.

Tel qu'il est expliqué dans la section 6.3, les bornes ne sont jamais relaxées d'une itération à l'autre ; par conséquent, $\tau_{\min_k}^t \geq \tau_{\min_{k-1}}^t$ et $\tau_{\max_k}^t \leq \tau_{\max_{k-1}}^t$, où $\tau_{\min_k}^t$ désigne la $t^{\text{ème}}$ composante du vecteur τ_{\min_k} .

Proposition 1 *Toute suite croissante (respectivement décroissante) majorée (respectivement minorée) est convergente.*

Comme Ω est borné, et $\tau_{\min_k} \in \Omega$, alors la suite $\{\tau_{\min_k}^t\}_{k=1}^\infty$ est à son tour bornée. Par conséquent, en vertu de sa monotonie, la suite $\{\tau_{\min_k}^t\}_{k=1}^\infty$ converge. De même, la suite $\{\tau_{\max_k}^t\}_{k=1}^\infty$ converge. Comme chacune des composantes des vecteurs τ_{\min_k} et τ_{\max_k} est convergente, alors les suites de vecteurs $\{\tau_{\min_k}\}_{k=1}^\infty$ et $\{\tau_{\max_k}\}_{k=1}^\infty$ sont aussi convergentes.

Soit $\tilde{\tau}_{\min}$ et $\tilde{\tau}_{\max}$ les limites respectives de $\{\tau_{\min_k}\}_{k=1}^\infty$ et $\{\tau_{\max_k}\}_{k=1}^\infty$. Compte tenu du fait que Ω est un fermé de \mathbb{R}^n , alors il contient tous ces points adhérents, donc $\tilde{\tau}_{\min}$ et $\tilde{\tau}_{\max}$ sont dans Ω .

Jusqu'à présent nous avons démontré que les suites des bornes générées par la fonction g en réponse à la sortie de la fonction f convergent. Nous voulons maintenant démontrer que le système admet un point fixe.

Un programme linéaire peut s'écrire sous la forme standard :

$$\begin{aligned} (\text{PL}) \quad & \min_x \quad c^T x \\ \text{s.t.} \quad & Ax = b \\ & x \geq 0. \end{aligned}$$

Une base d'une solution est réalisable si

$$B^{-1}b \geq 0,$$

et elle est optimale si

$$c_H^T - c_B^T B^{-1}H \geq 0,$$

où B est une sous matrice de A formée des coefficients associés aux variables de base x_B , H , une sousmatrice de A formée des coefficients associés aux variables hors base x_H et c_H^T, c_B^T les coefficients du vecteur c^T associés à x_H et x_B respectivement.

L'analyse de sensibilité d'un programme linéaire nous dit que lorsque la perturbation dans les membres de droite des contraintes b est de l'ordre de ε , la condition de réalisabilité reste satisfaite, par conséquent la base de la solution B ne change pas, tandis que la solution varie linéairement en fonction de cette perturbation (voir Griva et al., 2009)

$$\bar{x}_B = x_B + B^{-1}\varepsilon,$$

c'est-à-dire que, dans notre contexte, pour tous les nombres réels positifs ε_1 et ε_2 , les deux vecteurs bornes τ_{\min_k} et τ_{\max_k} sont proches de $\tilde{\tau}_{\min}$ et $\tilde{\tau}_{\max}$ respectivement, et ce pour k assez grand ; nous avons donc

$$\|\tau_{\min_k} - \tilde{\tau}_{\min}\|_{\infty} \leq \varepsilon_1,$$

$$\|\tau_{\max_k} - \tilde{\tau}_{\max}\|_{\infty} \leq \varepsilon_2.$$

Soit $\varepsilon > 0$ un réel quelconque. Il existe $N_0 \in \mathbb{N}$ tel que pour $k > N_0$ assez grand nous avons

$$\tau_k - \tilde{\tau} = \begin{pmatrix} \tau_{\min_k} - \tilde{\tau}_{\min} \\ \tau_{\max_k} - \tilde{\tau}_{\max} \end{pmatrix} = \begin{pmatrix} \xi_1 \\ \xi_2 \end{pmatrix},$$

où $\begin{pmatrix} \xi_1 \\ \xi_2 \end{pmatrix}$ est un vecteur de \mathbb{R}^{2n} de norme inférieure à ε .

Posons $f(\tau_k) = y_k$. Compte-tenu de l'analyse de sensibilité mentionnée ci-dessus, nous avons

$$f(\tilde{\tau}) = \begin{pmatrix} y_{k_B} \\ y_{k_H} \end{pmatrix} + \begin{pmatrix} (B^{-1}\Delta\xi)_{y_{k_B}} \\ 0 \end{pmatrix},$$

où $(B^{-1}\Delta\xi)_{y_{k_B}}$ le sous-vecteur du vecteur $(B^{-1}\Delta\xi)$ dont les éléments sont associés aux variables de base y_{k_B} , $B \in \mathbb{R}^{m \times m}$ est la matrice de base, m le nombre de contraintes du PL et

$$\Delta\xi := \begin{pmatrix} 0 \\ \tau_{\min_k} - \tilde{\tau}_{\min} \\ \tau_{\max_k} - \tilde{\tau}_{\max} \end{pmatrix} \in \mathbb{R}^m.$$

Observons que

$$\|g(f(\tau_k)) - g(f(\tilde{\tau}))\|_\infty = \left\| g \begin{pmatrix} y_{k_B} \\ y_{k_H} \end{pmatrix} - g \begin{pmatrix} y_{k_B} + (B^{-1}\Delta\xi)_{y_{k_B}} \\ y_{k_H} \end{pmatrix} \right\|_\infty.$$

Puisque

$$\begin{aligned} \left\| \begin{pmatrix} y_{k_B} \\ y_{k_H} \end{pmatrix} - \begin{pmatrix} y_{k_B} + (B^{-1}\Delta\xi)_{y_{k_B}} \\ y_{k_H} \end{pmatrix} \right\|_\infty &= \left\| \begin{pmatrix} (B^{-1}\Delta\xi)_{y_{k_B}} \\ 0 \end{pmatrix} \right\|_\infty \\ &\leq \left\| \begin{pmatrix} B^{-1}\Delta\xi \\ 0 \end{pmatrix} \right\|_\infty \\ &= \|B^{-1}\Delta\xi\|_\infty \\ &\leq \|B^{-1}\|_{\mathcal{M}_m(\mathbb{R})} \times \|\Delta\xi\|_\infty \\ &\leq \|B^{-1}\|_{\mathcal{M}_m(\mathbb{R})} \times \varepsilon \xrightarrow{\varepsilon \rightarrow 0} 0. \end{aligned}$$

où la norme matricielle est définie par

$$\|A\|_{\mathcal{M}_m(\mathbb{R})} := \sup_{x \neq 0} \frac{\|Ax\|_\infty}{\|x\|_\infty} = \sup_{\|x\|_\infty=1} \|Ax\|_\infty, x \in \mathbb{R}^n.$$

Ainsi, en nous servant de la continuité “locale” de la fonction g , nous obtenons

$$\|g(y_k) - g(y_k + B^{-1}\varepsilon)\|_\infty \xrightarrow{\varepsilon \downarrow 0} 0.$$

Cela nous permet de déduire que

$$\|g(f(\tau_k)) - g(f(\tilde{\tau}))\|_{\infty} < \varepsilon,$$

ce qui veut dire que

$$\lim_{k \rightarrow +\infty} g(f(\tau_k)) = g(f(\tilde{\tau})).$$

Mais

$$g(f(\tau_k)) = \tau_{k+1},$$

donc en appliquant la limite de part et d'autre de l'égalité nous obtenons

$$\lim_{k \rightarrow +\infty} g(f(\tau_k)) = \lim_{k \rightarrow +\infty} \tau_{k+1},$$

donc

$$g(f(\tilde{\tau})) = \tilde{\tau}.$$

En conclusion, $\tilde{\tau}$ est un point fixe de $g \circ f$ dans Ω .

6.5 Résultats numériques

Dans cette section, nous présentons les résultats numériques issus d'une simulation du mécanisme expliqué ci-dessus menée sur 200 chauffe-eau. Nous considérons qu'une consigne n'est pas atteinte quand la valeur absolue de la différence entre la valeur de consigne et la valeur de la température atteinte par le CCM est supérieure à $0,4^{\circ}C$. Cette simulation a été effectuée en collaboration avec Romain Losseau.

La figure 6.2 illustre le profil de température de consigne constante par morceaux calculé par le *Scheduler* avec τ_{\min} et τ_{\max} initialisés à 0 et $P_{nominale}$ respectivement. Comme nous le constatons sur la figure, quelques segments dans le profil de consignes ne sont pas atteints par le CCM, notamment vers $t = 600$ min, $t = 900$ min et $t = 1300$ min. Le GCR serre à son tour la borne supérieure vers $t = 900$ min et les bornes inférieures vers $t = 600$ min et $t = 1300$ min comme l'illustre la figure 6.3.

Le *Scheduler* résout à nouveau le problème d'optimisation en tenant compte de nouvelles bornes sur la puissance et calcule un nouveau profil de température de consigne. Le mécanisme converge vers un point fixe à la deuxième itération avec un profil de consigne atteignable à $0,4^{\circ}C$ près, comme illustré par la figure 6.4. Le prix à payer pour corriger le profil de consigne est la dégradation du lissage de la courbe de demande; cependant, cette dégradation reste bénéfique car la pointe de charge issue de cette technique reste inférieure à la pointe de la

demande originale comme illustré par la figure 6.5.




Figure 6.2 Profil de consigne inatteignable après la 1^{ère} itération (voir Losseau, 2016)




Figure 6.3 Bornes sup et inf sur la puissance après la 1^{ère} itération




Figure 6.4 Profil de consigne atteignable après la 2^{ème} itération (voir Losseau, 2016)




Figure 6.5 Lissages de la demande nette à chaque itération (voir Losseau, 2016)

CHAPITRE 7 DISCUSSION GÉNÉRALE

7.1 Synthèse des travaux

Les éléments de cette thèse répondent au problème de gestion de la demande électrique des chauffe-eau résidentiels quand nous utilisons ceux-ci pour lisser la courbe de demande nette et atténuer l’intermittence de la production éolienne. Cette étude a été accomplie dans le cadre du projet **smartDESC**, où une approche hiérarchique de contrôle de chauffe-eau a été mise en œuvre. Cette approche est constituée de deux phases : la première phase, dans laquelle s’inscrit cette thèse, consistait à développer un modèle d’optimisation stochastique. Ce modèle d’optimisation est responsable de calculer le profil optimal de consommation électrique d’un modèle agrégé d’une population de chauffe-eau. Le modèle agrégé de chauffe-eau représente leur comportement moyen et le profil de consommation est calculé sur un horizon de 24 heures. Ce profil est envoyé sous forme d’un profil de température de consigne aux contrôleurs locaux qui constituent la seconde phase. Les contrôleurs locaux à champ moyen contrôlaient à leur tour les chauffe-eau localement de façon à ce que la température moyenne de la population de chauffe-eau suive ces consignes.

Afin de représenter l’intermittence de la production éolienne dans le modèle d’optimisation stochastique, nous avons présenté dans le chapitre 4 une méthode de génération d’une prévision probabiliste de la production éolienne. Cette prévision probabiliste est le résultat d’une extrapolation de la prévision d’ensemble d’une hauteur de 10 mètres au-dessus du niveau du sol à la hauteur des turbines des éoliennes (~ 100 mètres). L’extrapolation de données à 10 mètres de haut vers des données à 100 mètres est une opération courante en météorologie et différentes méthodes existent pour y parvenir. Typiquement, ces méthodes utilisent des relations logarithmiques ou exponentielles paramétrées par la nature du sol via une hauteur de rugosité et par la mesure de la stabilité de l’atmosphère (comme la longueur de Monin-Obukhov). La nouveauté de notre approche consiste à extrapoler ces données au moyen d’un modèle de régression linéaire entraîné sur des données de prévisions déterministes calculées à une altitude de 100 mètres et qui nous ont été fournies par l’entreprise partenaire WPred. Nous avons montré que cette méthode est efficace en matière de représentation de l’incertitude de la prévision du vent, où l’écart type du faisceau des scénarios de prévision d’ensemble extrapolée varie proportionnellement avec l’erreur de la prévision du vent. Cela permet au gestionnaire du réseau électrique de prendre des décisions robustes face à l’incertitude de la production éolienne.

Dans le chapitre 5, nous avons présenté le modèle d’optimisation stochastique multi-étapes.

Notre second partenaire industriel Artelys nous a fourni un modèle qui prévoit la charge électrique en fonction de la prévision de la vitesse du vent et de la température. Nous avons fait usage de la prévision probabiliste de la production éolienne et de la charge pour créer nos arbres de scénarios utilisés par la suite pour résoudre le modèle d’optimisation. Le code de ce modèle a été intégré dans la plateforme de simulation de **smartDESC** qui regroupe également le module de traitement de données, la couche de simulation du réseau de communication et les contrôleurs locaux à champ moyen. Les résultats issus de la simulation montraient qu’avec un niveau significatif de pénétration de l’énergie de source éolienne, une réduction importante de la charge de pointe et de la fluctuation de la demande nette est atteinte grâce à la gestion de la capacité de stockage de chauffe-eau.

Bien que ce modèle soit ajusté de manière à interagir avec des chauffe-eau par une technique de champ moyen, la façon dont les chauffe-eau sont contrôlés localement est considérée comme une boîte noire pour l’unité de calcul centrale. L’avantage de ce modèle vient donc du fait qu’il est possible de l’adapter pour qu’il interagisse avec d’autres modèles de contrôleurs locaux ou de charges contrôlables, notamment les véhicules électriques, les chauffages et la climatisation des espaces.

Comme nous avons considéré dans notre programme d’optimisation un modèle agrégé de chauffe-eau qui reflète leur comportement moyen et que nous avons omis l’évolution de la distribution de chauffe-eau autour de la moyenne induite par les commandes à champ moyen, il se peut que la solution optimale soit exigeante de façon à surestimer la capacité réelle de la population de chauffe-eau qui suit le profil de température de consigne. Dans le chapitre 5, nous avons présenté la preuve de convergence d’un algorithme itératif qui corrige le profil de température quand les consignes ne sont pas atteignables aux contrôleurs locaux. Le module responsable de la vérification de la réalisabilité et la correction du profil de température de consigne a été développé par Romain Losseau durant sa maîtrise. Ce module prend en entrée le profil de température et restreint selon le besoin les bornes supérieures et inférieures sur la puissance que le modèle d’optimisation pourrait injecter dans les chauffe-eau. Ces bornes sont renvoyées au modèle d’optimisation qui recalcule à son tour un nouveau profil de température moins exigeant, le mécanisme procède ainsi jusqu’à ce que les températures de consigne soient réalisables par les contrôleurs locaux.

7.2 Limitations de la solution proposée et améliorations futures

En général, la qualité des solutions optimales obtenues par des modèles d’optimisation stochastique dépend de la qualité de l’approximation des paramètres incertains sous forme d’arbre de scénarios. Dans cette thèse, nous nous sommes concentrés sur le traitement de

prévisions d'ensemble que nous avons utilisées par la suite pour créer les arbres de scénarios. Par conséquent, le nombre de scénarios dans l'arbre était restreint par le nombre de scénarios dans la prévision d'ensemble. Nous avons fait l'hypothèse que les scénarios de l'arbre de peigne sont équiprobables. De plus, pour créer des étapes de branchements dans l'arbre de scénarios, nous nous sommes contentés de l'algorithme de construction que fournit le logiciel Scenred2. Des améliorations possibles seraient de proposer une méthode permettant de créer des scénarios de prévision de la vitesse du vent et de la température plus riches en terme de possibilités. Par exemple, nous pourrions modéliser des processus stochastiques décrivant l'évolution de la vitesse du vent et de la température à partir des données historiques, tel que les modèles ARIMA et ARCH (voir Box et al., 2013). Nous pourrions appliquer par la suite des méthodes d'échantillonnage comme des méthodes de Monte-Carlo pour approximer ces processus stochastiques en un nombre fini de possibilités. En effet, cette approche pourrait être bénéfique pour enrichir les prévisions météorologiques à très court terme (c.-à-d. de 1 à 3 heures), cependant, ces modèles n'arrivent pas à capter la variabilité de la vitesse du vent sur un intervalle de temps plus long. Alors, une approche hybride qui combine des modèles mathématiques de prévision avec des prévisions numériques du temps qui se comportent mieux sur une fenêtre de temps plus longue serait éventuellement prometteuse. Élaborer le modèle de régression présenté dans le chapitre 4 afin de tenir compte de l'effet saisonnier aurait été intéressant (voir Radics et al., 2008), sauf que dans le cadre de cette thèse, nous étions limités par les données disponibles dans les archives d'Environnement Canada qui dataient depuis juillet 2015.

Une autre amélioration serait de suggérer une méthode d'ajustement des probabilités d'occurrence des scénarios de l'arbre de peigne en fonction de la révélation de l'incertitude des paramètres aléatoires, et ce, de façon à ce que les scénarios les plus probables aient une pondération plus élevée que les autres. De plus, le modèle d'optimisation présenté au chapitre 5 pourrait être étendu à d'autres types de stockages tel que les chauffages et la climatisation comme il a été mentionné dans la section 7.1. Le contrôle de ce genre de dispositifs comporte des défis, entre autres des manœuvres de stockage plus restreintes étant donné que le confort de clients est plus sensible au moindre changement de température de chauffage/climatisation. La gestion de la charge des véhicules électriques est également une voie prometteuse à explorer, surtout que leur marché aura tendance à prendre de l'ampleur au cours des années à venir. Il serait aussi intéressant d'étudier le gain que peut apporter l'approche de gestion de chauffe-eau proposé par cette thèse sur la régulation de fréquence présenté dans l'article de Jasmin et al. (2015)

Une limitation que nous avons dans la contribution présentée dans le chapitre 6 découle du fait que notre preuve de convergence est basée sur l'hypothèse que les bornes générées

par le GCR ne sont jamais relaxées, ce qui garde la monotonie de la suite des bornes. Nous avons dû poser cette hypothèse car la fonction f , définie dans la section 6.4, n'est pas globalement continue. Cela nous empêche de solliciter le théorème de point fixe de *Brouwer* ou de *Schauder*. Par conséquent, pour contourner ce problème de discontinuité, nous avons dû imposer la monotonie de la suite des bornes pour garantir la convergence de l'algorithme vers un point fixe. Cette hypothèse conservatrice pourrait conserver des bornes inutiles d'une itération à l'autre et nuire à la qualité de lissage de la courbe de demande nette obtenue au point fixe.

CHAPITRE 8 CONCLUSION ET RECOMMANDATIONS

En conclusion, cette thèse porte sur l'étude de la gestion de la charge de chauffe-eau à court terme pour atténuer la variabilité de production due aux sources d'énergie éolienne intermittentes. Nous avons présenté une méthode de génération de scénarios de production éolienne à partir de la prévision numérique du temps fournie par *Environnement Canada*. Nous avons ensuite développé un modèle d'optimisation stochastique à multi-étapes qui calcule le profil de consommation optimal d'un modèle agrégé de chauffe-eau sur un horizon de 24 heures, et ce, en tenant compte de l'incertitude de la demande nette approximée par des scénarios. Ensuite, nous avons intégré ce modèle dans la plateforme de simulation de **smartDESC** où il interagissait avec les contrôleurs locaux et les résultats issus de la simulation étaient présentés dans le chapitre 5. En raison du fait que lors de cette simulation l'effet de thermostat est négligé, autrement dit que la puissance appliquée au chauffe-eau est continue entre 0 et la puissance nominale, et grâce à la technique de contrôleurs locaux, l'effet de la charge de reprise est minimisé. Enfin, nous avons présenté la preuve de convergence d'un algorithme qui vise à rectifier la solution optimale obtenue par le modèle d'optimisation afin que les contrôleurs locaux soient capables de la réaliser.

RÉFÉRENCES

- Energy Use Data Handbook*. Natural Resources Canada, June 2004.
- J. Aghaei *et al.*, “Demand response in smart electricity grids equipped with renewable energy sources : A review”, *Renewable and Sustainable Energy Reviews*, vol. 18, pp. 64 – 72, 2013.
- M. Albadi *et al.*, “A summary of demand response in electricity markets”, *Electric Power Systems Research*, vol. 78, no. 11, pp. 1989 – 1996, 2008.
- V. Balijepalli *et al.*, “Review of demand response under smart grid paradigm”, dans *Innovative Smart Grid Technologies - India (ISGT India)*, 2011 IEEE PES, Dec 2011, pp. 236–243.
- A. Ben-Tal et A. Nemirovski, “Robust solutions of linear programming problems contaminated with uncertain data”, *Mathematical Programming*, vol. 88, no. 3, pp. 411–424, 2000.
- D. P. Bertsekas, *Dynamic Programming and Optimal Control*. Athena Scientific ; 4th edition, 2007.
- D. Bertsimas et M. Sim, “The price of robustness”, *Operations research*, vol. 52, no. 1, pp. 35–53, 2004.
- D. Bertsimas, D. B. Brown, et C. Caramanis, “Theory and applications of robust optimization”, *SIAM Review*, vol. 53, no. 3, pp. 464–501, 2011.
- J. R. Birge et F. Louveaux, *Introduction to Stochastic Programming*. Springer New York, 2011.
- J. Birge et F. Louveaux, *Introduction to Stochastic Programming*, série Springer Series in Operations Research and Financial Engineering. Springer, 2011.
- R. Bischke et R. A. Sella, “Design and controlled use of water heater load management”, *Power Apparatus and Systems, IEEE Transactions on*, vol. PAS-104, no. 6, pp. 1290–1293, 1985.
- G. E. P. Box, G. M. Jenkins, et G. C. Reinsel, *Time Series Analysis, Fourth Edition*, 2013.
- E. Canada, “Description of the meteorological service (msc) of canada global ensemble prediction system (geps) version 4.0.0”, Rapp. tech., 2014.

- P.-L. Carpentier, “Méthodes de décomposition pour la planification À moyen terme de la production hydroÉlectrique sous incertitude”, Thèse de doctorat, École Polytechnique de Montréal, 2014.
- W.-Y. Chang, “A literature review of wind forecasting methods”, vol. 2, pp. 161–168, 2014. DOI : 10.4236/jpee.2014.24023
- A. I. Cohen *et al.*, “An optimization method for load management scheduling”, *Power Systems, IEEE Transactions on*, vol. 3, no. 2, pp. 612–618, 1988.
- G. Dorini, P. Pinson, et H. Madsen, “Chance-constrained optimization of demand response to price signals”, *Smart Grid, IEEE Transactions on*, vol. 4, no. 4, pp. 2072–2080, Dec 2013.
- H. Falsafi, A. Zakariazadeh, et S. Jadid, “The role of demand response in single and multi-objective wind-thermal generation scheduling : A stochastic programming”, *Energy*, vol. 64, pp. 853 – 867, 2014.
- R. Ferreira, L. Barroso, et M. Carvalho, “Demand response models with correlated price data : A robust optimization approach”, *Applied Energy*, vol. 96, no. 0, pp. 133 – 149, 2012, smart Grids.
- H. Fukuda., “The development of a wind velocity prediction method based on a data-mining type autoregressive model”, 2001.
- J. Garratt, *The Atmospheric Boundary Layer*, série Cambridge Atmospheric and Space Science Series. Cambridge University Press, 1994.
- G. Giebel, G. Kariniotakis, et R. Brownsword. The state-of-the-art in short-term prediction of wind power - a literature review.
- I. Griva, S. G. Nash, et A. Sofer, *Linear And Nonlinear Optimization, Second Edition*, 2009.
- GWEC, “Global wind report annual market update”, Gwec.net, Rapp. tech., 2014.
- B. F. Hastings, “Ten years of operating experience with a remote controlled water heater load management system at detroit edison”, *Power Apparatus and Systems, IEEE Transactions on*, vol. PAS-99, no. 4, pp. 1437–1441, 1980.
- M. He, S. Murugesan, et J. Zhang, “A multi-timescale scheduling approach for stochastic reliability in smart grids with wind generation and opportunistic demand”, *IEEE Transactions on Smart Grid*, vol. 4, no. 1, pp. 521–529, March 2013.

- H. Heitsch et W. Römisch, “Scenario tree modeling for multistage stochastic programs”, *Mathematical Programming*, vol. 118, no. 2, pp. 371–406, 2007.
- S. Jasmin *et al.*, “A novel technology to improve grid frequency response on electrical power system with high level of renewable generation penetration”, 2015.
- E. Kalnay, S. J. Lord, et R. D. McPherson, “Maturity of operational numerical weather prediction : Medium range”, *Bulletin of the American Meteorological Society*, vol. 79, no. 12, pp. 2753–2769, 1998.
- M. Kaut et S. W. Wallace, “Evaluation of scenario-generation methods for stochastic programming”, dans *World Wide Web, Stochastic Programming E-Print Series*, 2003, pp. 14–2003.
- A. C. Kizilkale et R. P. Malhamé, “Mean field based control of power system dispersed energy storage devices for peak load relief”, dans *Decision and Control (CDC), 2013 IEEE 52nd Annual Conference on*, Dec 2013, pp. 4971–4976.
- A. C. Kizilkale *et al.*, “smartdesc : Smart distributed energy storage controller (in preparation)”, 2016.
- A. Kizilkale et R. Malhame, “Collective target tracking mean field control for markovian jump-driven models of electric water heating loads”, Groupe d’Etudes et de Recherche en Analyse des Decisions (GERAD), Rapp. tech., 2014.
- E. Klaassen, Y. Zhang, I. Lampropoulos, et H. Slootweg, “Demand side management of electric boilers”, dans *Innovative Smart Grid Technologies (ISGT Europe), 2012 3rd IEEE PES International Conference and Exhibition on*, 2012, pp. 1–6.
- J. Kondoh, N. Lu, et D. Hammerstrom, “An evaluation of the water heater load potential for providing regulation service”, *Power Systems, IEEE Transactions on*, vol. 26, no. 3, pp. 1309–1316, 2011.
- M. Kuliasha, *A Dynamic Model of Power System Operation Incorporating Load Control*. Oak Ridge National Laboratory, 1980.
- M. Lacroix, “Electric water heater designs for load shifting and control of bacterial contamination”, *Energy Conversion & Management*, vol. 40, pp. 1313–1340, 1999.
- B. LaMeres, M. Nehrir, et V. Gerez, “Controlling the average residential electric water heater power demand using fuzzy logic”, *Electric Power Systems Research*, vol. 52, no. 3,

pp. 267 – 271, 1999.

J.-C. Laurent, G. Desaulniers, R. Malhame, et F. Soumis, “A column generation method for optimal load management via control of electric water heaters”, *Power Systems, IEEE Transactions on*, vol. 10, no. 3, pp. 1389–1400, 1995.

J.-C. Laurent *et al.*, “A physically-based computer model of aggregate electric water heating loads”, *Power Systems, IEEE Transactions on*, vol. 9, no. 3, pp. 1209–1217, 1994.

S. H. Lee et C. L. Wilkins, “A practical approach to appliance load control analysis : A water heater case study”, *Power Apparatus and Systems, IEEE Transactions on*, vol. PAS-102, no. 4, pp. 1007–1013, 1983.

R. Losseau, “Modélisation agrégée de chauffe-eau électriques commandés par champ moyen pour la gestion des charges dans un réseau”, Mémoire de maîtrise, 2016.

C. Loutan et D. Hawkins, “Integration of renewable resources”, 2007.

O. Malik et P. Havel, “Active demand-side management system to facilitate integration of renewable energy sources (RES) in low-voltage distribution networks”, *Sustainable Energy, IEEE Transactions on*, vol. 5, no. 2, pp. 673–681, April 2014.

M. Nehrir et B. LaMeres, “A multiple-block fuzzy logic-based electric water heater demand-side management strategy for leveling distribution feeder demand profile”, *Electric Power Systems Research*, vol. 56, no. 3, pp. 225 – 230, 2000.

T. N. Palmer, “Predicting uncertainty in forecasts of weather and climate”, *Reports on Progress in Physics*, vol. 63, no. 2, p. 71, 2000.

A. Papavasiliou et S. S. Oren, “Supplying renewable energy to deferrable loads : Algorithms and economic analysis”, dans *IEEE PES General Meeting*, July 2010, pp. 1–8.

A. Papavasiliou, S. Oren, et R. O’Neill, “Reserve requirements for wind power integration : A scenario-based stochastic programming framework”, *Power Systems, IEEE Transactions on*, vol. 26, no. 4, pp. 2197–2206, Nov 2011.

A. Papavasiliou, “Coupling renewable energy supply with deferrable demand”, Thèse de doctorat, University of California, Berkeley, 2011.

P. Pinson, “Estimation of the uncertainty in wind power forecasting”, Thèse de doctorat, École Nationale Supérieure des Mines de Paris, 2006.

- K. Radics *et al.*, “Estimating and modelling the wind resource of hungary”, *Renewable and Sustainable Energy Reviews*, vol. 12, no. 3, pp. 874 – 882, 2008.
- P. A. Rosario, W. Morsi, et L. Chang, “Application of pso to optimize the operation of electric water heaters for reserve provision”, dans *Electrical Power and Energy Conference (EPEC), 2011 IEEE*, 2011, pp. 164–169.
- N. V. Sahinidis, “Optimization under uncertainty : state-of-the-art and opportunities”, *Computers & Chemical Engineering*, vol. 28, no. 6–7, pp. 971 – 983, 2004, {FOCAPO} 2003 Special issue.
- H. Salehfar *et al.*, “Direct control of residential water heater loads to reduce power system distribution losses”, dans *Power Engineering Society Winter Meeting, 2001. IEEE*, vol. 3, 2001, pp. 1455–1460 vol.3.
- P. Scott *et al.*, *Principles and Practice of Constraint Programming : 19th International Conference*. Springer Berlin Heidelberg, 2013, ch. Residential Demand Response under Uncertainty, pp. 645–660.
- A. Sepulveda, L. Paull, W. Morsi, H. Li, C. Diduch, et L. Chang, “A novel demand side management program using water heaters and particle swarm optimization”, dans *Electric Power and Energy Conference (EPEC), 2010 IEEE*, 2010, pp. 1–5.
- J. A. Short, D. G. Infield, et L. L. Freris, “Stabilization of grid frequency through dynamic demand control”, *IEEE Transactions on Power Systems*, vol. 22, no. 3, pp. 1284–1293, Aug 2007.
- P. Siano, “Demand response and smart grids,a survey”, *Renewable and Sustainable Energy Reviews*, vol. 30, pp. 461 – 478, 2014.
- G. Skandalis, *Topologie et analyse*, 2004.
- G. Strbac, “Demand side management : Benefits and challenges”, *Energy Policy*, vol. 36, no. 12, pp. 4419 – 4426, 2008, foresight Sustainable Energy Management and the Built Environment Project.
- A. I. Tammam, C. S. Watters, M. F. Anjos, et M. Gendreau, “A methodology for ensemble wind power scenarios generation from numerical weather predicitions (accepted for ieee pes gm 2016 proceedings)”, GERAD, Rapp. tech., 2015.

X. Wang, P. Guo, et X. Huang, “A review of wind power forecasting models”, *Energy Procedia*, vol. 12, pp. 770 – 778, 2011, the Proceedings of International Conference on Smart Grid and Clean Energy Technologies (ICSGCE 2011).

C. Watters et P. Leahy, “Influence of wind direction in the downscaling of wind speeds from numerical weather prediction”, dans *Aerospace Sciences Meetings*. American Institute of Aeronautics and Astronautics, 2012.

G. Welch et G. Bishop, “An introduction to the kalman filter”, 2006.

G. Zhang, B. E. Patuwo, et M. Y. Hu, “Forecasting with artificial neural networks : : The state of the art”, *International Journal of Forecasting*, vol. 14, no. 1, pp. 35 – 62, 1998.

L. Zhang et Y. Li, “Optimal energy management of wind-battery hybrid power system with two-scale dynamic programming”, *Sustainable Energy, IEEE Transactions on*, vol. 4, no. 3, pp. 765–773, July 2013.