



HAL
open science

Etude de stratégies de gestion en temps réel pour des bâtiments énergétiquement performants

Maxime Robillart

► **To cite this version:**

Maxime Robillart. Etude de stratégies de gestion en temps réel pour des bâtiments énergétiquement performants. Ingénierie de l'environnement. Ecole Nationale Supérieure des Mines de Paris, 2015. Français. NNT : 2015ENMP0042 . tel-01299525

HAL Id: tel-01299525

<https://pastel.hal.science/tel-01299525>

Submitted on 7 Apr 2016

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

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

École doctorale n° 432 : Sciences des Métiers de l'Ingénieur

Doctorat ParisTech

THÈSE

pour obtenir le grade de docteur délivré par

l'École nationale supérieure des mines de Paris

Spécialité “ Énergétique ”

présentée et soutenue publiquement par

Maxime ROBILLART

le 28 septembre 2015

Étude de stratégies de gestion en temps réel pour des bâtiments énergétiquement performants

Directeur de thèse : **Bruno PEUPORTIER**

Co-encadrement de la thèse : **Patrick SCHALBART**

Jury

M. Étienne WURTZ,
M. Frédéric WURTZ,
M. Michael BALDEA,

Directeur de Recherche CNRS, LEB, CEA-INES
Directeur de Recherche CNRS, G2ELab, Grenoble-INP
Assistant Professor, McKetta Department of Chemical Engineering,
The University of Texas at Austin

M. Vincent LEMORT,
M. Laurent MORA,
M. Nicolas PETIT,

Assistant Professor, Thermodynamics Laboratory, University of Liège
Maître de Conférences, I2M, Université de Bordeaux
Professeur, CAS, MINES ParisTech

M. Bruno PEUPORTIER,
M. François CHAPLAIS,
M. Patrick SCHALBART,

Maître de Recherche, CES, MINES ParisTech
Ingénieur de recherche, CAS, MINES ParisTech
Ingénieur de recherche, CES, MINES ParisTech

Rapporteur
Rapporteur

Examineur
Examineur
Examineur
Président
Examineur
Invité
Invité

T
H
È
S
E

MINES ParisTech

Centre Efficacité énergétique des Systèmes

5 rue Léon Blum, 91120 Palaiseau, FRANCE

Autrefois, j'étais indécis, mais à présent, je n'en suis plus aussi sûr.

UMBERTO ECO

Remerciements

Dans un premier temps, je veux remercier mon directeur de thèse Bruno Peuportier de m'avoir fait confiance et proposé ce sujet de thèse. Son engagement écologique, sa rigueur et son intégrité permettent aux différents membres de l'équipe ETB de travailler sur des sujets passionnants et au cœur des enjeux sociétaux.

Je tiens également à remercier très sincèrement mon maître de thèse Patrick Schalbart pour son implication, sa rigueur et son exigence. Le temps consacré à l'encadrement de ces travaux a permis de faire de ce manuscrit ce qu'il est.

Je remercie aussi chaleureusement François Chaplais de m'avoir fait découvrir le merveilleux monde de l'automatique. Sa disponibilité, sa pédagogie et son grand intérêt pour la gestion énergétique des bâtiments ont rendu le travail à ses côtés passionnant.

Je souhaite remercier Nicolas Petit qui a présidé mon jury de soutenance, Étienne Wurtz et Frédéric Wurtz qui ont accepté d'être les rapporteurs de cette thèse, Michael Baldea, Vincent Lemort et Laurent Mora qui m'ont fait l'honneur de participer à ce jury. Leurs appréciations, remarques et critiques ont donné lieu à des échanges très constructifs lors de la soutenance.

Le bon déroulement d'une thèse doit également beaucoup à l'environnement de travail. Un GRAND merci aux membres de l'équipe ETB ,anciens, nouveaux, lanceurs infatigables de débats lors de la pause café ou autour d'une bière, amateurs de rugby, adeptes du zap de Spion, joueurs de Mölkky, membres de la première ou de la deuxième catégorie (et ceux qui jouent avec la loi de Murphy !).

A mes amis pour leur soutien et les années inoubliables passées à leurs côtés, que ce soit à La Rhumerie ou au Bouillon Belge en passant par La Presqu'île, que ce soit à Sens, Tours ou à Cardiff en passant par Saint-Etienne-de-Crossey, ou encore que ce soit au refuge de Petra Piana ou au col de Madamète en passant par les 25 bosses... Geoffrey, on peut enfin dire que notre promesse d'enfance a été tenue !

Enfin, je remercie profondément et dédie cette thèse à ma famille et plus particulièrement à mes parents pour m'avoir toujours soutenu, supporté et encouragé pendant toute ma scolarité. A ma sœur, pour avoir toujours été un modèle à suivre et sans qui je n'en serais pas là. Et enfin à Jules, mon neveu et filleul, qui du haut de ses quelques mois a apporté un soutien non négligeable à base de sourires et de cris de joie !

Table des matières

<u>TABLE DES MATIÈRES</u>	<u>1</u>
<u>NOMENCLATURE</u>	<u>11</u>
<u>INTRODUCTION</u>	<u>15</u>
<u>CHAPITRE 1 : LA RÉGULATION ÉNERGÉTIQUE DES BÂTIMENTS.....</u>	<u>19</u>
<u>1. LES OBJECTIFS DE LA RÉGULATION</u>	<u>23</u>
<u>2. ÉTAT DE L'ART DES SYSTÈMES DE RÉGULATION</u>	<u>25</u>
2.1 INTRODUCTION	25
2.2 SYSTÈMES DE RÉGULATION SANS MODÈLE THERMIQUE DU BÂTIMENT	26
2.3 SYSTÈME DE RÉGULATION AVEC MODÈLE THERMIQUE DU BÂTIMENT	27
<u>3. THÉORIE DE LA COMMANDE PRÉDICTIVE</u>	<u>32</u>
3.1 LA COMMANDE OPTIMALE	32
3.2 LES MÉTHODES DE RÉOLUTION	34
<u>4. APPLICATION À L'EFFACEMENT DE LA CONSOMMATION ÉLECTRIQUE DE POINTE</u>	<u>35</u>
4.1 CONTEXTE : DÉSÉQUILIBRE DU RÉSEAU ÉLECTRIQUE	36
4.2 ÉTAT DE L'ART DES MÉTHODES D'EFFACEMENT	37
<u>5. CONCLUSION DU CHAPITRE.....</u>	<u>45</u>
<u>CHAPITRE 2 : MODÈLES NÉCESSAIRES À LA RÉGULATION</u>	<u>47</u>
<u>1. INTRODUCTION.....</u>	<u>51</u>
<u>2. MODÈLE THERMIQUE DYNAMIQUE DU BÂTIMENT (COMFIE)</u>	<u>51</u>

3.	<u>MODÉLISATION DE L'OCCUPATION</u>	<u>55</u>
3.1	INTRODUCTION.....	55
3.2	ÉTAT DE L'ART SUR LE CONFORT.....	55
4.	<u>MODÉLISATION DU CLIMAT</u>	<u>61</u>
4.1	INTRODUCTION.....	61
4.2	ÉTAT DE L'ART DE LA MODÉLISATION DES CONDITIONS CLIMATIQUES.....	62
4.3	CARACTÉRISATION DES MODÈLES ARMA.....	67
4.4	MODÉLISATION DES CONDITIONS CLIMATIQUES.....	74
4.5	CONCLUSION.....	92
5.	<u>CONCLUSION DU CHAPITRE</u>	<u>93</u>
<u>CHAPITRE 3 : CALIBRAGE DE MODÈLE.....</u>		<u>95</u>
1.	<u>LE CALIBRAGE DE MODÈLE</u>	<u>99</u>
1.1	LES LOGICIELS DE SIMULATION THERMIQUE DYNAMIQUE	99
1.2	LES STANDARDS INTERNATIONAUX	100
1.3	LES INCERTITUDES DANS LE BÂTIMENT.....	101
1.4	LES DIFFÉRENTES MÉTHODES DE CALIBRAGE EXISTANTES.....	102
2.	<u>LE CALIBRAGE BAYÉSIEN</u>	<u>103</u>
2.1	INTRODUCTION : L'APPROCHE STATISTIQUE.....	103
2.2	LES MÉTHODES MCMC	105
2.3	LES MÉTHODES MCMC UTILISANT UN MÉTAMODÈLE	106
2.4	LE CALCUL BAYÉSIEN APPROCHÉ.....	108
3.	<u>MÉTHODOLOGIE</u>	<u>113</u>
3.1	ÉTAPE 1 : RÉCUPÉRATION DES DONNÉES	113
3.2	ÉTAPE 2 : CRÉATION DU MODÈLE	114
3.3	ÉTAPE 3 : ANALYSE DE SENSIBILITÉ	114
3.4	ÉTAPE 4 : CALIBRAGE DU MODÈLE.....	116
3.5	ÉTAPE 5 : ÉVALUATION DES RÉSULTATS	117

<u>4.</u>	<u>CAS D'APPLICATION</u>	<u>118</u>
4.1	COLLECTE DES DONNÉES (ÉTAPE 1)	118
4.2	HYPOTHÈSES DE MODÉLISATION DU BÂTIMENT (ÉTAPE 2)	122
4.3	ANALYSE DE SENSIBILITÉ : MÉTHODE DE MORRIS (ÉTAPE 3).....	124
4.4	CALIBRAGE DU MODÈLE (ÉTAPE 4).....	128
4.5	ÉVALUATION DES RÉSULTATS (ÉTAPE 5)	132
<u>5.</u>	<u>CONCLUSION DU CHAPITRE.....</u>	<u>138</u>
<u>CHAPITRE 4 : ÉLABORATION DE LOIS DE TYPE HEURISTIQUE</u>		<u>141</u>
<u>1.</u>	<u>L'OPTIMISATION HORS-LIGNE</u>	<u>145</u>
<u>2.</u>	<u>CADRE DE L'ÉTUDE</u>	<u>147</u>
2.1	BÂTIMENT ÉTUDIÉ	147
2.2	OBJECTIF DE L'OPTIMISATION	149
<u>3.</u>	<u>MÉTHODOLOGIE</u>	<u>151</u>
3.1	ALGORITHME D'OPTIMISATION	151
3.2	ÉLABORATION DES LOIS HEURISTIQUES	153
<u>4.</u>	<u>RÉSULTATS.....</u>	<u>161</u>
4.1	DONNÉES MÉTÉOROLOGIQUES	161
4.2	INFLUENCE DES DONNÉES D'ENTRAÎNEMENT SUR LES RÉGRESSIONS BÊTA	162
4.3	UTILISATION D'UN CONTRÔLEUR	164
4.4	COMPARAISON À UNE LOI DE COMMANDE CLASSIQUE.....	166
<u>5.</u>	<u>INFLUENCE DE LA PRÉVISION MÉTÉOROLOGIQUE SUR LA LOI HEURISTIQUE IDENTIFIÉE ...</u>	<u>168</u>
5.1	MODÈLE DE PRÉVISION MÉTÉOROLOGIQUE.....	168
5.2	IMPACT SUR LES LOIS HEURISTIQUES	170
<u>6.</u>	<u>CONCLUSION DU CHAPITRE.....</u>	<u>173</u>

CHAPITRE 5 : APPLICATION DE LA COMMANDE PRÉDICTIVE	177
1. INTRODUCTION	181
2. RÉDUCTION DU MODÈLE THERMIQUE.....	182
2.1 PROPRIÉTÉS DES SYSTÈMES D'ÉTAT	182
2.2 LA RÉALISATION ÉQUILIBRÉE	183
2.3 LA RÉDUCTION ÉQUILIBRÉE	184
2.4 APPLICATION AU CAS D'ÉTUDE	184
3. COMMANDE OPTIMALE	189
3.1 PRINCIPE DES MÉTHODES DE PÉNALISATION.....	189
3.2 ALGORITHME D'OPTIMISATION.....	191
3.3 APPLICATION AU CAS D'ÉTUDE	192
3.4 ANALYSE DE SENSIBILITÉ	196
4. OBSERVATEUR ASYMPTOTIQUE.....	201
4.1 STRUCTURE DE L'OBSERVATEUR.....	202
4.2 APPLICATION.....	203
5. COMMANDE PRÉDICTIVE	205
5.1 COMMANDE PRÉDICTIVE SANS CONTRÔLEUR	205
5.2 COMMANDE PRÉDICTIVE AVEC RÉGULATEUR.....	211
6. CONCLUSION DU CHAPITRE	216
CONCLUSION GÉNÉRALE	219
BIBLIOGRAPHIE	223

<u>ANNEXE A.</u>	<u>RÉSULTATS DE LA MODÉLISATION DE LA TEMPÉRATURE.....</u>	<u>235</u>
<u>ANNEXE B.</u>	<u>RÉSULTATS DE LA MODÉLISATION DU RAYONNEMENT</u>	<u>237</u>
<u>ANNEXE C.</u>	<u>PARAMÈTRES CONSIDÉRÉS LORS DU CIBLAGE DE MORRIS</u>	<u>239</u>
<u>ANNEXE D.</u>	<u>IDENTIFICATION DES MODÈLES DE REGRESSION BÊTA</u>	<u>243</u>
<u>ANNEXE E.</u>	<u>RÉSULTATS DES MODÈLES DE RÉGRESSION BÊTA</u>	<u>245</u>

Nomenclature

NOTATIONS LATINES

A	Matrice d'état	[-]
a	Coefficient de régression	[-]
a_j	Paramètres de régression	[-]
B	Opérateur de recul	[-]
b	Coefficient de régression	[-]
C	Matrice diagonale des capacités thermiques	[J/K]
C_{elec}	Coût de l'électricité	[€]
C_i	Capacité thermique de la maille i	[J/K]
C_o	Matrice de commandabilité	[-]
C_m	Capacité thermique de la maille	[J/K]
$D_{j,s}^*$	Distance normalisée (Méthode de Morris)	[-]
d_j^*	Distance (Méthode de Morris)	[-]
E	Matrice de commande	[-]
$E_j^{(i)}$	Effet élémentaire (Méthode de Morris)	[°C]
$e(.)$	Erreur de mesure	[°C]
$f(.)$	Dynamique du système	[-]
G	Matrice d'action directe	[-]
G_h	Rayonnement solaire global horizontal	[W/m ²]
$H(.)$	Hamiltonien du système	[-]
h	Horizon de prévision	[s]
J	Matrice d'observation	[-]
K	Gain proportionnel	[-]
L	Matrice de l'observateur asymptotique	[-]
$L(.)$	Fonction de coût	[-]
N_{ABC}	Nombre de paramètres satisfaisant un seuil de tolérance (algorithme ABC)	[-]
N_C	Dimension de U_t	[-]
$N_{mailles}$	Nombre de mailles	[-]
N_{pro}	Nombre de simulations réalisées lors de la propagation d'incertitudes	[-]
N_S	Dimension de X_t	[-]
N_{var_max}	Nombre de fois où la vitesse de variation de la température est supérieure à la vitesse maximale	[-]
O_b	Matrice d'observabilité	[-]
P	Matrice de passage	[-]
P	Puissance de chauffage	[W]
$P_{idéal}$	Puissance de chauffage exacte pour atteindre la consigne	[W]
P_{max}	Puissance de chauffage maximale	[W]
P_{mes}	Puissance mesurée	[W]
P_{min}	Puissance de chauffage minimale	[W]
P_{ref}	Puissance de référence (commande en boucle ouverte)	[W]
P_{reg}	Puissance calculée par le régulateur	[W]

p	Vecteur adjoint	[-]
p	Ordre d'un processus autorégressif	[-]
p	Paramètre de la loi Bêta	[-]
p_0	Vecteur adjoint initial	[-]
$p_{i,j}$	Probabilité de transition de l'état i à l'état j	[-]
Q	Niveaux de discrétisation (méthode de Morris)	[-]
\dot{Q}_G	Gains thermiques	[W]
\dot{Q}_P	Pertes thermiques	[W]
q	Ordre d'un processus à moyenne mobile	[-]
q	Paramètre de la loi Bêta	[-]
R_M	Matrice de transition	[-]
r	Nombre de répétitions (Méthode de Morris)	[-]
S^{at}	Fonction de saturation	[-]
S_t	Composante saisonnière ou périodique d'une série temporelle	[-]
T	Champ discrétisé des températures	[°C]
T_{conf}	Température de confort	[°C]
T_d	Terme purement dynamique du vecteur des températures	[°C]
T_{ext}	Température extérieure	[°C]
T_i	Température de la maille i	[°C]
T_i	Temps d'intégration	[s]
T_m	Température de la maille	[°C]
T_{max}	Température maximale	[°C]
T^{mes}	Températures mesurées	[°C]
$T^{o\ mes}$	Température mesurée (commande optimale)	[°C]
T_{min}	Température minimale	[°C]
T_p	Terme de régime permanent glissant du vecteur des températures	[°C]
T_{ref}	Température de référence	[°C]
$T^{o\ ref}$	Température de référence (commande optimale)	[°C]
T_i^{sim}	Températures simulées	[°C]
T_{zone}	Température de la zone	[°C]
TI_{max}	Taux d'inconfort supérieur	[%]
TI_{min}	Taux d'inconfort inférieur	[%]
t	temps	[s]
t_f	Horizon d'optimisation	[s]
U	Ensemble des contrôles admissibles	[-]
U	Vecteur des sollicitations	[W]
U_t	Ensemble des commandes admissibles au temps t	[-]
u	Sollicitations, Variable de commande	[W]
V	Fonction valeur	[-]
V_0^t	Problème d'optimisation séquentielle à horizon fini	[-]
v_t	Fonction coût	[-]
W_C	Grammien de commandabilité	[-]
W_O	Grammien d'observabilité	[-]
X	Vecteur d'état du système	[-]
$\hat{X}_N(h)$	Prévision à l'horizon h d'une série temporelle	[-]
X_t	Observations d'une série temporelle	[-]
X_t	Ensemble des états admissibles au temps t	[-]
x	Variable d'état décrivant le système	[-]
\hat{x}	État estimé	[-]
x_0	État initial	[-]
x_j	Variables explicatives	[-]

Y	Variables d'intérêt	[-]
Y	Vecteur des sorties	[°C]
y	Variable à prédire	[-]
y_i	Observations de la variable à prédire y	[-]
Z	Observations	[-]
Z_t	Tendance d'une série temporelle	[-]

LETTRES GRECQUES

α_{CLO}	Absorptivité aux courtes longueurs d'onde	[-]
β	Constante de lissage	[-]
$\gamma(\cdot)$	Fonction de covariance	[-]
$\gamma(\cdot)$	Fonction de pénalisation	[-]
γ_i	Coefficient d'un processus ARMA saisonnier	[-]
Δ	Saut entre deux nœuds successifs (Méthode de Morris)	[-]
Δt	Pas de temps	[s]
$\delta(\cdot)$	Erreur du modèle à calibrer	[°C]
$\pm \varepsilon$	Bande morte du contrôleur on-off	[°C]
ε_C	Seuil cible	[°C]
ε_{GLO}	Émissivité aux grandes longueurs d'onde	[-]
ε_t	Composante résiduelle d'une série temporelle	[-]
ε_t	Bruit blanc centré de variance σ^2	[-]
$\eta(\cdot, \cdot)$	Sorties du modèle à calibrer	[-]
θ	Vecteur des paramètres à calibrer	[-]
θ_i	Coefficient d'un processus à moyenne mobile	[-]
μ	Paramètre de la loi Bêta modifiée	[-]
μ_j	Moyenne des effets élémentaires (Méthode de Morris)	[°C]
μ_j^*	Moyenne absolue des effets élémentaires (Méthode de Morris)	[°C]
$\rho(\cdot)$	Fonction d'autocorrélation	[-]
$\rho(\cdot, \cdot)$	Distance entre les données simulées et les données observées	[°C]
σ^2	Variance	[-]
σ_i	Valeur singulière de Hankel	[-]
σ_j	Écart-type des effets élémentaires (Méthode de Morris)	[°C]
φ_i	Coefficient d'un processus autorégressif	[-]
ϕ	Paramètre de la loi Bêta modifiée	[-]
ψ_i	Coefficient d'un processus ARMA saisonnier	[-]
ω	Nombre de paramètres d'un modèle	[-]

ABBREVIATIONS

ABC	Approximate Bayesian Computation
AIC	Akaike's Information Criterion
AIC _c	AIC corrigé
ARMA	Autoregressive moving average
ARMAX	Autoregressive moving average and external input
ARX	Autoregressive with external input
BB	Béton Banché
BIC	Bayesian Information Criterion
BJ	Box-Jenkins
CVC	Chauffage, ventilation, climatisation
CVRMSE	Coefficient of Variation of Root Mean Square Error
DE _{heures creuses}	Données d'entraînement heures creuses
DE _{heures pleines}	Données d'entraînement heures pleines
DE _{heures pointe}	Données d'entraînement heures de pointe
FIR	Finite Impulse Response
HVAC	Heating, Ventilation and Air Conditioning
IPMVP	International Performance Measurement and Verification Protocol
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
MBE	Mean Biased Error
MCMC	Markov Chain Monte Carlo
MLE	Maximum Likelihood Estimation
MPC	Model Predictive Control
MSE	Mean Squared Error
PACF	Fonction d'autocorrélation partielle
PDF	Probability Density Function
PG	Processus Gaussien
PID	Proportionnel Intégral Dérivé
PMC	Population Monte Carlo
PMV	Predicted Mean Vote
PPD	Predicted Percentage Dissatisfied
PRC	Partial Rejection Control
RMSE	Root Mean Square Error
SARIMA	Seasonal Autoregressive Integrated Moving Average
SMC	Sequential Monte Carlo
SVM	Support Vector Machine
TOR	Tout-Ou-Rien
TRY	Test Reference Year
UTC	Temps universel coordonné
VMC	Ventilation Mécanique Contrôlée

Introduction

POSITIONNEMENT DU SUJET

Secteur économique le plus énergivore avec plus de 40 % de la consommation finale énergétique (68,7 Mtep en 2012), le secteur du bâtiment représente en France un levier majeur dans la mise en place des politiques d'économies d'énergie (ADEME 2013). Pour réduire l'impact de ce secteur une des solutions apportées actuellement est la conception et la rénovation de bâtiments à faible consommation énergétique. L'accroissement du nombre de ces bâtiments énergétiquement performants ouvre par conséquent de nouvelles perspectives concernant le développement de nouveaux services liés à la gestion de l'énergie et aux réseaux intelligents (« *smart grids* »). Parmi ces services, ceux liés à une gestion optimisée des flux d'énergie à l'intérieur de l'habitat sont particulièrement intéressants, et ce pour plusieurs raisons.

Tout d'abord, étant de plus en plus isolés thermiquement, les bâtiments performants sont beaucoup plus sensibles aux phénomènes intermittents, en particulier aux apports solaires transmis par les vitrages et aux usages (apports internes liés aux équipements et aux occupants). De plus, ce type de bâtiment amène à une sophistication des différents systèmes installés pouvant interagir. La gestion du bâtiment n'est alors plus intuitive pour l'occupant et nécessite l'utilisation de dispositifs de régulation anticipatifs et réactifs permettant d'assurer le confort tout en maîtrisant les consommations énergétiques.

De plus, de nombreux retours d'expériences ont fait apparaître des écarts significatifs entre les consommations théoriques calculées par les logiciels de simulation thermique dynamique et les consommations réelles mesurées en phase d'exploitation (Sidler 2011). Ces écarts peuvent être expliqués par les erreurs du modèle thermique du bâtiment utilisé, par les incertitudes pesant sur les données d'entrée (climat, occupation, caractéristiques physiques du bâti) ou encore par une mauvaise gestion énergétique des bâtiments entraînant une dégradation de leurs performances énergétiques. Une gestion optimisée des consommations énergétiques est alors une des solutions permettant de réduire ces écarts et de progresser vers la garantie de performance énergétique (GPE).

Enfin, le secteur résidentiel-tertiaire représente en France 68% de la consommation finale d'électricité (CGDD 2015) induisant des tensions sur le réseau, en particulier lors des pointes de consommation électrique. Plus précisément, 33 % du parc résidentiel est chauffé à l'électricité (ADEME 2013), entraînant en hiver une pointe de consommation électrique entre 17 h et 21 h et une thermosensibilité accrue du réseau. Pour faire face à ces demandes, une des solutions est d'augmenter les moyens de production de pointe. Cependant, ces derniers sont plus coûteux et

induisent de fortes émissions de CO₂ puisqu'ils utilisent des combustibles fossiles. Une alternative à l'augmentation des moyens de production et des capacités de transport consiste à mettre en œuvre des programmes de gestion de la demande. Ces derniers ont alors pour objectif de lisser le profil temporel de la demande en décalant les consommations des heures de pointe vers les heures creuses. Cette « flexibilité » est atteinte soit en incitant les consommateurs à décaler leur consommation, soit en prenant le contrôle des appareils électriques. Dans le secteur industriel, ces schémas sont classiquement utilisés car les puissances effacées par sites sont importantes. En revanche, dans le secteur résidentiel ceux-ci sont moins développés en raison de la multitude des clients potentiels. Aujourd'hui, le développement des technologies et des réseaux de communication ouvre des perspectives quant à l'utilisation de programmes de gestion de la demande dans le secteur résidentiel. Les stratégies de gestion énergétique doivent alors pouvoir s'adapter en temps réel aux contraintes du réseau (et aux prix de l'électricité) et permettre d'effacer la consommation électrique de pointe tout en garantissant le confort des occupants.

OBJECTIFS SCIENTIFIQUES

C'est dans ce contexte que s'inscrit le travail de thèse dont l'objectif est de développer des méthodes et stratégies visant à une gestion optimisée en temps réel des flux énergétiques. En effet, on dispose aujourd'hui de capteurs fiables et bon marché, de moyens de calculs de grande puissance ainsi que de moyens de télécommunication développés. Cependant, il subsiste un besoin dans le développement d'algorithmes permettant une gestion optimisée des flux d'énergie. Ces derniers ont en charge, à partir des données récoltées par les différents capteurs répartis dans un bâtiment, de planifier les stratégies de gestion énergétique tout en respectant les contraintes liées au bâtiment (confort de l'occupant, puissance maximale de chauffage, etc.). Dans cette thèse, nous nous intéressons au contrôle du chauffage et plus particulièrement à la réduction du pic de consommation électrique en hiver sous la contrainte du maintien du confort. Ces stratégies ont pour but de minimiser le coût de la consommation de chauffage sous des contraintes de température de confort et de commande de la puissance de chauffage. Il s'agit alors de développer des connaissances en termes de régulation anticipative appliquée au bâti, donc de prévision météorologique locale et de prévision des usages d'un bâtiment, de fiabilité et de calibrage des modèles prédictifs utilisés.

DÉMARCHE PROPOSÉE

La méthodologie développée pour répondre aux objectifs scientifiques de la thèse est construite en plusieurs étapes qui constituent les chapitres de la thèse.

La première étape consiste à réaliser un état de l'art sur la régulation énergétique des bâtiments dans le contexte de l'effacement de pointe et à définir les méthodes d'optimisation employées (chapitre 1).

Dans une deuxième étape, pour répondre aux objectifs d'adaptation en continu des stratégies de régulation aux usages et aux conditions environnementales changeantes ainsi que d'anticipation de l'état futur du bâtiment, le développement de trois modèles est nécessaire (chapitre 2) :

- un modèle de prévision météorologique locale ;
- un modèle d'occupation du bâtiment ;
- un modèle thermique du bâtiment.

Le modèle de prévision météorologique a pour but de prédire à un horizon de temps de 24 h les valeurs de la température extérieure et du rayonnement solaire global horizontal, deux variables indispensables au fonctionnement du modèle de simulation thermique dynamique du bâtiment. L'occupation peut quant à elle être définie d'une part par des scénarios représentatifs (éventuellement affinés à partir de données collectées sur le site) ou d'autre part par l'utilisation de modèles statistiques. Enfin, le modèle thermique dynamique du bâtiment COMFIE, développé par le Centre Efficacité énergétique des Systèmes (CES) de MINES ParisTech, est utilisé et permet d'intégrer les deux premiers modèles.

Suite au constat d'un écart important, ou du moins non maîtrisé, entre les performances énergétiques prévues par la simulation et les consommations réelles, le calibrage du modèle de bâtiment à partir de relevés in situ est indispensable dès lors que l'on souhaite un suivi fiable des performances énergétiques et le pilotage optimal des installations. La troisième étape a pour objectif de développer une méthodologie de calibrage du modèle de bâtiment basée sur une approche probabiliste permettant de prendre en compte les incertitudes pesant sur les différentes données du bâtiment (chapitre 3).

Enfin, la quatrième étape correspond à l'étude des stratégies de régulation adaptées au temps réel. Pour cela, deux méthodes ont été développées : l'une correspondant à l'élaboration de lois heuristiques à partir d'une stratégie optimale calculée sous des sollicitations représentatives d'une année-type (chapitre 4) et l'autre consistant à adapter au temps réel la commande optimale sous contraintes d'état et de commande (chapitre 5).

Chapitre 1

La régulation énergétique des bâtiments

L'objectif de ce chapitre consiste à réaliser un état de l'art sur la régulation énergétique des bâtiments. Dans un premier temps, nous chercherons à déterminer les principaux objectifs de la régulation ainsi que les commandes associées. Par la suite, les différents types de modèles utilisés pour la mise en place d'une régulation anticipative seront présentés. Les méthodes de résolution du problème d'optimisation ainsi posé seront également étudiées. Enfin, nous nous concentrerons sur la problématique de gestion du réseau électrique et en particulier sur l'application de la régulation énergétique des bâtiments pour répondre à cet enjeu.

PLAN DU CHAPITRE 1

1.	<u>LES OBJECTIFS DE LA RÉGULATION</u>	<u>23</u>
2.	<u>ÉTAT DE L'ART DES SYSTÈMES DE RÉGULATION</u>	<u>25</u>
2.1	INTRODUCTION	25
2.2	SYSTÈMES DE RÉGULATION SANS MODÈLE THERMIQUE DU BÂTIMENT	26
2.2.1	LES RÉGULATEURS CLASSIQUES	26
2.2.2	LES RÉGULATEURS AVANCÉS.....	26
2.3	SYSTÈME DE RÉGULATION AVEC MODÈLE THERMIQUE DU BÂTIMENT	27
2.3.1	LES MODÈLES THERMIQUES DU BÂTIMENT	27
2.3.2	LA COMMANDE PRÉDICTIVE	30
2.3.3	L'OPTIMISATION HORS-LIGNE	31
3.	<u>THÉORIE DE LA COMMANDE PRÉDICTIVE</u>	<u>32</u>
3.1	LA COMMANDE OPTIMALE.....	32
3.1.1	LE PRINCIPE DU MINIMUM DE PONTRYAGIN.....	33
3.1.2	LA PROGRAMMATION DYNAMIQUE	34
3.2	LES MÉTHODES DE RÉOLUTION	34
3.2.1	LES MÉTHODES DIRECTES.....	35
3.2.2	LES MÉTHODES INDIRECTES.....	35
4.	<u>APPLICATION À L'EFFACEMENT DE LA CONSOMMATION ÉLECTRIQUE DE POINTE</u>	<u>35</u>
4.1	CONTEXTE : DÉSÉQUILIBRE DU RÉSEAU ÉLECTRIQUE	36
4.2	ÉTAT DE L'ART DES MÉTHODES D'EFFACEMENT	37
4.2.1	LA « DEMAND SIDE RESPONSE (DSR) »	37
4.2.2	LES OFFRES D'EFFACEMENT DU FOURNISSEUR D'ÉLECTRICITÉ	38
4.2.3	LES TECHNIQUES D'EFFACEMENT AU NIVEAU DU BÂTIMENT	40
4.2.4	EXPÉRIMENTATIONS ET SITES PILOTES	43
5.	<u>CONCLUSION DU CHAPITRE.....</u>	<u>45</u>

1. LES OBJECTIFS DE LA RÉGULATION

De nombreux objectifs sont associés à la régulation énergétique des bâtiments, dont les principaux sont la réduction des consommations énergétiques et le maintien du confort de l'occupant.

La maîtrise de la consommation énergétique du bâtiment peut être assurée en profitant des apports externes (rayonnement solaire, fraîcheur de la nuit) et internes (énergie dissipée par les occupants et les équipements). Cependant, il peut exister un décalage temporel entre le moment où l'apport est disponible et l'instant où il serait le plus utile. L'utilisation de capacités de stockage du bâtiment est alors une réponse pertinente pour décaler dans le temps la restitution des apports. Par exemple, dans le cas de la climatisation, il est possible d'utiliser l'inertie thermique du bâtiment et sa capacité à stocker les apports excédentaires pendant la journée pour les évacuer la nuit grâce à un système de ventilation. Il s'agit des techniques de *night cooling* ou *free cooling* qui valorisent le froid « gratuit » par la mise en place d'une ventilation (naturelle ou forcée) lorsque la température extérieure est plus basse la nuit. Ces techniques s'appliquent principalement à des bâtiments tertiaires soumis à de fortes charges internes et permettent ainsi de réduire les demandes de climatisation pendant la journée (Braun et al. 2001 ; Chahwane 2011). Concernant le logement, la diminution des consommations de chauffage en hiver est un autre cas d'application. Le but est alors de profiter au maximum des apports solaires en prévoyant à l'avance l'évolution des conditions météorologiques extérieures (Nygard Ferguson 1990 ; Bauer 1998). Une gestion optimale des charges de chauffage permet ainsi de réduire la consommation énergétique du bâtiment (Ky Le 2008 ; Malisani 2012). Enfin, une dernière application concerne la réduction de la consommation d'électricité en période de pointe lors de la période estivale avec le contrôle de la climatisation (principalement pour les bâtiments tertiaires) ou lors de période hivernale avec le contrôle du système de chauffage (Greensfelder et al. 2011 ; Favre 2013).

La régulation énergétique du bâtiment peut également répondre à des objectifs de maintien ou d'amélioration du confort de l'occupant. La qualité de vie dans un bâtiment peut ainsi être définie par plusieurs facteurs :

- le confort thermique ;
- le confort visuel ;
- le confort acoustique ;
- la qualité de l'air intérieur.

Différentes méthodes peuvent être utilisées pour évaluer le confort thermique. Une des approches les plus simples consiste à définir des seuils de confort (en °C) et à quantifier le dépassement de ces seuils par la température du local. Par exemple, l'inconfort thermique peut être caractérisé par le pourcentage de temps d'occupation où la température du local est supérieure ou inférieure à ces seuils de confort. La température du local est souvent caractérisée par la température opérative correspondant à une moyenne des échanges convectifs (température de l'air) et des échanges radiatifs

Chapitre 1 : La régulation énergétique des bâtiments

(température des parois). Une deuxième approche repose sur la méthode de Fanger et l'utilisation de deux indices pour évaluer le confort thermique d'une pièce (Fanger 1970 ; Humphreys et Nicol 2002) : l'indice PMV (*Predicted Mean Vote*) et l'indice PPD (*Percentage of People Dissatisfied*). Enfin, l'approche adaptative, intégrant dans sa réflexion la capacité d'adaptation climatique et la capacité d'interaction de l'occupant avec son environnement, peut être également employée (Nicol et Humphreys 2002).

Le confort visuel peut quant à lui être évalué par le niveau d'éclairement (exprimé en lux). Différentes normes existent telles que la norme ISO 16817 :2012 ou la norme NF EN 12464-1. Elles définissent les exigences d'éclairage selon les types de bâtiments (bureaux, logement, école, etc.) et selon les activités exercées à l'intérieure de ces bâtiments.

Pour le confort acoustique, la réglementation fixe des performances minimales selon les types de bâtiments et les usages. En particulier, l'isolation acoustique (exprimée en dB) aura pour but de se protéger des bruits extérieurs. Par exemple la réglementation thermique 2012 ¹(annexe II de la RT2012) définit trois classes d'exposition des bâtiments au bruit des infrastructures de transport.

Enfin, la qualité de l'air intérieure (QAI) est un aspect du confort à ne pas négliger. Ainsi, différentes réglementations (en France, l'arrêté du 24 mars 1982) fixent des taux minimaux de renouvellement d'air des volumes considérés en fonction du type d'activité et du nombre d'occupants. Cette qualité de l'air intérieure est fonction de l'entrée de polluants extérieurs mais également de polluants intérieurs provenant des matériaux, des équipements et de l'occupation même (Deoux et Deoux 2002). Par exemple, la QAI est couramment estimée par l'utilisation d'un indicateur mesurant la concentration de dioxyde de carbone (CO₂) dans le bâtiment, cette concentration provenant principalement de la présence des occupants dans le bâtiment. Le renouvellement d'air et la ventilation forcée sont les moyens utilisés pour contrôler la qualité de l'air intérieur (Emmerich et Persily 2001 ; Wang et Xu 2004).

Les objectifs de confort peuvent entrer en conflit avec les objectifs de réduction des consommations énergétiques. Par exemple, une modification des températures de consigne de chauffage pour diminuer les consommations énergétiques peut entraîner un non-respect du confort de l'occupant. De même, une trop forte variation de la température de consigne provoque l'inconfort. Pour cela, des régulations multi-objectifs existent qui ont pour but de diminuer les consommations énergétiques tout en respectant le confort de l'occupant. Il s'agit alors de minimiser une fonction de coût global sous des contraintes de confort (Malisani 2012 ; Favre 2013).

La régulation énergétique des bâtiments répond donc à différents objectifs, dont les principaux sont la réduction des consommations énergétiques et le maintien ou l'amélioration du confort des occupants. Pour répondre à ces objectifs, différentes commandes leur sont associées telles que le contrôle du chauffage, de la climatisation, de la ventilation (naturelle ou forcée), de l'éclairage, des ouvrants ou encore des protections solaires.

¹<http://www.legifrance.gouv.fr/affichTexte.do?cidTexte=JORFTEXT000026871753&dateTexte=&categorieLien=id>

Dans cette thèse, nous allons nous concentrer sur l'utilisation de la régulation énergétique des bâtiments pour réaliser l'effacement du chauffage lors des périodes de pointe de consommation électrique.

2. ÉTAT DE L'ART DES SYSTÈMES DE RÉGULATION

2.1 Introduction

Suite à la présentation des différents objectifs et commandes associées d'une régulation énergétique appliquée au bâtiment, il est possible de dresser un état de l'art des différentes méthodes existantes.

Dans un système de régulation, on peut distinguer d'une part le système physique sur lequel s'applique la régulation, et d'autre part le système de régulation.

Le système physique est composé de différents éléments tels que :

- **le bâtiment et ses différents systèmes** (chauffage, climatisation, etc.) sur lesquels est appliquée la régulation ;
- **les occupants** qui imposent des contraintes de confort ;
- **les sollicitations** telles que la météorologie, les apports internes dus aux occupants et aux équipements, ainsi que les caractéristiques du site (masques du bâtiment, climat local).

Quant aux paramètres du système de régulation, on peut citer :

- **la commande** correspondant au système piloté par la régulation, tels que les systèmes de chauffage, de climatisation, de ventilation, ou les protections solaires ;
- **les contraintes** qui portent aussi bien sur le système physique (températures de confort à ne pas dépasser, variation de température à respecter, etc.) que sur les paramètres propres au système de régulation (puissance de chauffage limitée, temps de calculs à respecter, etc.) ;
- **la fonction objectif** (dans le cas de la régulation optimale) qui sert de critère pour déterminer la meilleure solution au problème d'optimisation. Ce critère peut être de minimiser la consommation énergétique, de maximiser le confort, ou de minimiser le coût d'une consommation énergétique par exemple.

Les systèmes de régulation ont alors pour but de suivre une consigne donnée ou de minimiser une fonction objectif donnée tout en respectant des contraintes fixées. L'utilisation ou non d'un modèle thermique de bâtiment permet alors de diviser en deux grandes catégories les systèmes de régulation existants. On trouvera une présentation détaillée des différentes méthodes de régulation dans l'article de Dounis et Caraiscos (2009) et la thèse de Morosan (2011).

2.2 Systèmes de régulation sans modèle thermique du bâtiment

Dans la plupart des bâtiments, les lois de commande utilisées pour les systèmes de chauffage, de ventilation et de climatisation (CVC, ou en anglais HVAC : *Heating, Ventilation and Air Conditioning*) sont relativement simples. Ces systèmes de régulation ne reposent pas sur un modèle thermique du bâtiment et ont souvent pour objectif de maintenir le confort thermique en respectant une température de consigne.

2.2.1 Les régulateurs classiques

Les méthodes de régulation classiques correspondent à la mise en place d'un thermostat. Le plus souvent le système de régulation se compose d'un thermostat, d'un amplificateur et d'un mécanisme (ou moteur) pour actionner les vannes ou les commutateurs. Ainsi, on utilise des lois de commande de type tout-ou-rien (TOR) ou des régulateurs de type PID (Proportionnel intégral dérivé) pour respecter la température de consigne. Le régulateur PID est le système de contrôle classique lié aux rétroactions le plus utilisé. Pour le réglage du PID, plusieurs règles existent (dont certaines permettent à ses paramètres d'évoluer au cours du temps) telles que celles de Ziegler-Nichols, Cohen-Coon, Chien-Hrones-Reswick ou encore Lee-Park-Lee-Brosilow². Cependant, ces systèmes sont incapables d'anticiper un changement des sollicitations ou des contraintes. Une alternative classique consiste alors à utiliser des systèmes de régulation avancés reposant sur une approche dite intelligente.

2.2.2 Les régulateurs avancés

Ce type de contrôle, appelé généralement BIEMS (*Building Intelligent Energy Management Systems*), a pour objectif de parvenir à un contrôle simple, adaptatif et performant sans avoir recours à un modèle thermique du bâtiment. Une approche courante repose sur l'utilisation de lois heuristiques.

Ces stratégies de régulation reposent fréquemment sur l'utilisation d'arbres de décision : à partir des différentes sollicitations mesurées ou prédites auxquelles le bâtiment est soumis (par exemple les conditions météorologiques, ou l'occupation du bâtiment) ainsi que de la mesure des sorties (ou de l'estimation de l'état) du bâtiment, des lois heuristiques (ou règles de décision) sont utilisées pour déterminer la commande à appliquer à chaque système énergétique. La Figure 1 illustre le fonctionnement de ce type de régulateur.

² N. Petit, P. Rouchon, Dynamique et contrôle des systèmes, Cours, MINES ParisTech, 2014

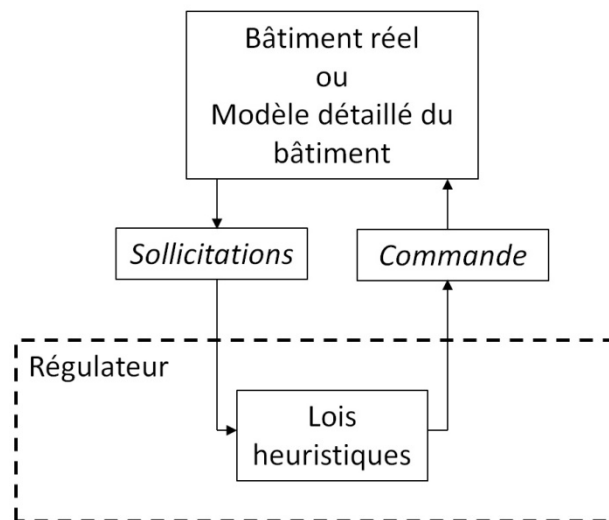


Figure 1 : Régulateur basé sur des lois heuristiques, adapté de Coffey (2012)

Cependant, plus le bâtiment est performant énergétiquement, plus les interactions et effets de couplage entre celui-ci, son environnement, ses systèmes énergétiques et ses usages deviennent importants. Il devient alors difficile de définir, de manière intuitive, des lois heuristiques et un mode de fonctionnement optimal. Par conséquent, pour assurer le confort des occupants et maintenir les performances énergétiques du bâtiment, les stratégies de régulation doivent pouvoir s'adapter en continu aux usages et conditions environnementales changeantes. Elles doivent également anticiper l'état futur du bâtiment (à travers un modèle thermique du bâtiment) ainsi que l'évolution de différents paramètres tels que les conditions météorologiques, les tarifs ou le contenu CO₂ de l'électricité pour déterminer la gestion optimale des flux d'énergie.

Une alternative consiste alors à utiliser des méthodes de régulation plus avancées permettant de résoudre des problèmes d'optimisation complexes. Ces techniques reposent sur l'application de la commande prédictive (ou MPC pour *Model Predictive Control*) avec l'utilisation d'un modèle thermique du bâtiment.

2.3 Système de régulation avec modèle thermique du bâtiment

2.3.1 Les modèles thermiques du bâtiment

Un modèle thermique dynamique du bâtiment est nécessaire lorsque le système de régulation doit anticiper des changements futurs au niveau des contraintes ou des sollicitations. Le système réel (ici le bâtiment) est alors décrit par un ensemble d'équations mathématiques qui permet de représenter la relation existante entre les entrées et les sorties du système.

Chapitre 1 : La régulation énergétique des bâtiments

Il est possible de diviser les modèles en trois catégories en fonction des informations utilisées pour leur conception :

- les modèles de type « boîte blanche » ou modèles de connaissance ;
- les modèles de type « boîte noire » ou modèles de comportement ;
- les modèles de type « boîte grise » ou modèles semi-physiques.

2.3.1.1 Modèle de type « boîte blanche »

Les modèles de type boîte blanche (ou modèles de connaissance) reposent sur la description physique du système. Il s'agit de modèles physiques construits à partir de l'application de lois générales ou de lois empiriques qui régissent les phénomènes intervenant au sein du système. Ces modèles comportent uniquement des paramètres physiques.

Selon le niveau de détail voulu, le modèle peut contenir quelques dizaines à quelques milliers d'équations, entraînant des temps de modélisation et de calcul variables. Selon le type d'équations utilisées, ces modèles peuvent être classifiés en :

- modèles linéaires et modèles non-linéaires ;
- modèles continus ou discontinus.

Dans le cadre de la modélisation thermique d'un bâtiment, de nombreux logiciels de simulation thermique dynamique des bâtiments ont été développés et peuvent être considérés comme des modèles de type boîte blanche. On peut citer par exemple EnergyPlus³, ESP-r⁴ ou Pléiades+COMFIE⁵. Un état de l'art portant sur une vingtaine d'outils a été réalisé en 2008 (Crawley et al. 2008). L'utilisation de ces logiciels requiert une connaissance précise de la composition des parois et des métrés du bâtiment à modéliser.

2.3.1.2 Modèle de type « boîte noire »

Les modèles de type boîte noire (ou modèle de comportement) sont des modèles non physiques construits sur la base de mesures effectuées sur les entrées et les sorties du système à modéliser. La modélisation consiste alors à utiliser les mesures disponibles pour estimer les paramètres des équations reliant les entrées aux sorties dans le but d'obtenir la meilleure précision possible. Ces paramètres sont traditionnellement identifiés de manière automatique (Ljung 1999).

On distingue généralement deux approches pour les modèles de type boîte noire : les modèles linéaires et les modèles non-linéaires. Les modèles linéaires correspondent à l'utilisation de fonctions de transfert pour représenter le lien entre les entrées et les sorties du système. On peut citer par exemple (Henze et Neumann 2012) les modèles de type FIR (*Finite Impulse Response*), ARX (*Autoregressive with*

³ Source : <http://apps1.eere.energy.gov/buildings/energyplus/>

⁴ Source : <http://www.esru.strath.ac.uk/Programs/ESP-r.htm>

⁵ Source : <http://www.izuba.fr/logiciel/pleiadescomfie>

Chapitre 1 : La régulation énergétique des bâtiments

external input), ARMAX (*Autoregressive moving average and external input*), ARMA (*Autoregressive moving average*) ou encore BJ (Box-Jenkins). Ils peuvent être définis de manière générale par :

$$A(q)y(t) = \frac{B(q)}{F(q)}u(t) + \frac{C(q)}{D(q)}e(t) \quad (1.1)$$

avec :

- $u(t)$: entrées mesurées ;
- $y(t)$: sorties mesurées ;
- $e(t)$: perturbations ;
- q : l'opérateur de recul avec $q^{-1}u(t) = u(t - 1)$ et $A(q) = 1 + a_1q^{-1} + \dots + a_nq^{-n}$;
- A, B, C, D et F : matrices ou polynômes.

Les modèles non-linéaires correspondent quant à eux à l'utilisation de réseaux de neurones. Un réseau de neurones artificiels (ou ANN pour *Artificial Neural Network*) est un modèle de calcul qui essaie de copier le fonctionnement des neurones biologiques. Les neurones composant le réseau sont organisés en plusieurs couches et reliés entre eux de manière pondérée. Le comportement de ce système est acquis lors de la phase d'apprentissage où il est confronté à des données issues du problème à traiter. Il ajuste alors la valeur de ses poids pour obtenir des résultats similaires à ceux présentés lors de la phase d'apprentissage.

2.3.1.3 Modèle de type « boîte grise »

Les modèles de type boîte grise correspondent à des modèles hybrides combinant des modèles de type boîte blanche et boîte noire. Ces modèles peuvent s'appliquer à des modèles globaux combinant d'une part des modèles de connaissance et d'autre part des modèles de comportement. Ils peuvent également correspondre à un modèle de type boîte blanche complété par un modèle de type boîte noire dans le but de modéliser des paramètres non pris en compte par le modèle physique.

2.3.2 La commande prédictive

Dans le cadre du bâtiment, les systèmes de régulation reposant sur un modèle thermique du bâtiment utilisent la technique de la commande prédictive. Contrairement aux régulateurs classiques, dans la commande prédictive la minimisation de la fonction objectif est réalisée en prenant en compte l'état actuel et futur du bâtiment par la prévision de l'évolution des sollicitations extérieures et intérieures. Cette méthode consiste ainsi en une résolution répétée à chaque période d'échantillonnage du régulateur (fixé par l'utilisateur) d'un problème de commande optimale, c'est-à-dire comment aller d'un état actuel à un état objectif de manière optimale tout en respectant les contraintes. À chaque période d'échantillonnage, une séquence de commande optimale (minimisant la fonction coût) est calculée en boucle ouverte sur un horizon de prédiction fixe. Cependant, seule la première commande est appliquée et la procédure est reprise à la période d'échantillonnage suivante (principe de l'horizon fuyant). La Figure 2 illustre le fonctionnement de la commande prédictive sur un horizon de prédiction $N\Delta t$.

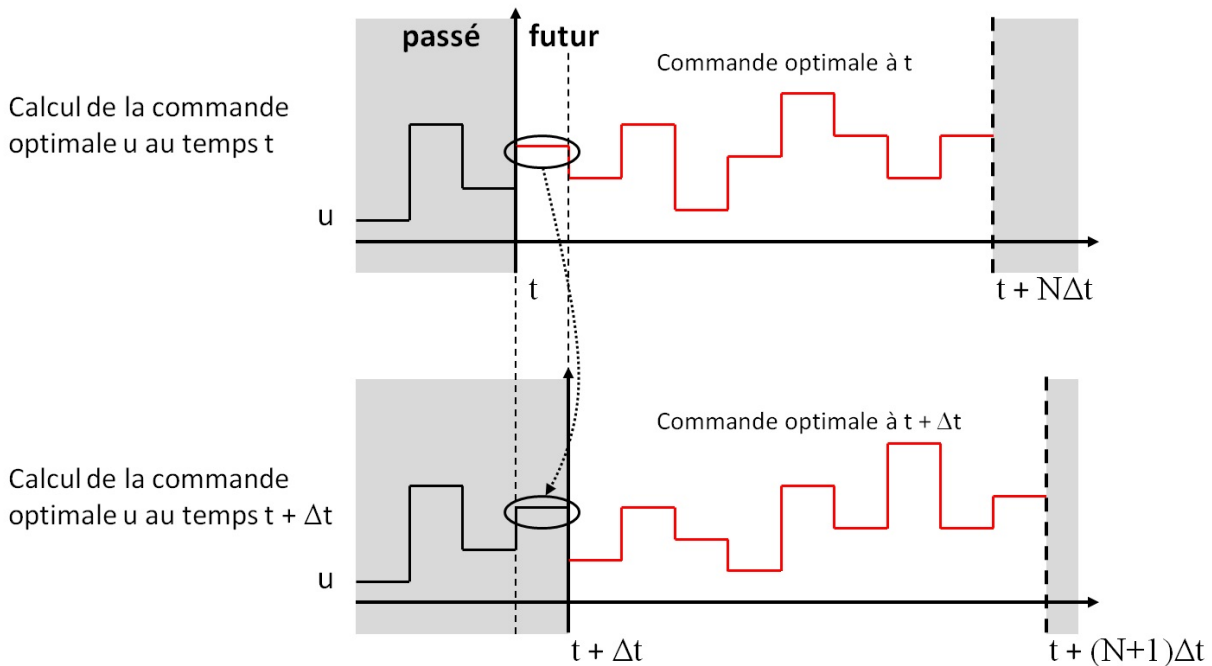


Figure 2 : Fonctionnement de la commande prédictive

Initiée par Richalet et al. (1978) la commande prédictive est aujourd'hui une technique classiquement utilisée dans différents domaines industriels (pétrochimie par exemple) où le respect des contraintes dans le processus industriel est particulièrement important. Il s'agit d'un thème de recherche encore actif dont la théorisation est plus récente que les applications. Une revue détaillée de la théorie de la commande prédictive est disponible dans Mayne et al. (2000). Récemment, l'utilisation de la commande prédictive dans le domaine du bâtiment s'est développée, comme en attestent de nombreux travaux de recherche (Chen 2002 ; Henze et al. 2005 ; Freire et al. 2008 ; Moroşan et al. 2010 ; Prívará et al. 2011 ; Oldewurtel et al. 2012 ; Prívará et al. 2012 ; Corbin et al. 2013 ; Touretzky et Baldea 2014). La Figure 3 illustre l'application de la commande prédictive à la régulation d'un bâtiment.

Chapitre 1 : La régulation énergétique des bâtiments

Cette technique a été longtemps pénalisée par le coût élevé de la technologie nécessaire à l'implémentation et la difficulté d'obtenir un modèle mathématique du bâtiment satisfaisant. Mais suite aux évolutions récentes des moyens de calculs (permettant l'exécution rapide de calculs complexes) et de la disponibilité de capteurs fiables et bon marché, cette technologie devient de plus en plus accessible. Cependant, elle reste encore éloignée des pratiques courantes des professionnels du bâtiment, en particulier concernant l'utilisation de règles expertes dans les systèmes de régulation. Une alternative consiste alors à utiliser des méthodes d'optimisation hors-ligne permettant d'identifier des lois de commande simplifiées.

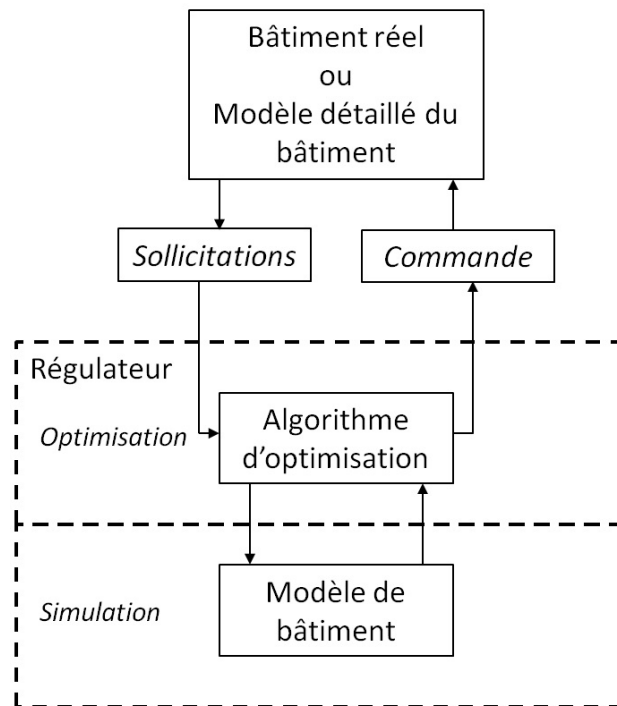


Figure 3 : Régulateur basé sur la commande prédictive, adapté de Coffey (2012)

2.3.3 L'optimisation hors-ligne

Une première méthode consiste à résoudre de manière explicite le problème de commande prédictive, l'objectif étant d'obtenir une formulation explicite des lois de commande. Au cours des dernières années, le développement ou l'utilisation de différentes méthodes – la programmation multiparamétrique (Bemporad et al. 2002), la programmation dynamique (J. B. Mare 2004) ou encore l'utilisation des polyèdres paramétrés (Olaru 2005) – a permis la description explicite de la loi de commande pour certains problèmes de commande prédictive. L'expression de la loi prédictive est alors calculée hors-ligne et stockée dans une table d'interpolation (« *look-up table* »). Ainsi, au lieu de résoudre un problème d'optimisation en ligne à chaque pas de temps, il suffit d'évaluer la fonction explicite stockée (classiquement une fonction affine par morceaux). Plus précisément, l'utilisation classique de la commande prédictive consiste à résoudre un problème d'optimisation paramétré par l'état actuel (mesuré) du système. En revanche, s'il est possible de résoudre le problème d'optimisation pour tous les états possibles du système (optimisation « hors-ligne »), il n'est alors plus nécessaire de

résoudre le problème d'optimisation à chaque pas de temps (optimisation « en ligne »). Cette méthode permet ainsi de fournir des lois de commande optimale qui couvrent l'ensemble de l'espace des états. Cependant, cette méthode est difficilement applicable au cas de la régulation énergétique du bâtiment. Une alternative a été proposée consistant à approximer la résolution explicite de la commande prédictive (Coffey 2012). Pour diminuer la dimension du problème, l'idée est de résoudre la commande prédictive seulement sur un ensemble de points déterminés à l'avance (sollicitations extérieures, état initial du bâtiment) et de réaliser des interpolations entre les différents points de la grille. Bien qu'intéressante, la mise en œuvre de cette méthode nécessite de grandes capacités de calculs.

Une deuxième méthode pour approximer les résultats de la commande prédictive est de minimiser la fonction objectif du problème d'optimisation en simulant le bâtiment sous des sollicitations extérieures et intérieures représentatives d'une année type. A partir des résultats obtenus on peut alors identifier une loi de commande à fournir au système de régulation (à travers des lois de commande heuristique par exemple), et l'utiliser pour la gestion en temps réel du bâtiment. L'objectif ici est de fournir des stratégies générales de gestion énergétique pour minimiser la consommation d'énergie ou les coûts de fonctionnement. Cette approche a par exemple été utilisée pour identifier des lois de commande d'un système automatisé de protection solaire d'un bâtiment (Le et al 2014) ou encore pour le contrôle de l'ouverture des fenêtres (May-Ostendorp et al. 2013).

Dans cette thèse, nous allons développer des stratégies de gestion énergétique reposant d'une part sur l'élaboration de lois heuristiques à partir des résultats de la stratégie optimale calculée par la commande optimale (optimisation « hors-ligne ») et d'autre part sur l'application directe de la commande prédictive (optimisation « en ligne »). Une présentation de la théorie de la commande prédictive et de la commande optimale est alors indispensable.

3. THÉORIE DE LA COMMANDE PRÉDICTIVE

La commande prédictive présente l'avantage d'utiliser un modèle dynamique du système à contrôler permettant d'anticiper son comportement futur. Dans cette méthode, la séquence de commande optimale à appliquer au système est déterminée par la résolution, à chaque période d'échantillonnage, d'un problème de commande optimale consistant à maximiser une fonction objectif ou minimiser une fonction coût. Nous allons nous intéresser dans la suite au principe de la commande optimale ainsi qu'aux méthodes de résolution.

3.1 La commande optimale

La théorie de la commande optimale propose des méthodes mathématiques permettant d'étudier des systèmes dynamiques. Le problème de commande optimale consiste à déterminer la commande d'un système qui minimise un critère donné (fonction de coût) sous des contraintes d'état et/ou de commande. Dans le cadre de cette thèse, il s'agit de déterminer la loi de commande de chauffage qui

Chapitre 1 : La régulation énergétique des bâtiments

minimise le coût de la consommation de chauffage sous des contraintes de température (contraintes d'état) et de puissance de chauffage (contraintes de commande).

On s'intéresse tout d'abord au problème général de commande optimale (sans contraintes d'état) s'écrivant sous la forme suivante :

$$\min_{u \in U} \left[J(u) = \int_0^{t_f} L(x^u(t), u(t)) dt \right] \quad (1.2)$$

sous la contrainte de dynamique suivante :

$$\dot{x}^u(t) = f(x^u(t), u(t)) \quad ; \quad x(0) = x_0 \quad (1.3)$$

où L est une fonction à valeur réelle régulière de ses arguments, et où $x^u(t)$ et $u(t)$ sont respectivement l'état et le contrôle qui satisfont l'équation différentielle (1.3). Dans le cadre de cette thèse, l'équation différentielle (1.3) correspond à la représentation sous forme d'état de la dynamique du bâtiment, $x^u(t)$ représente l'état du bâtiment au temps t et $u(t)$ la puissance de chauffage à injecter dans le bâtiment au temps t .

On peut ainsi agir sur l'état x à travers la variable de commande u sur l'horizon de temps $[0; t_f]$. L'ensemble U représente l'ensemble des commandes admissibles tel que les contraintes de commande soient respectées. Le problème de commande optimale consiste alors à trouver la commande u et l'état associé x^u solution de l'équation différentielle (1.3) et minimisant le critère intégral (1.2).

La théorie de la commande optimale comporte deux grandes approches : le principe du minimum de Pontryagin et la programmation dynamique. Nous discuterons des différences entre les deux approches dans les sections suivantes.

3.1.1 Le principe du minimum de Pontryagin

Le principe du minimum de Pontryagin donne une condition nécessaire (mais non suffisante) d'optimalité. Si le contrôle $u^* \in U$ associé à la trajectoire $x^* \in \mathbb{R}^n$ est solution du problème de commande optimale, alors il existe une application $p(\cdot) : [0; t_f] \rightarrow \mathbb{R}^n$ appelée vecteur adjoint telle que, pour presque tout $t \in [0; t_f]$:

$$\dot{x}^*(t) = \frac{\partial}{\partial p} H(x^*(t), u^*(t), p(t)) \quad (1.4)$$

$$\dot{p}(t) = -\frac{\partial}{\partial x} H(x^*(t), u^*(t), p(t)) \quad (1.5)$$

$$H(x^*(t), u^*(t), p(t)) = \min_u H(x^*(t), u(t), p(t)) \quad (1.6)$$

où $H(x(t), u(t), p(t)) = L(x(t), u(t)) + p(t)^t f(x(t), u(t))$ est l'Hamiltonien du système.

Cette condition nécessaire pour trouver un contrôle optimal nous amène alors à la résolution du système suivant :

$$\begin{aligned}
 \dot{x}^u(t) &= f(x^u(t), u(t)) \\
 x(0) &= x_0 \\
 \dot{p}(t) &= -\frac{\partial}{\partial x} H(x(t), u(t), p(t)) \\
 p(t_f) &= 0 \\
 u(t) &\in \underset{v}{\text{arg min}} H(x(t), v(t), p(t))
 \end{aligned} \tag{1.7}$$

La méthode de résolution de ce système est présentée dans le §3.2.2. L'extension du problème de commande optimale à des contraintes d'état (contraintes de température) est possible par l'utilisation de méthodes de points intérieurs par exemple (Malisani, et al. 2014). Cette méthode sera présentée dans le chapitre 5.

3.1.2 La programmation dynamique

Cette approche est basée sur le principe d'optimalité de Bellman (1957) qui stipule : « Une suite de commande est optimale si, quels que soient l'état et l'instant considérés sur la trajectoire qui lui est associée, les commandes ultérieures constituent, pour le problème ayant cet état et cet instant comme conditions initiales, une suite de commande optimale ».

On considère ici le système :

$$\dot{x}(t) = f(x(t), u(t)) \quad ; \quad x(t_0) = x_0 \tag{1.8}$$

et on s'intéresse au problème de commande optimale :

$$\min_{u \in U} \left[J_{x_0, t_0}(u) = \int_{t_0}^{t_f} L(x(t), u(t)) dt \right] \tag{1.9}$$

On définit alors la fonction valeur V sur $\mathbb{R}^n \times [0; t_f]$. Il s'agit de la fonction ayant pour valeur la valeur optimale pour le problème (1.8)-(1.9) avec pour condition initiale (x_0, t_0) :

$$V(x_0, t_0) = \inf_{u \in U} \{ J_{x_0, t_0}(u) \} \tag{1.10}$$

D'après le principe de Bellman, il est possible d'établir que la fonction valeur V du problème de commande optimale est solution d'une équation aux dérivées partielles non linéaire appelée équation d'Hamilton-Jacobi-Bellman (HJB) :

$$\frac{\partial}{\partial t} V(x_0, t_0) + \inf_{v \in U} H \left(x_0, v, \frac{\partial}{\partial x} V(x_0, t_0) \right) = 0 \tag{1.11}$$

Cette approche a l'avantage d'être nécessaire et suffisante, mais présente des inconvénients en termes de temps de calcul et d'encombrement de mémoire.

3.2 Les méthodes de résolution

Il existe deux types de méthodes numériques de résolution en commande optimale : les méthodes directes et les méthodes indirectes (Trélat 2005).

3.2.1 Les méthodes directes

Les méthodes directes consistent à discrétiser l'état et le contrôle et à ramener le problème à un problème d'optimisation non-linéaire en dimension finie (ou problème de programmation non-linéaire). La résolution numérique peut être effectuée par une méthode de pénalisation ou par une méthode SQP (*Sequential Quadratic Programming*) par exemple. Pour accélérer la résolution numérique du problème, des méthodes d'inversion peuvent par exemple être employées dont l'objectif est de ne paramétrer que les états minimaux et d'en déduire les autres états et les commandes par dérivées (Petit et al. 2001 ; Chaplais et Petit 2008, ; Petit et Sciarretta 2011). Les méthodes directes ont l'avantage d'être simples à mettre en œuvre et d'être peu sensibles au choix de la condition initiale. En revanche, elles ont l'inconvénient d'être peu précises et d'être gourmandes en mémoire. Betts (2010) présente une étude complète sur les méthodes directes et leur mise en œuvre numérique.

3.2.2 Les méthodes indirectes

Les méthodes indirectes consistent à résoudre par une méthode de tir un problème aux valeurs limites obtenu par l'application du principe du minimum de Pontryagin. Ce dernier donne les conditions nécessaires d'optimalité et permet d'exprimer la commande comme une fonction de l'état et de l'état adjoint ($u(t) = \Gamma(x(t), p(t))$). Ces conditions nécessaires d'optimalité amènent alors à résoudre un problème aux deux bouts (avec une condition initiale sur l'état et une condition finale sur l'état adjoint). L'idée de l'algorithme de tir est alors d'introduire une inconnue, à savoir la valeur initiale de l'état adjoint p_0 et de considérer la fonction de tir qui à p_0 associe la condition finale $p(t_f)$, où (x, p) est solution du problème de Cauchy (permettant d'établir l'existence et l'unicité d'une solution) sur $[0, t_f]$:

$$\begin{aligned} \dot{x}(t) &= f(x(t), \Gamma(x(t), p(t))), & x(0) &= x_0 \\ \dot{p}(t) &= -\frac{\partial}{\partial x} H(x(t), \Gamma(x(t), p(t)), p(t)), & p(0) &= p_0 \end{aligned} \quad (1.12)$$

On se ramène donc à chercher un zéro d'une fonction, ce qui peut être réalisé par une méthode de Newton.

La méthode de tir a l'avantage d'être très précise et d'avoir un coût numérique faible. Cependant, la convergence de la méthode nécessite une bonne initialisation de p_0 , ce qui peut être difficile à obtenir en pratique.

4. APPLICATION À L'EFFACEMENT DE LA CONSOMMATION ÉLECTRIQUE DE POINTE

L'utilisation d'un système de régulation anticipatif prend toute son importance lorsque le système doit anticiper des variations brusques des sollicitations ou des contraintes. C'est en particulier le cas pour des politiques d'incitation à l'effacement de la consommation électrique de pointe où la grille tarifaire de l'électricité peut subir des variations importantes. Dans la suite de ce chapitre, on se propose

de faire un rapide état de l'art des différentes stratégies de régulation existantes appliquées à l'effacement de la consommation électrique de pointe.

4.1 Contexte : déséquilibre du réseau électrique

Les caractéristiques actuelles de la production d'électricité positionnent le secteur électrique au cœur des tensions énergétiques et plus précisément de l'enjeu sociétal qu'est l'équilibre de la production et de la consommation électrique. En effet, dans le « bilan prévisionnel » publié en 2012 (RTE 2012), RTE observe que sur les dix dernières années la pointe électrique a augmenté 2,5 fois plus vite que l'énergie consommée. A titre d'exemple, lors de la vague de froid de février 2012, la France a connu une pointe de consommation à 102,1 GW. Ainsi, RTE prévoit que la sécurité d'alimentation électrique devrait être assurée jusqu'en 2015 mais qu'à partir de 2016, elle devient plus difficile en raison notamment de la fermeture de certaines centrales thermiques à énergie fossile. La puissance manquante est alors estimée à 1,2 GW en 2016 et à 2,1 GW en 2017.

Ces pointes de consommation électrique sont de différentes natures et dépendent de la période (journée, saison) et de la zone géographique. Il en existe deux types :

- **La pointe journalière** : elle correspond au moment où la consommation électrique totale en France est la plus importante de la journée. Elle est caractérisée par une hausse importante de la consommation pendant quelques heures. En hiver, cette pointe est observée à 19 h et correspond à la mise en service simultanée de plusieurs appareils électriques (chauffage, éclairage, télévision, cuisson, etc.). En été, la pointe est plutôt observée à 13 h.
- **La pointe saisonnière** : elle correspond à une augmentation de la consommation électrique pour répondre aux besoins de chauffage des bâtiments lors de la période hivernale. Cette consommation est très sensible à la température en raison du fort équipement en chauffages électriques des bâtiments français. Ainsi RTE (2014) estime la thermosensibilité de la consommation électrique à 2400 MW par degré Celsius à 19 heures (c'est-à-dire que la baisse d'un degré Celsius entraîne une croissance de la puissance appelée de 2400 MW). Par exemple lors de la vague de froid de l'hiver 2011-2012, 40 % de la consommation d'électricité appelée était due au chauffage électrique. La Figure 4 illustre le phénomène de la pointe saisonnière.

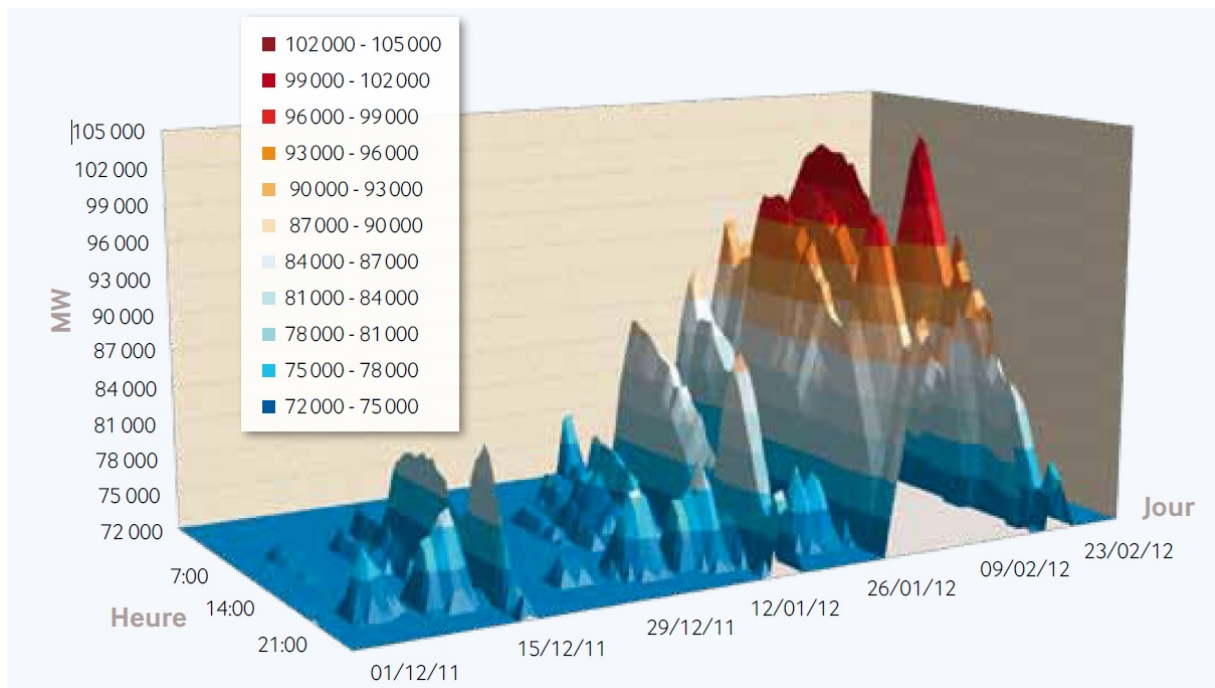


Figure 4 : Évolution de la consommation électrique en France sur l'hiver 2011-2012, extrait de RTE (2012)

Ces problèmes de gestion de la pointe électrique remettent en question la structure du système de production électrique français de type *top-down*, c'est-à-dire une production centralisée et donc « délocalisée » de la consommation d'énergie finale. C'est pourquoi des systèmes de type *bottom-up* qui favorisent la production à l'échelle du quartier et l'utilisation d'énergies renouvelables intégrées aux bâtiments sont à l'étude. Une autre méthode est de développer des stratégies d'effacement de la pointe électrique dans l'optique de lisser la courbe de charge. Un état de l'art sur ces méthodes d'effacement est proposé dans la suite.

4.2 État de l'art des méthodes d'effacement

4.2.1 La « Demand Side Response (DSR) »

La *Demand Side Response* (ou gestion de la demande) correspond aux stratégies d'effacement de la consommation électrique dans le but de lisser la courbe de charge. Elle permet ainsi d'impliquer les consommateurs en les incitant économiquement à consommer au bon moment en fonction des conditions du réseau électrique.

Il existe différentes méthodes de gestion de la demande. On peut citer par exemple :

- **Load shifting (report de la demande « longue durée »)** : correspond au report d'un usage sur la journée, sous la contrainte que la demande doit être satisfaite dans la journée. Il s'agit par exemple du déclenchement de l'ECS (Eau Chaude Sanitaire) en heure creuse. Les usages concernés sont par exemple le lave-linge, le sèche-linge, ou le lave-vaisselle. Cette gestion de la demande implique une influence sur les usages.

Chapitre 1 : La régulation énergétique des bâtiments

- **Peak Clipping (report de la demande « courte durée »)** : correspond au report à court terme d'un usage pour diminuer la pointe électrique. Les usages concernés sont la réfrigération, le chauffage, la climatisation, ou la ventilation. Cette gestion de la demande n'a que peu voire pas d'influence sur les usagers.
- **Valley filling** : le but est de lisser la courbe de charge en remplissant les heures creuses.

4.2.2 Les offres d'effacement du fournisseur d'électricité

4.2.2.1 Les offres en France

4.2.2.1.1 Les effacements tarifaires

Les options tarifaires telles que EJP (créée dans les années 1980) et Tempo (qui lui a succédé dans les années 1990) constituent le premier mécanisme d'effacement de consommation apparu historiquement et toujours le plus important en terme de réduction de puissance. Leur principe est d'inciter le consommateur à réduire sa consommation par un tarif très élevé sur 22 périodes mobiles (de 18 heures pour EJP, de 16 heures pour Tempo en jour rouge) réparties par le fournisseur entre le 1^{er} novembre et le 31 mars. En contrepartie, le tarif est plus attractif en dehors de ces périodes.

Cependant, la mise en extinction du tarif EJP bleu depuis 1998, puis du tarif Tempo bleu professionnel depuis 2004 ont entraîné une diminution de la puissance disponible pour atteindre 2000 MW sur l'hiver 2012-2013. Cette diminution progressive, estimée à 10 % par an, devrait perdurer dans les années à venir (RTE 2013). Ainsi, suite à l'article L 337-9 du code de l'énergie portant sur la fin des tarifs réglementés de vente jaune et vert, et entraînant la suppression d'une grande partie des contrats EJP, le volume d'effacement devrait être inférieur à 1000 MW en 2016.

4.2.2.1.2 Les effacements de marché

RTE propose également un mécanisme d'ajustement sous forme d'un appel d'offres permanent permettant en temps réel de disposer d'une réserve d'ajustement de puissance à la hausse comme à la baisse. Ainsi, un consommateur qui a la possibilité de réduire sa consommation peut déposer une offre, spécifiant la puissance effacée, le délai d'activation, et autres contraintes techniques, ainsi que le coût lié à l'activation. L'exploitant du système électrique commande alors l'activation de l'offre en fonction des besoins d'équilibrage du réseau électrique et selon la préséance économique et les conditions d'utilisation de l'offre.

4.2.2.1.3 Les autres effacements

Il existe d'autres formes d'effacements, tels que les contrats bilatéraux liant un consommateur à son fournisseur d'électricité contenant des clauses d'effacement contractuel. Ces contrats concernent principalement des établissements industriels très gros consommateurs, et représentent un potentiel

d'effacements estimé à 300 MW, auquel on peut ajouter 200 MW d'effacements « de crise » utilisables uniquement en cas de fortes tensions sur le réseau (RTE 2013).

4.2.2.2 Les offres à l'international

A l'international, différents modèles économiques sont utilisés dans les programmes de management de la demande (*Demand Side Response programs*). On peut distinguer deux grandes catégories : les programmes basés sur le temps (*time-based program*) et les programmes basés sur les incitations économiques (*incentive-based program*) (Federal Energy Regulatory Commission 2006 ; Marwan et Kamel 2011).

4.2.2.2.1 « Time-based programs »

Dans les programmes basés sur le temps, on peut citer :

- **Time of Use (TOU)** : il s'agit d'un des plus importants programmes de DSR qui a pour but d'encourager le consommateur à modifier ses comportements et ses usages (Sheen et al. 1994). Basée sur deux coûts de l'électricité, un tarif haut pour la période de pic (période de plusieurs heures) et un tarif bas pour la période hors pic, cette tarification n'applique pas de malus ou de bonus pour le consommateur. Pour participer, le consommateur doit décaler sa consommation d'énergie de la période de pic à la période hors pic dès qu'il reçoit l'information du fournisseur d'électricité. Le prix et le calendrier de chaque période est prédéterminé et constant.
- **Real time pricing (RTP)** : ce programme permet au consommateur d'avoir accès à des prix de l'électricité qui sont variables d'une heure et d'un jour à l'autre et basés sur les prix du marché de production de l'énergie (Moholkar et al. 2004).
- **Critical peak pricing** : dans ce programme, le prix de l'électricité est très élevé lors de la période de pic. Ces périodes sont limitées souvent à 10-15 h par an. Il existe deux types de politiques de prix : soit le prix et la durée de la période sont fixés à l'avance, soit le prix et la période peuvent varier suivant les demandes du réseau électrique.

4.2.2.2.2 « Incentive-based programs »

Dans les programmes basés sur des incitations, on peut trouver :

- **Direct load control (DLC)** : ces programmes concernent principalement le résidentiel ou les petits commerces. Il s'agit de dispositifs de contrôle direct, par un service public ou par un fournisseur d'énergie, de la charge d'équipements électriques (climatiseur, chauffe-eau) dans le but de réduire la demande d'énergie d'un client à certains moments.

- **Interruptible / curtailable (I/C)** : dans ce modèle, le consommateur signe un contrat dit « d'effacement » avec le fournisseur pour réduire sa consommation à certaines heures. Le fournisseur indique ensuite au consommateur les moments où il doit effacer sa consommation, et pénalise celui-ci s'il ne réduit pas sa consommation (Yu et al. 2005).
- **Demand bidding (DB)** : programme qui permet d'identifier les offres des consommateurs prêts à réduire leur consommation. Le fournisseur peut alors utiliser ces offres à un prix spécifique en fonction des besoins d'équilibrage du réseau.
- **Emergency demand response program (EDRP)** : particulièrement appliqué dans les moments où l'électricité est peu disponible comme lors d'évènements majeurs (événement sportif télévisé, vague de froid) qui impliquent des consommations hors du commun, le consommateur est financièrement récompensé pour chaque kWh non consommé lors de ces évènements (Tyagi et Black 2010).

4.2.2.2.3 Exemples de programmes

Suite à la crise de l'énergie en Californie de 2000 et 2001, des investisseurs ont mené l'étude *Statewide Pricing Pilot (SPP)* de juillet 2003 à décembre 2004. Cette étude a montré que les consommateurs pouvaient réduire leur consommation d'électricité de 7,6 % à 27 % lors des périodes de pic en réponse à une tarification dynamique de l'électricité (Faruqui et George 2005). Des études similaires sur l'utilisation de la tarification de l'électricité de type TOU ont été menées par la suite (Herter et al. 2007 ; Herter 2007).

La tarification TOU a été par la suite testée et implémentée dans plusieurs pays. Ainsi Faruqui et Sergici (2010) présentent au travers de 15 études les résultats de ce type de tarification. Par exemple, aux États-Unis, et plus précisément en Floride, le « *Gulf Power Select Program* » a permis de réduire la consommation d'électricité pendant les périodes de pointe de 41 %. De même en Norvège, il y a eu une réduction de 8 % à 9 % de consommation de l'électricité pendant ces mêmes périodes (Faruqui et Sergici 2010).

4.2.3 Les techniques d'effacement au niveau du bâtiment

Après une présentation des différentes offres d'effacement du fournisseur d'électricité, nous allons nous intéresser tout particulièrement dans cette thèse à la mise en place de stratégie de gestion énergétique dans le but d'effacer les consommations de chauffage. L'effacement des autres usages électriques domestiques (eau chaude sanitaire, équipements électriques) peut bien entendu être envisagé dans des programmes de gestion de la demande plus globaux (Da Silva 2011).

Différentes stratégies d'effacement du chauffage (ou de la climatisation) au niveau du bâtiment existent. Elles sont basées soit sur le tarif de l'électricité, soit sur l'utilisation de l'inertie thermique du bâtiment pour décaler la pointe de consommation électrique.

4.2.3.1 Techniques basées sur le tarif de l'électricité

Yang et al. (2013) ont développé une méthode de tarification prenant en compte à la fois le consommateur et le producteur d'électricité. La méthode se base sur une tarification de type TOU, où deux périodes sont considérées (une période de pic et une période de base), et sur une fonction de coût quadratique. Lors de la période de pic, le producteur détermine le tarif TOU en considérant le comportement du consommateur, alors que lors de la période de base, le consommateur répond au tarif TOU en décalant sa consommation d'électricité de la période de pic à la période de base. Les résultats montrent qu'une tarification adéquate pouvait générer aussi bien des profits pour le producteur qu'une réduction du coût de la consommation d'électricité pour le client.

L'utilisation d'une tarification de type TOU amène à développer de nouvelles méthodes pour optimiser les consommations d'énergies des consommateurs. Par exemple, Hämäläinen et Mäntysaari (2002) ont développé une approche multicritère pour le chauffage d'un bâtiment sous des contraintes de prix variable de l'électricité. Ils ont ainsi utilisé la méthode de « *dynamic goal programming* » dont le but est d'optimiser la température intérieure, c'est-à-dire le confort thermique, sous des critères de coût et de consommation d'énergie. L'utilisation de ces méthodes d'optimisation peut être envisagée pour estimer les réponses des consommateurs à la mise en place d'une politique de tarification dynamique (Hämäläinen et al. 2000; Pineau et Hämäläinen 2000).

4.2.3.2 Techniques basées sur l'inertie thermique du bâtiment

4.2.3.2.1 Effacement en été

Les techniques d'effacements basées sur l'inertie thermique du bâtiment peuvent tout d'abord s'appliquer en été. Le but est de maintenir un certain confort thermique dans le bâtiment à l'aide de son inertie en utilisant notamment la ventilation nocturne.

Par exemple, l'état du bâtiment peut être contrôlé par le biais des variations de température des différentes zones thermiques du bâtiment associées à un rafraîchissement nocturne dans le but de réduire la pointe électrique, de tirer partie d'un tarif avantageux de l'électricité et d'utiliser la ventilation naturelle la nuit plutôt qu'une ventilation mécanique (Braun 1990). Les résultats de cette méthode montrent qu'il est possible de réduire de manière significative la pointe électrique d'un bâtiment commercial ainsi que le coût de l'énergie par l'application du contrôle optimal de l'énergie stockée dans le bâtiment. Cependant, la performance dépend de nombreux facteurs, tels que le tarif de l'électricité, les caractéristiques techniques de la ventilation, la météo, l'occupation ainsi que l'inertie du bâtiment (Braun et al. 2001; Braun 2003). Dans une autre étude, l'utilisation intensive de la ventilation nocturne a permis de diminuer la puissance de refroidissement d'au minimum 43 % (Becker et Paciuk 2002).

Xu et al. (2004) ont appliqué une méthode similaire de pré-refroidissement d'un immeuble de bureaux. Après avoir défini un intervalle pour la température de confort (température minimale et maximale), l'idée est de maintenir le bâtiment à la température minimale de confort pendant la période occupée jusqu'à 14 h, puis de 14 h à 17 h (pendant les heures de pointe) la température de zone est

Chapitre 1 : La régulation énergétique des bâtiments

laissée libre et autorisée à atteindre la température maximale de confort. Grâce à cette stratégie, la puissance de refroidissement est réduite de 80 % à 100 %, sans problème de confort thermique. Une précédente étude avait démontré par simulation la possibilité de diminuer de 10 % à 15 % la pointe dans un immeuble de bureaux (Andersen et Brandemuehl 1992).

D'autres études ont été menées dans le passé, aussi bien pour des immeubles de bureaux que dans des laboratoires tests et ont toutes montré le potentiel des différentes techniques d'effacement en été. On peut citer par exemple Ruud et al. (1990) ; Coniff (1991) ; Sukkhir et al. (1993) ; Morris, Braun, et Treado (1994) ; Keeney et Braun (1996).

Sane et Guay (2008) ont étudié une technique d'optimisation dynamique en temps réel sur un horizon fini répondant à une problématique de « *demand response* » d'un bâtiment. Ils l'ont appliquée à des problèmes d'optimisation de type « minimax » (où l'on souhaite résoudre des problèmes du type $\min_x \max_t F_i(x)$). Les résultats ont montré que l'optimisation en temps réel pouvait réduire de manière significative le coût de l'énergie.

Enfin, Favre et Peuportier (2013) ont également étudié l'utilisation de la surventilation nocturne dans un bâtiment performant. La méthode d'optimisation employée est la programmation dynamique et les commandes étudiées concernent la ventilation forcée et la ventilation naturelle. Les résultats obtenus montrent que la ventilation naturelle est plus efficace pour maintenir le confort dans le bâtiment lors d'une période de forte chaleur que la ventilation forcée.

4.2.3.2 Effacement en hiver

Les techniques d'effacement en hiver ont pour but de stocker de la chaleur en utilisant différents systèmes tels que le stockage dans un ballon d'eau chaude ou encore l'utilisation de l'inertie thermique du bâtiment tout en maintenant un certain confort thermique.

Wyse (2011) a étudié deux niveaux d'isolation d'un bâtiment, avec d'une part un niveau d'isolation de l'enveloppe standard et d'autre part une maison passive. Utilisant le logiciel ESP-r, Wyse étudie la réponse du bâtiment à un effacement au cours d'une période hivernale. Il émet l'hypothèse qu'un maximum de 9 % du temps d'occupation pendant lequel la température est en-dessous de 18°C est acceptable (taux d'inconfort). Ses résultats indiquent qu'un effacement d'une heure pour une maison moyennement isolée est acceptable avec 6,4 % de taux d'inconfort, alors que pour la maison passive, le taux d'inconfort est de 0,9 % pour un effacement de 6 heures.

Hong et al. (2011) ont publié une étude qui avait pour but de déterminer le temps maximal d'effacement d'une maison typique du Royaume-Uni chauffée par une pompe à chaleur, prenant en compte le niveau d'isolation, l'influence de la météo et l'occupation. Ils étudièrent pour cela différents mécanismes de stockage de l'énergie : l'inertie du bâtiment, l'utilisation d'un ballon tampon de stockage ou l'augmentation de la température de consigne avant l'effacement. Les résultats montrent qu'il est possible de couper la pompe à chaleur pendant une heure sans effet significatif sur le confort de l'occupant. L'augmentation de la température de consigne de 2°C permet un effacement de 1,5 h, mais

Chapitre 1 : La régulation énergétique des bâtiments

entraîne une augmentation de 10 % de la consommation énergétique de la pompe à chaleur. Enfin, l'utilisation d'un ballon de stockage de 300 L entre la pompe à chaleur et le réseau de distribution permet également un effacement de 1,5 h contre 2 h pour un ballon de 500 L, avec une légère diminution de la consommation d'énergie par rapport au cas de base.

Favre et Peuportier (2012) ont étudié la possibilité de décaler une partie de la consommation du chauffage d'un bâtiment en utilisant sa masse thermique. Pour cela, ils ont utilisé la méthode de la programmation dynamique pour minimiser une fonction de coût, tenant compte d'une tarification différenciée (heures creuses, pleines et de pointe) sous des contraintes de confort (température minimale et gradient de température maîtrisé) et de puissance maximale de l'équipement. Les deux cas d'étude correspondent au même bâtiment, avec une variante de type BBC et une autre peu isolée. Dans le cas de la maison peu isolée, les résultats de l'optimisation montrent qu'il y a un effacement partiel pendant les heures de pointe mais qu'il est nécessaire de chauffer les pièces à plus de 25°C avant l'effacement pour maintenir une température de confort de 19°C. Ils constatent également une forte variation de la température intérieure qui passe de 19°C à 26°C pendant les périodes d'heures creuses de 1 h à 8 h du matin, ainsi qu'une chute brutale de cette dernière de plus de 2,2°C par heure pendant les heures pleines. Dans le cas de la maison BBC, l'effacement des heures de pointe est complet (une partie des heures pleines est également effacée) alors que la variation de la température intérieure ne dépasse pas 1,4°C par heure. Enfin, par rapport à une régulation classique qui consiste à maintenir la température intérieure à 19°C, l'effacement des heures de pointe pour la maison BBC permet de réaliser 18 % d'économie sur la facture énergétique (en fonction des hypothèses tarifaires prises).

4.2.4 Expérimentations et sites pilotes

L'effacement des consommations résidentielles, ou effacement diffus, présente potentiellement de nombreux avantages, tels que la diminution du recours à la production d'électricité par centrales thermiques ou encore une meilleure insertion des énergies renouvelables sur le réseau. Cependant, des études doivent être menées pour mesurer l'impact des campagnes d'effacement sur le confort de l'occupant.

Ainsi, les premiers résultats d'une étude menée conjointement par l'ADEME et le CSTB en collaboration avec la société Voltalis montrent que l'effacement diffus pourrait permettre aux consommateurs de réaliser des économies d'électricité. Les scénarios d'effacements correspondent à des coupures de l'alimentation du chauffage et de l'eau chaude électrique pendant 15 à 20 minutes par heure. Ces coupures permettraient une économie de l'ordre de 7 à 8 % de la consommation totale journalière d'électricité les jours où l'effacement est pratiqué (Les Avis de l'ADEME 2012). De plus, les utilisateurs n'ont pas manifesté d'inconfort lors de cette étude. Cependant, ne donnant pas de détails quant à la typologie des bâtiments étudiés ni concernant les relevés de températures intérieures, il est difficile de tirer des enseignements précis. On peut en revanche retenir de cette étude la relative acceptabilité sociale d'effacements courts pour soulager le réseau électrique.

Chapitre 1 : La régulation énergétique des bâtiments

Dès lors qu'il y a une économie réalisée par l'effacement, un marché de capacité peut se mettre en place. Ainsi en France, la loi NOME (Nouvelle Organisation des Marchés de l'Électricité, loi n°2010-1488), adoptée en décembre 2010 prévoit, outre un accès régulé à l'électricité nucléaire historique et l'intégration des énergies renouvelables dans les réseaux, l'obligation pour les fournisseurs d'électricité à disposer de garanties de capacités d'effacement de consommation et de production d'électricité. Ces capacités d'effacement ou de production pourront alors être échangées sur un marché de capacité.

La loi BROTTE (loi n°2013-312) prévoit :

- d'une part l'organisation d'« une expérimentation permettant la valorisation des offres d'effacement de consommation d'électricité sur les marchés de l'énergie et sur le mécanisme d'ajustement, selon des modalités définies, notamment s'agissant du versement (financier) de l'opérateur d'effacement vers les fournisseurs des sites effacés » ;
- et d'autre part, « la possibilité pour un opérateur d'effacement, de procéder à des effacements de consommation, indépendamment de l'accord du fournisseur d'électricité des sites concernés et de les valoriser sur les marchés de l'énergie ou sur le mécanisme d'ajustement, ainsi qu'un régime de versement de l'opérateur d'effacement vers les fournisseurs d'électricité des sites effacés (prenant en compte les quantités d'électricité) ».

La mise en place de ce type de marché de capacité contribue au développement de nombreuses entreprises. On peut citer par exemple Voltalis, seule société à ce jour qualifiée par RTE comme acteur d'effacement résidentiel. Cette société a développé le BluePod, un boîtier qui s'installe sur le tableau électrique et permet de mesurer les consommations électriques en temps réel et de les moduler via Internet. Les appareils de chauffage ou climatisation électriques ainsi que les chauffe-eaux électriques sont concernés.

Des projets à différentes échelles ont été développés par ces opérateurs d'effacement. On peut citer par exemple la convention signée en 2010 en Bretagne (région structurellement fragile) entre le préfet, le président du Conseil régional, RTE et Voltalis et qui a pour but d'équiper du boîtier d'effacement BluePod 60 000 foyers et sites bretons volontaires. La société prend en charge les coûts d'installation du boîtier et se rémunère en vendant sa capacité d'effacement à RTE. Du point de vue industriel, il existe le projet *EnR-Pool* liant Energy Pool, Schneider Electric et le CEA par l'intermédiaire de l'INES. Ce projet a pour but d'évaluer comment les clients industriels peuvent contribuer à résoudre certaines problématiques liées à l'insertion des énergies renouvelables intermittentes sur le réseau en adaptant ponctuellement leur consommation (« Le projet *EnR-Pool* » 2013). On peut également citer le projet *Smart Electric* Lyon, démarré en 2012, qui est un démonstrateur à grande échelle regroupant des partenaires académiques et industriels. Piloté par EDF, il s'agit d'un démonstrateur où des équipementiers pourront tester leurs matériels avec des tarifs adaptés à la problématique de la pointe journalière. Les expérimentations se dérouleront dans les communes du grand Lyon et concerneront principalement des ménages propriétaires et vivant en maison individuelle.

Enfin, au niveau européen, les directives 2006/32/EC et 2009/72/EC fixent les directions de la politique énergétique européenne et supposent le déploiement de compteurs communiquant équipant

Chapitre 1 : La régulation énergétique des bâtiments

a minima 80 % des clients d'ici 2020. On peut ainsi citer en France le projet Linky, développé par ERDF. Il s'agit d'un compteur communicant qui donnera accès à la consommation électrique en temps réel et aidera à une meilleure gestion de la demande électrique et des différentes pannes. Ce compteur permettra également aux consommateurs de disposer d'offres tarifaires et de solutions de pilotage des appareils électriques dans une optique d'effacement des consommations lors des périodes de pointe électrique. Cependant, ce projet suscite de nombreuses critiques liées à la confidentialité des données, au coût d'installation et aux impacts sur la santé liés aux champs électromagnétiques.

5. CONCLUSION DU CHAPITRE

Ce premier chapitre a permis de présenter les enjeux de la régulation énergétique du bâtiment, à savoir maîtriser la consommation, améliorer le confort des occupants, ou encore réduire les consommations de pointe (chauffage en hiver, climatisation en été). La réponse à ces enjeux de manière anticipative impose d'utiliser un modèle thermique du bâtiment.

Ce problème d'optimisation ainsi posé peut être résolu par des méthodes dites « en ligne » (commande prédictive) ou « hors-ligne » selon que le calcul de la stratégie énergétique optimale est réalisé en temps réel ou non.

Cet état de l'art s'est ensuite intéressé plus particulièrement à la problématique d'effacement des consommations électriques. Plusieurs équipes de recherche travaillent sur ce sujet, mais également les autorités et les entreprises qui cherchent à développer un modèle économique gagnant-gagnant pour assurer la stabilité du réseau dans des conditions acceptables pour le client final. Concernant plus spécifiquement l'effacement du chauffage électrique, quelques études ont esquissé son intérêt dans certains cas (particulièrement pour des logements bien isolés). La possibilité de sa mise en œuvre (et le gisement d'effacement associé) pour différents types de logements et pour différentes durées reste à déterminer, et notamment en termes de conséquences sur le confort des occupants.

Le prochain chapitre portera sur le développement des modèles nécessaires à la mise en place d'un système de régulation anticipatif, à savoir un modèle météorologique, un modèle d'occupation du bâtiment, et un modèle thermique dynamique du bâtiment.

Chapitre 2

Modèles nécessaires à la régulation

Pour anticiper l'état futur du bâtiment et s'adapter aux usages et conditions environnementales changeantes, les stratégies de régulation doivent reposer sur l'utilisation de différents modèles. L'objectif de ce chapitre est de les présenter. Tout d'abord, nous décrivons le modèle thermique dynamique du bâtiment utilisé. Ensuite, un rapide état de l'art sera réalisé sur la modélisation de l'occupation et en particulier sur la modélisation du confort de l'occupant. Enfin, nous nous concentrerons sur le développement d'un modèle de prévision météorologique locale.

PLAN DU CHAPITRE 2

1.	<u>INTRODUCTION.....</u>	<u>51</u>
2.	<u>MODÈLE THERMIQUE DYNAMIQUE DU BÂTIMENT (COMFIE)</u>	<u>51</u>
3.	<u>MODÉLISATION DE L'OCCUPATION</u>	<u>55</u>
3.1	INTRODUCTION	55
3.2	ÉTAT DE L'ART SUR LE CONFORT	55
3.2.1	LE CONFORT THERMIQUE.....	56
3.2.2	MODÉLISATION	60
4.	<u>MODELISATION DU CLIMAT</u>	<u>61</u>
4.1	INTRODUCTION	61
4.2	ÉTAT DE L'ART DE LA MODÉLISATION DES CONDITIONS CLIMATIQUES	62
4.2.1	VARIABLES CLIMATIQUES À MODÉLISER	62
4.2.2	LES MODÈLES DE PRÉVISIONS MÉTÉOROLOGIQUES	62
4.3	CARACTÉRISATION DES MODÈLES ARMA.....	67
4.3.1	ÉLIMINATION DE LA TENDANCE ET DE LA SAISONNALITÉ	67
4.3.2	LES PROCESSUS ARMA	69
4.3.3	ESTIMATION ET CHOIX D'UN MODÈLE	72
4.4	MODÉLISATION DES CONDITIONS CLIMATIQUES.....	74
4.4.1	INDICATEURS DE LA QUALITÉ DE LA PRÉVISION.....	74
4.4.2	MÉTHODES DE MODÉLISATION DÉVELOPPÉES.....	76
4.4.3	DONNÉES UTILISÉES.....	77
4.4.4	MODÉLISATION DE LA TEMPÉRATURE	79
4.4.5	MODÉLISATION DU RAYONNEMENT SOLAIRE.....	88
4.5	CONCLUSION	92
5.	<u>CONCLUSION DU CHAPITRE.....</u>	<u>93</u>

1. INTRODUCTION

L'objectif de cette thèse est de développer des stratégies de régulation adaptée au temps réel. Ces stratégies doivent pouvoir s'adapter en continu aux usages et conditions environnementales changeantes tout en anticipant l'état futur du bâtiment. Ainsi, elles reposent sur l'utilisation de différents modèles :

- un modèle thermique du bâtiment,
- un modèle d'occupation du bâtiment,
- un modèle de prévision météorologique.

La validité du modèle thermique dynamique est un critère indispensable à la mise en place d'une régulation efficace. En effet, seule la fiabilité du modèle assurera la robustesse de la commande optimale calculée. Le temps de simulation du modèle est également un critère important, l'optimisation faisant de multiples appels au modèle du bâtiment. Enfin, concernant le système de chauffage sur lequel la régulation va s'appliquer, celui-ci est directement intégré dans le modèle thermique dynamique du bâtiment.

Pour fonctionner, le modèle thermique requiert des données d'occupation, telles que les heures de présence, l'utilisation des équipements ou encore les contraintes de température de confort à respecter. Dans cette étude, une modélisation simplifiée de l'occupation a été considérée étant données les nombreuses incertitudes dans ce domaine.

Enfin, le modèle thermique du bâtiment nécessite l'utilisation de données météorologiques telles que la température extérieure et le rayonnement. Dans le cadre de la régulation, le développement des stratégies se fait tout d'abord dans un cas idéal où la météorologie est parfaitement connue à l'avance. Des données mesurées ou des données de type TRY (*Test Reference Year*) (Lund 1985) représentant la climatologie typique d'une région sont alors utilisées. Ensuite, la robustesse des stratégies de régulation développées est évaluée dans des cas plus réalistes où les prévisions météorologiques ne sont pas connues parfaitement à l'avance. Il est alors nécessaire de développer un modèle basé sur les prévisions météorologiques régionales pour anticiper l'évolution du climat local.

2. MODÈLE THERMIQUE DYNAMIQUE DU BÂTIMENT (COMFIE)

Le modèle thermique dynamique du bâtiment utilisé dans cette thèse repose sur le concept de « zone thermique », sous-ensemble du bâtiment considéré à température homogène (Peuportier et Blanc-Sommereux 1990). Pour chaque zone, les murs sont décomposés en mailles (méthodes des volumes finis) sur lesquelles un bilan thermique est appliqué en supposant que la température de la

Chapitre 2 : Modèles nécessaires à la régulation

maille est uniforme. Pour assurer cette hypothèse, le maillage est d'autant plus fin que la maille est proche de l'ambiance intérieure. L'air, le mobilier et les cloisons légères éventuelles contenus dans la zone sont regroupés dans une maille unique. Le bilan thermique sur chaque maille prend alors la forme suivante (Neveu 1984) :

$$C_m \frac{dT_m}{dt} = \dot{Q}_G - \dot{Q}_P \quad (2.1)$$

avec

- C_m la capacité thermique de la maille ;
- T_m la température de la maille ;
- \dot{Q}_G les gains comprenant les apports solaires et internes, ainsi que les puissances de chauffage ou de refroidissement des équipements ;
- \dot{Q}_P les pertes dues à la ventilation et aux transferts thermiques par conduction, convection, rayonnement.

Certains phénomènes non stationnaires (ouverture d'un volet) ou non linéaires (mouvement d'air) sont pris en compte dans un vecteur des sollicitations noté U , ce qui permet d'écrire les équations (2.1) sous la forme d'un système d'équations linéaires (2.2).

En répétant ce bilan pour chaque maille de la zone considérée et en ajoutant une équation de sortie, l'ensemble des équations peut ainsi être représenté sous la forme d'un système linéaire continu et invariant (Bacot 1984 ; Lefebvre 1987) :

$$\begin{cases} C\dot{T}(t) = AT(t) + EU(t) \\ Y(t) = JT(t) + GU(t) \end{cases} \quad (2.2)$$

avec

- T le champ discrétisé des températures ;
- C la matrice diagonale des capacités thermiques ;
- U le vecteur des sollicitations (comprenant les paramètres climatiques, le chauffage, etc.) ;
- A la matrice d'état ou matrice des termes d'échange entre mailles ;
- E la matrice de commande ou matrice des termes d'échange entre mailles et sollicitations ;
- J la matrice d'observation ou matrice reliant les sorties aux températures des mailles ;
- G la matrice d'action directe ou matrice reliant les sorties aux sollicitations ;
- Y le vecteur des sorties (ici la température intérieure de la zone prenant en compte l'air et la température des murs).

Le système étant linéaire, il est possible de décomposer le vecteur des températures $T(t)$ en un terme purement dynamique et un terme de régime permanent glissant (Palomo Del Barrio et al. 2000) :

Chapitre 2 : Modèles nécessaires à la régulation

$$T(t) = T_d(t) + T_p(t) \quad (2.3)$$

où $T_p(t)$ représente le comportement du système lorsque sa capacité thermique est supposée être égale à 0 (régime permanent). On obtient alors $T_p(t) = -A^{-1}EU(t)$.

En utilisant l'équation (2.3) dans l'équation (2.2), on obtient alors :

$$\begin{cases} \dot{T}_d(t) = C^{-1}AT_d(t) + A^{-1}E\dot{U}(t) \\ Y(t) = JT_d(t) + (G - JA^{-1}E)U(t) \end{cases} \quad (2.4)$$

Pour résoudre simplement ce système on diagonalise la matrice $C^{-1}A$. On réalise alors un changement de base en utilisant la matrice de passage P formée des vecteurs propres de $C^{-1}A$. Le vecteur des températures $T_d(t)$ est ainsi transformé en un vecteur d'état $X(t)$ par la relation suivante :

$$T_d(t) = PX(t) \quad (2.5)$$

Le système (2.4) devient alors :

$$\begin{cases} \dot{X}(t) = FX(t) + B\dot{U}(t) \\ Y(t) = HX(t) + SU(t) \end{cases} \quad (2.6)$$

avec

- $F = P^{-1}C^{-1}AP$
- $B = P^{-1}A^{-1}E$
- $H = JP$
- $S = G - JA^{-1}E$

F est une matrice diagonale dont le $i^{\text{ème}}$ terme diagonal est $-1/\tau_i$, τ_i étant la $i^{\text{ème}}$ constante de temps de la zone. Ces constantes de temps sont ordonnées dans F de la plus grande à la plus petite. L'avantage de ce changement de base est de pouvoir réduire l'ordre du système. En effet, certaines constantes de temps sont petites et les termes correspondants du vecteur $X(t)$ atteignent très rapidement leur régime permanent. Il est alors possible de les négliger dans le calcul de la partie dynamique (on considère qu'ils sont en régime permanent). On peut ainsi obtenir un modèle d'ordre réduit en ne conservant que les N plus grandes constantes de temps différentes (Marshall 1966). Suite à des analyses de sensibilité, la valeur maximale de N a été fixée à 10 dans le logiciel.

On obtient alors pour chaque zone thermique du bâtiment le modèle réduit suivant :

$$\begin{cases} \dot{X}_r(t) = F_r X_r(t) + B_r \dot{U}(t) \\ Y(t) = H_r X_r(t) + S U(t) \end{cases} \quad (2.7)$$

Il est alors possible de coupler les différents modèles de zones entre eux (Blanc Sommereux et Lefebvre 1989 ; Blanc Sommereux 1991) et d'aboutir au système couplé suivant (où $Y_g(t)$ est le vecteur des variables de couplage et où l'on sépare dans les matrices B_r et S les colonnes concernant U_g regroupées dans les matrices B_g^α et S_g^α , et celles concernant Y_g , regroupées dans B_g^β et S_g^β) :

$$\begin{cases} \dot{X}_g(t) = F_g X_g(t) + B_g^\alpha \dot{U}_g(t) + B_g^\beta \dot{Y}_g(t) \\ Y_g(t) = H_g X_g(t) + S_g^\alpha U_g(t) + S_g^\beta Y_g(t) \end{cases} \quad (2.8)$$

Chapitre 2 : Modèles nécessaires à la régulation

On peut alors intégrer le système ainsi obtenu sur un pas de temps Δt en notant X_g^{n+1} et X_g^n les vecteurs d'état aux temps $(n+1)\Delta t$ et $n\Delta t$ (on procède de même pour les vecteurs Y_g et U_g). Le système (2.8) devient alors après intégration :

$$\begin{cases} X_g^{n+1} = \exp(F_g \Delta t) X_g^n + W_g^\alpha (U_g^{n+1} - U_g^n) + W_g^\beta (Y_g^{n+1} - Y_g^n) \\ Y_g^{n+1} = MGIF \cdot X_g^n + MGIE \cdot U_g^{n+1} - MGID \cdot U_g^n - MGIC \cdot Y_g^n \end{cases} \quad (2.9)$$

avec (en notant I la matrice identité) :

- $MGIF = (I - H_g W_g^\beta - S_g^\beta)^{-1} H_g F_g$
- $MGIE = (I - H_g W_g^\beta - S_g^\beta)^{-1} (H_g W_g^\beta + S_g^\alpha)$
- $MGID = (I - H_g W_g^\beta - S_g^\beta)^{-1} H_g W_g^\alpha$
- $MGIC = (I - H_g W_g^\beta - S_g^\beta)^{-1} H_g W_g^\beta$
- $W_i^j = e^{-\Delta t / \tau_i} B_i^j$

Les phénomènes non linéaires ou impliquant des paramètres variables (ventilation externe, ventilation interne, résistance variable due à l'usage intermittent des occultations, etc.) sont pris en compte après le couplage des modèles zonaux réduits modaux. Par exemple pour la ventilation externe, une valeur moyenne est considérée pour les débits de ventilation externe dans les systèmes linéaires. C'est après le couplage que les écarts par rapport à la moyenne sont pris en compte et que le vecteur des sollicitations U_g est corrigé.

La simulation de ce modèle nécessite de connaître les sollicitations, en particulier les émissions de chaleur par les occupants et les équipements, mais également les données météorologiques locales concernant la température extérieure et le rayonnement solaire. Toutes ces données sont contenues dans le vecteur des sollicitations.

Dans le cadre de cette thèse, nous nous intéressons uniquement à un système de chauffage électrique pour la régulation, directement intégré dans le modèle thermique dynamique du bâtiment. On suppose que le système de chauffage dispose d'un rendement de 100 % et qu'il fournit l'ensemble de la puissance à la maille d'air. Ce type de système permet ainsi d'être très réactif (sa dynamique sera négligée) et de ne pas avoir de décalage entre le moment où la commande est envoyée au système et celui où la puissance de chauffage est injectée dans la maille d'air.

3. MODÉLISATION DE L'OCCUPATION

3.1 Introduction

La modélisation de l'occupation est une notion complexe mais néanmoins essentielle pour la mise en place d'une régulation. En effet, l'impact de l'occupation sur la consommation énergétique finale du bâtiment est non négligeable. Il devient alors indispensable de la modéliser. Selon les manières d'aborder le sujet, deux approches peuvent être distinguées (Vorger 2014).

La première approche considère le comportement des occupants comme des processus stochastiques (J. Fergus Nicol et Humphreys 2004). L'objectif de la modélisation est alors de reproduire, à partir de données d'observations et à travers des modèles statistiques, le comportement des occupants (durée et fréquence des actions) en fonction des conditions environnementales. Plus précisément, il s'agit d'observer la réalité et de la reproduire sans expliciter les relations de cause à effet entre les conditions environnementales et le choix d'une action. Ces modèles permettent ainsi de prendre en compte un ensemble de phénomènes cachés (liés au comportement de l'occupant) qu'il est difficile de modéliser de manière explicite. Ils sont également capables de reproduire la variété des comportements existants. L'utilisation de ces modèles est ainsi pertinente dans le cadre du développement de la Garantie de Performance Énergétique (GPE) qui vise à garantir (par contrat) la performance énergétique d'un bâtiment réhabilité. Ces modèles peuvent ainsi être utilisés par les logiciels de simulation thermique dynamique pour prévoir les consommations énergétiques.

La deuxième approche considère quant à elle que les actions des occupants sont réalisées dans le but d'assurer certaines conditions de confort (Fanger 1986). En effet, les bâtiments sont chauffés ou refroidis dans le but d'assurer aux occupants des conditions de confort acceptables. La définition de ce confort est alors un pré-requis pour la modélisation de l'occupation. On modélise ainsi de manière explicite la logique menant au choix de l'action de l'occupant.

Dans le cadre de la régulation énergétique des bâtiments, les différents systèmes du bâtiment (chauffage, climatisation, ventilation, protections solaires) sont pilotés par le système de régulation et non par les occupants. Le comportement des occupants est pris en compte sous la forme de contraintes à respecter. Dans ce cas, la modélisation de l'occupation se focalise sur le confort, et plus précisément sur le respect des conditions acceptables par l'occupant (deuxième approche).

3.2 État de l'art sur le confort

Comme nous l'avons vu dans le chapitre 1, le confort peut être défini par plusieurs facteurs, tels que le confort thermique, le confort visuel, le confort acoustique et la qualité de l'air intérieur. Dans le cadre de la régulation énergétique des bâtiments en période hivernale, c'est la notion de confort thermique qui va nous intéresser tout particulièrement.

3.2.1 Le confort thermique

L'amélioration du confort de l'occupant, en particulier le confort thermique, est un des objectifs principaux de la régulation dans le bâtiment. La définition de cette notion est alors indispensable pour la prendre en compte dans l'optimisation, soit sous forme de contrainte à respecter, soit en tant qu'objectif même.

Le phénomène de confort thermique est lié à l'interaction du corps humain avec son environnement à travers des échanges de chaleur (sensibles et latents) et à la régulation de sa température par « des processus de régulation thermo-physiologique involontaires qui modulent la production et le transfert de masse et de chaleur, internes et externes » (Thellier et al. 2009). Ainsi, en réaction à des sensations d'inconfort, le corps humain va réagir en s'adaptant à son environnement à travers un ensemble de réactions physiologiques dans le but de retrouver un état de confort. Dans cet état de l'art du confort thermique, nous allons dans un premier temps nous intéresser au bilan thermique du corps humain pour ensuite présenter deux méthodes d'évaluation du confort thermique, à savoir l'approche statique et l'approche adaptative.

3.2.1.1 Bilan thermique chez l'homme

Le corps humain est homéotherme, c'est-à-dire qu'il tend à maintenir une température corporelle constante autour de 37°C. Cette stabilité de la température impose un équilibre entre la production de chaleur à l'intérieur du corps (résultat du métabolisme de base ainsi que du travail physique) et les pertes de chaleur par échange vers le milieu extérieur. Le métabolisme correspond à l'ensemble des transformations de la nourriture consommée en constituants du corps (protéines, etc.) d'une part et en énergie d'autre part. L'énergie ainsi produite est alors transformée en travail et en chaleur. Ces échanges de chaleur entre l'individu et le milieu extérieur se font selon divers mécanismes et dépendent des activités et de l'habillement (Figure 5).




Figure 5 : Echanges entre le corps humain et le milieu extérieur (Thellier et al. 2012)

Ce bilan thermique (en régime transitoire) par unité de surface corporelle peut alors s'écrire sous la forme (Fanger 1970) :

$$M - W = C_{res} + E_{res} + K + C + R + E \quad (2.10)$$

Chapitre 2 : Modèles nécessaires à la régulation

avec

- $M - W$, production de chaleur interne du corps (en W/m^2), avec M le métabolisme et W le travail physique,
- C_{res} , échange de chaleur au niveau des voies respiratoires par convection (en W/m^2),
- E_{res} , échange de chaleur au niveau des voies respiratoires par évaporation (en W/m^2),
- K , échange de chaleur au niveau de la peau par conduction (en W/m^2),
- C , échange de chaleur au niveau de la peau par convection (en W/m^2),
- R , échange de chaleur au niveau de la peau par rayonnement (en W/m^2),
- E , échange de chaleur au niveau de la peau par évaporation (en W/m^2).

Lorsque le corps humain est à l'équilibre avec son environnement, on dit qu'il est à neutralité thermique. Cette situation idéale correspond à des réactions thermo-physiologiques minimales avec un bilan thermique équilibré. Cependant, si les réactions thermo-physiologiques ne parviennent pas à maintenir l'équilibre thermique du corps, le corps est alors dans une situation d'hyper ou d'hypothermie (température corporelle supérieure à $38^{\circ}C$ ou inférieure à $35^{\circ}C$ respectivement). Ainsi, si un individu a chaud, des mécanismes de vaso-dilatation et de transpiration seront utilisés alors que dans le cas contraire des mécanismes de frissons et de vaso-constriction seront enclenchés.

La notion de confort thermique correspond à une appréciation subjective. Par exemple, la norme ASHRAE (ASHRAE 2003) définit le confort thermique comme « la condition d'esprit qui exprime la satisfaction en présence d'un environnement thermique donné ». Ainsi, la sensation de confort ne sera pas la même pour différentes personnes au sein d'une même pièce, rendant la définition du confort thermique, au delà des aspects purement physiques, très difficile.

Il est important de noter que la température de zone calculée par COMFIE est proche d'une température opérative, correspondant à une synthèse des échanges convectifs (température de l'air) et des échanges radiatifs (température des parois). Cette température opérative correspond, de manière simplifiée, à la température de confort ressentie par les occupants.

3.2.1.2 L'approche statique

Une des approches le plus couramment utilisée pour décrire le confort thermique est l'approche développée par Fanger (1967) avec les indices PMV (*Predicted Mean Vote*) et PPD (*Predicted Percentage Dissatisfied*).

Dans cette approche, Fanger considère que la situation de confort thermique dépend de trois conditions :

- un bilan thermique équilibré ;
- une température moyenne de la peau située dans les limites du confort ;
- une sudation située dans les limites du confort.

Chapitre 2 : Modèles nécessaires à la régulation

Dans ces conditions, l'équilibre thermique est caractérisé par 6 paramètres :

- le métabolisme (en W/m^2) ;
- le clo, correspondant à l'unité d'isolement vestimentaire ($1 \text{ clo} = 0,155^\circ\text{C}\cdot\text{m}^2/\text{W}$) ;
- la température de l'air (en $^\circ\text{C}$) ;
- la température des parois (en $^\circ\text{C}$) ;
- l'humidité relative de l'air (en %) ;
- la vitesse relative de l'air (en m/s).

A partir de ces paramètres et en écrivant le bilan thermique, il est possible de calculer l'indice PMV qui décrit la sensation thermique en fonction de l'écart entre le flux de chaleur cédé par le corps à l'environnement et celui qui correspond aux conditions de confort. L'indice PMV permet de prédire l'avis moyen d'un groupe important de personnes qui exprimeraient un vote de sensation de confort thermique. Ces votes reposent sur une échelle (Tableau 1) allant de -3 à +3 où un indice PMV de 0 exprime une sensation de confort thermique idéale. Un indice PMV négatif signifie que la température est plus basse que la température idéale et inversement, un indice positif indique une température trop élevée.

Tableau 1 : Echelle des indices PMV

+3	Chaud
+2	Tiède
+1	Légèrement tiède
0	Neutre
-1	Légèrement frais
-2	Frais
-3	Froid

La sensation thermique n'étant pas suffisante pour exprimer le confort, Fanger a alors proposé un autre indice pour compléter le PMV : il s'agit du PPD (pourcentage prévu des insatisfaits). Cet indice permet de prévoir le pourcentage de personnes insatisfaites à une sensation de confort thermique donnée en fonction du PMV (Figure 6).




Figure 6 : Relation entre le PMV et le PPD (ASHRAE 2004)

On peut remarquer que le PPD n'atteint jamais 0 %, illustrant le fait qu'aucune condition n'est jugée optimale pour l'ensemble de la population.

Cependant, la mise en place de l'approche statique implique l'utilisation de nombreux capteurs pour mesurer les différents paramètres, entraînant une augmentation du coût ainsi que de la logistique nécessaire à la régulation. De plus, cette approche ne prend pas en compte les possibilités d'actions sur l'environnement dont dispose l'occupant. L'approche adaptative, reposant sur une hypothèse d'adaptation des occupants à leur environnement, permet de prendre en compte ce phénomène.

3.2.1.3 L'approche adaptative

L'approche adaptative se différencie de l'approche statique en intégrant dans sa réflexion la capacité d'adaptation climatique et la capacité d'interaction de l'occupant avec son environnement. Cette adaptation des occupants peut se décliner en trois domaines :

- **Comportemental** : correspond aux réactions de l'occupant à des situations ressenties, qui va d'une part s'adapter à son environnement (cela inclut par exemple la modification de l'habillement, le changement de posture, le déplacement ou encore l'absorption de boissons chaudes ou froides) et d'autre part modifier son environnement (on peut citer par exemple la modification de la consigne de chauffage ou de climatisation, l'ouverture ou la fermeture des fenêtres, ou encore l'action sur des occultations).
- **Physiologique** : sur une échelle de quelques jours ou semaines, les individus vont ajuster de manière inconsciente les réactions et les processus de régulation du corps.

Chapitre 2 : Modèles nécessaires à la régulation

- **Psychologique** : selon le degré de liberté dont dispose les occupants, les zones de confort thermique et les exigences de confort des occupants sont plus ou moins grandes. Ainsi, si les occupants disposent, ou pensent disposer, d'une capacité d'action sur la gestion du bâtiment, leur zone de confort thermique sera plus grande que s'ils n'avaient aucune possibilité d'action. L'anticipation des conditions climatiques (permettant d'adapter les vêtements) les rend également plus tolérants.

Ainsi, plusieurs études sur le terrain se sont intéressées à la relation existante entre la température de confort T_{conf} et la température extérieure. Cette relation, obtenue par régression linéaire, est de la forme suivante (de Dear et Brager 2002 ; J.F. Nicol et Humphreys 2002) :

$$T_{conf} = a T_{ext} + b \quad (2.11)$$

avec T_{ext} la moyenne mensuelle ou la moyenne glissante de la température extérieure.

Ces modèles adaptatifs ont été intégrés dans des standards tels que le standard ASHRAE 2004 ou encore le standard CEN avec la norme EN15251 (Nicol et Wilson 2010).

Les différentes approches du confort thermique (statique ou adaptative) présentent cependant quelques limites. En effet, aucun modèle ne s'impose par sa robustesse ou sa qualité de prévision (Vorger 2014). Par exemple, il existe des différences entre les standards ASHRAE et CEN. De plus, les modèles rationnels et adaptatifs reposent principalement sur des données de bâtiments de bureaux et non des logements, limitant leur validité. Enfin, la difficulté de mise en place de ces modèles (en particulier pour le modèle statique) peut être un frein à leur utilisation.

3.2.2 Modélisation

La prise en compte de la variabilité des comportements des occupants (avec par exemple la probabilité d'ouverture d'une fenêtre ou de l'activation de l'éclairage) peut être réalisée à partir de modèles statistiques (première approche). Cependant, cette approche impliquerait l'utilisation de méthodes de commande prédictive stochastique, méthodes qui sont hors du cadre de cette thèse.

Étant donné que le système de régulation a pour objectif de déterminer une séquence de commandes optimales de la puissance, le système de chauffage n'est plus contrôlé directement par l'occupant. La prise en compte de l'occupation est alors faite de manière indirecte à travers le respect des contraintes de confort, et en particulier la modélisation du confort thermique (deuxième approche). Cependant, un rapide état de l'art a permis de révéler les limites des différentes modélisations du confort thermique (statique ou adaptative). Les incertitudes associées nous ont conduits à adopter une approche déterministe (et plus précisément invariante) qui consiste à modéliser l'occupation à partir de scénarios définis par l'utilisateur. Il s'agit de l'approche la plus répandue dans les logiciels de simulation thermique dynamique.

Chapitre 2 : Modèles nécessaires à la régulation

Les scénarios permettent ainsi de renseigner les données suivantes :

- la présence (avec le nombre d'occupants et leur chaleur métabolique en W) ;
- les consignes de chauffage et de climatisation (en °C) ;
- les apports internes (liés à la puissance dissipée par les appareils électriques en W) ;
- les taux d'occultation des vitrages.

Ces scénarios peuvent être affinés à partir de données collectées sur le site, dans l'objectif d'être les plus réalistes possibles. Nous ne considérerons que le confort thermique. Notre cas d'application étant l'effacement de la consommation électrique de pointe en hiver, nous modéliserons le confort thermique par une zone de confort définie par une température minimale de 19°C et une température maximale de 24°C permettant une surchauffe du bâtiment. Les autres aspects du confort, tels que la qualité de l'air intérieur, ou la luminosité ne sont pas pris en compte dans le cadre de cette thèse car ils complexifieraient trop la contrainte de confort. Pour le lecteur intéressé, Vorger (2014) a réalisé un état de l'art approfondi sur la modélisation de l'occupant.

4. MODÉLISATION DU CLIMAT

4.1 Introduction

Dans le cadre du développement de stratégies de régulation, le climat est pris en compte, dans un premier temps, de manière simplifiée à partir de données horaires. On se place alors dans le cas idéal où la météorologie est parfaitement connue à l'avance. Ces données météorologiques peuvent ainsi être issues de données mesurées ou de données types (données TRY par exemple).

Dans un deuxième temps, la robustesse des stratégies de régulation est évaluée dans des cas plus réalistes où les prévisions météorologiques ne sont pas parfaites. Il est alors indispensable de développer des modèles permettant de prévoir l'évolution de la météorologie locale et d'avoir un ordre de grandeur sur les erreurs de prévisions.

L'objectif de la prévision météorologique est de concevoir un dispositif permettant de fournir en temps réel des données météorologiques prévisionnelles pour les heures ou les jours à venir pour un bâtiment donné. En effet, les données fournies par les instituts nationaux de prévisions météorologiques sont pour la plupart régionales, difficiles d'accès et payantes. Dans ce contexte, le développement d'un modèle de prévision météorologique locale est indispensable pour la gestion optimisée du bâtiment.

Dans cette partie, un état de l'art sur la modélisation des conditions climatiques est présenté (§4.2), suivi par une étude approfondie sur les modèles ARMA (§4.3). Enfin, les méthodes choisies pour modéliser les conditions climatiques locales ainsi que leurs résultats sont exposées dans le §4.4.

4.2 État de l'art de la modélisation des conditions climatiques

4.2.1 Variables climatiques à modéliser

Le pré-requis pour développer notre modèle est d'étudier les variables météorologiques nécessaires à la prévision des performances énergétiques d'un bâtiment et d'identifier les plus importantes et pertinentes. On peut citer par exemple le rayonnement solaire, la température extérieure, l'humidité, la vitesse du vent ainsi que la pression atmosphérique. En suivant l'approche de Crawley (1998), parmi les données météorologiques disponibles, seuls le **rayonnement solaire** et la **température de l'air** seront modélisés. En effet, la France, avec un climat tempéré, n'est pas sujette à de forts taux d'humidité et les zones soumises à des vents violents y sont limitées.

Le rayonnement solaire, ou plus précisément le rayonnement solaire global incident sur une surface donnée correspond à la somme des trois composantes : directe, réfléchie et diffuse. Il participe au chauffage, à la surchauffe, ainsi qu'à l'éclairage du bâtiment. En France métropolitaine, le rayonnement solaire global horizontal moyen varie dans une plage 1100-1900 kWh/m² sur un an.

La température de l'air extérieur a, quant à elle, une importance non négligeable sur les besoins de chauffage. En effet, elle influe directement sur les déperditions thermiques du bâtiment.

4.2.2 Les modèles de prévisions météorologiques

Il existe deux catégories de modèles de prévisions météorologiques. La première concerne les modèles physiques, utilisés par les services de météorologie ou certains centres de recherche. Ils mettent en jeu les différentes grandeurs caractérisant le climat et leurs interactions, et permettent d'effectuer des prévisions météorologiques fines. La deuxième catégorie regroupe les modèles purement mathématiques reposant uniquement sur l'étude statistique des données passées dans le but de caractériser le comportement du système.

4.2.2.1 Les modèles physiques

Les modèles physiques, ou plus précisément les modèles de prévision numérique de la météorologie, servent à produire une représentation la plus exacte possible de l'état présent et futur de l'atmosphère. Leur principale utilisation est la prévision météorologique pour les prochains jours. Ils sont donc utilisés principalement par les services de météorologie nationale. Ces modèles sont basés sur une division de l'atmosphère en de nombreuses mailles et utilisent les équations primitives atmosphériques, qui sont une version simplifiée des équations de Navier-Stokes, qui permettent de simuler le comportement futur de l'atmosphère à partir de nombreux points de mesure (stations terrestres, navires, aéronefs, radiosondes, données satellitaires de mesures à distance, etc.).

Chapitre 2 : Modèles nécessaires à la régulation

De nombreux modèles physiques ont été développés. On peut tout d'abord citer les modèles de Météo-France (Météo-France 2015) avec le modèle ARPEGE (système de prévision numérique couvrant le globe), le modèle ALADIN (système couvrant des régions de quelques milliers de km de taille) et le modèle AROME (système utilisé opérationnellement sur la France métropolitaine). Les tailles de mailles pour ces modèles sont respectivement de l'ordre de 15 km, 10 km et 2,5 km. Diagne et al. (2013) présentent un état de l'art complet des modèles physiques existants avec l'estimation de leurs erreurs.

L'avantage de ces modèles physiques est la précision des prévisions météorologiques réalisées sur plusieurs jours par rapport aux modèles mathématiques. Cependant, ces modèles très détaillés nécessitent l'utilisation de supercalculateurs qui ne sont accessibles qu'à des professionnels de la météorologie. De plus, les prévisions sont généralement faites à l'échelle régionale et non locale, ce qui induit une perte de précision et la non-prise en compte des spécificités locales telles que les microclimats, les masques, les montagnes, etc. Enfin, l'accès aux données est généralement payant et nécessite une connexion fiable.

A l'échelle de la ville, des modèles physiques existent également permettant de reproduire les échanges énergétiques et hydriques entre le milieu urbain et l'atmosphère (Musy et Bozonnet 2013). De nombreux modèles ont ainsi été développés pour modéliser les microclimats à différents niveaux d'échelle (ville, quartier, bâtiment) et évaluer l'interaction entre microclimat urbain et demande énergétique des bâtiments. Cependant, la modélisation des microclimats est complexe du fait de l'interdépendance des différents flux existants : ensoleillement, vents dominants, convection naturelle, polluants et production anthropique (Bozonnet et al. 2011). De plus, des problèmes se posent quant aux temps de calcul, à la fiabilité des modèles et à la disponibilité des données d'entrée.

4.2.2.2 Les modèles mathématiques

Les modèles purement mathématiques reposent sur l'analyse des relevés des données météorologiques et donc sur l'utilisation de séries temporelles (ou chronologiques). Ces modèles sont moins fiables et moins précis mais ont l'avantage d'être plus simples et ne nécessitent pas des moyens informatiques lourds. On peut donc imaginer leur utilisation sur des prévisions locales.

Il se dégage de cette catégorie quatre grandes familles de modèles (Voyant 2011) : les modèles de type « naïf », les modèles à probabilités conditionnelles, les réseaux de neurones et les modèles ARMA. Avant une présentation succincte de ces modèles, une définition des séries temporelles est nécessaire.

4.2.2.2.1 Définition et caractérisation des séries temporelles

Une série temporelle (ou série chronologique) à temps discret est une suite finie d'observations d'une famille de variables aléatoires réelles $(X_t)_{1 \leq t \leq n}$, où t représente le temps (en minute, jour, année...). Dans le cas des séries temporelles météorologiques, ces dernières sont constituées de valeurs instantanées séparées par un intervalle de temps fixe. Un des objectifs principaux de l'étude des séries temporelles est de décrire, expliquer et prévoir l'évolution au cours du temps d'un phénomène.

Chapitre 2 : Modèles nécessaires à la régulation

Une série temporelle est la résultante de différentes composantes fondamentales :

- La tendance (Z_t), qui représente l'évolution à long terme de la série étudiée. La tendance peut être linéaire, polynomiale, logarithmique, exponentielle, etc.
- La composante saisonnière ou périodique (S_t), qui correspond à un phénomène qui se répète à intervalles de temps réguliers.
- La composante résiduelle (ϵ_t), qui correspond à des fluctuations irrégulières, en général de faible intensité mais de nature aléatoire.

Il existe différents modèles de représentation générale d'une série temporelle. Plus précisément, les tendances et les facteurs saisonniers rencontrés le plus fréquemment peuvent être présentés par trois types de modèles :

- Le modèle additif :

$$X_t = Z_t + S_t + \epsilon_t \quad (2.12)$$

- Le modèle multiplicatif :

$$X_t = Z_t(1 + S_t)(1 + \epsilon_t) \quad (2.13)$$

- Les modèles hybrides, correspondant à différentes combinaisons de modèles additifs et de modèles multiplicatifs :

$$X_t = (Z_t + S_t)(1 + \epsilon_t) \quad (2.14)$$

4.2.2.2 Les modèles de type « naïf »

On peut citer dans les modèles de type « naïf », le lissage exponentiel ou encore les k plus proches voisins.

➤ Le lissage exponentiel

Les méthodes de lissage constituent l'ensemble des techniques empiriques de prévision qui accordent plus ou moins d'importance aux valeurs du passé d'une série temporelle. Ces méthodes reposent sur le principe d'une mise à jour facile de la prédiction de la série lorsqu'une nouvelle observation est disponible.

Soit une série temporelle (X_t) dont on dispose des N premières observations X_1, \dots, X_N , l'objectif est de faire une prévision de la série à l'horizon h , c'est-à-dire de prévoir la valeur \hat{X}_{N+h} ou $\hat{X}_N(h)$.

Le lissage exponentiel simple

Le lissage exponentiel simple permet d'effectuer des prévisions pour des séries temporelles sans saisonnalité et dont la tendance est constante. Il s'agit d'une technique permettant de faire des prévisions à $\hat{X}_N(1)$.

Chapitre 2 : Modèles nécessaires à la régulation

Étant donnée la constante de lissage β tel que $0 < \beta < 1$, la prévision de la série est :

$$\hat{X}_N(1) = (1 - \beta) \sum_{j=0}^{N-1} \beta^j X_{N-j} \quad (2.15)$$

Si β est proche de 0, la prévision est fortement influencée par les observations récentes. Au contraire, si β est proche de 1, l'influence des observations éloignées est d'autant plus importante et remonte loin dans le passé.

Le lissage exponentiel double

Le lissage exponentiel double permet de généraliser le lissage exponentiel simple au cas où la série peut être ajustée à une droite au voisinage de l'instant N . La prévision de la série à l'horizon h , $\hat{X}_N(h)$, est donnée par :

$$\hat{X}_N(h) = \hat{a}_N h + \hat{b}_N \quad (2.16)$$

où le couple (\hat{a}_N, \hat{b}_N) minimise la fonction :

$$\sum_{j=0}^{N-1} \beta^j (X_{N-j} - (aj + b))^2 \quad (2.17)$$

Les méthodes de Holt-Winters

Il s'agit des méthodes à privilégier parmi les techniques de lissage exponentiel dans le cas de séries d'observations présentant à la fois une tendance et une saisonnalité. On peut citer la méthode non saisonnière, qui s'applique à des séries sans saisonnalité, la méthode additive adaptée aux séries admettant une décomposition additive, et la méthode multiplicative adaptée aux séries admettant une décomposition multiplicative.

La différence entre les méthodes de Holt-Winters et le lissage exponentiel double porte principalement sur les formules de mise à jour.

➤ K plus proches voisins

La méthode des K plus proches voisins peut également être utilisée pour la prédiction de séries temporelles. Cette méthodologie a pour but de trouver dans les données d'apprentissage, c'est-à-dire l'historique, un groupe de données (formé de K données) se rapprochant le plus du groupe de données (formé également de K données) dont on veut prédire les valeurs futures (Sharif et Burn 2006). De nombreux algorithmes existent pour réaliser cet apprentissage supervisé.

4.2.2.2.3 Les chaînes à probabilités conditionnelles : chaîne de Markov

Certains auteurs ont eu recours aux chaînes de Markov pour la prévision de séries temporelles (Bauer 1998 ; Muselli et al. 2001). Une chaîne de Markov est un processus stochastique qui possède la propriété Markovienne qui signifie que, étant donné l'état présent, les états futurs sont indépendants des états passés. Les états futurs sont donc modélisables grâce à un processus probabiliste dépendant

Chapitre 2 : Modèles nécessaires à la régulation

uniquement des états présents et d'une matrice de transition (ou matrice de Markov). Pour initialiser le processus, il est nécessaire d'identifier la matrice de transition du phénomène en utilisant l'historique.

Soit $p_{i,j}$ la probabilité de transition de l'état i à l'état j :

$$p_{i,j} = P(X_t = j | X_{t-1} = i) \quad (2.18)$$

La matrice de transition R_M est constituée de la famille de ces probabilités. La prédiction à l'horizon h est donc donnée par :

$$\hat{X}_N(h) = X_N * (R_M)^h \quad (2.19)$$

4.2.2.2.4 Les réseaux de neurones

Une alternative aux approches conventionnelles est l'utilisation des réseaux de neurones artificiels. Il s'agit de modèles à intelligence artificielle dont le fonctionnement est analogue à celui du cerveau humain. Ils permettent de résoudre des problèmes très complexes tels que la classification ou la prédiction de séries temporelles. Les réseaux de neurones sont une solution appropriée lorsque l'on dispose de nombreuses données et que les règles régissant les phénomènes que l'on souhaite modéliser sont inconnues. De nombreuses études basées sur différentes techniques d'intelligence artificielle ont été réalisées. On peut citer par exemple Sfetsos et Coonick (2000), Mellit et al (2006) ou encore Tasadduq et al (2002).

Les réseaux de neurones artificiels ont un fonctionnement assez simple. Ils mettent en œuvre le principe de l'induction, c'est-à-dire la capacité à apprendre par l'expérience. Ainsi, par confrontation avec des données connues lors de la phase d'apprentissage, un système de décision est généré (un modèle sous forme de boîte noire) dont l'efficacité et le caractère générique sont fonction du nombre de cas d'apprentissage et de leur complexité par rapport au problème à modéliser et à résoudre.

4.2.2.2.5 Les modèles ARMA

Les modèles ARMA sont des modèles couramment utilisés pour représenter les séries temporelles. Ils associent deux types de processus : un processus autorégressif (AR) et un processus en moyenne mobile (MA). Ces processus sont construits à partir de l'idée que l'observation au temps t s'explique linéairement par les observations précédentes et par les observations d'un bruit blanc. Par exemple, Matyasovszky (2001) illustre l'utilisation des modèles ARMA pour la prévision météorologique de séries temporelles alors que Guerrier et al (1980) appliquent ces modèles pour la prévision du rayonnement solaire.

4.2.2.2.6 Choix de la méthode de modélisation

Cette section a permis de présenter les principaux modèles mathématiques pour modéliser une série temporelle. D'après la littérature, les réseaux de neurones et les modèles ARMA sont les méthodes classiquement utilisées pour modéliser les conditions climatiques (Voyant 2011). Par exemple, Favre (2013) a utilisé les réseaux de neurones pour prévoir la température et le rayonnement solaire (en

considérant une période d'apprentissage de cinq ans de données climatiques). Les résultats obtenus ne furent pas d'une grande précision (par exemple pour la prévision de la température à un horizon de 24 h, l'erreur moyenne absolue était de 1,6°C). D'autre part, différentes études semblent indiquer que les modèles ARMA peuvent être plus efficaces (Reikard 2009 ; Diagne et al. 2013). Par conséquent, les modèles ARMA ont été retenus dans la suite de l'étude pour tester la mise en œuvre d'un modèle de prévision du climat local. L'approche est appliquée sur l'Île-de-France, où le phénomène d'îlot de chaleur est important.

4.3 Caractérisation des modèles ARMA

Les processus ARMA s'appliquent à des séries stationnaires, c'est-à-dire des séries dont l'espérance est constante au cours du temps, la variance est constante au cours du temps et non infinie, et dont la structure de covariance reste aussi constante.

Ainsi pour modéliser la série temporelle à l'aide d'un processus ARMA, la démarche suivante doit être adoptée :

- Représenter graphiquement la série afin de repérer les tendances et saisonnalité.
- Estimer et supprimer les tendances et saisonnalités (partie déterministe du processus stochastique).
- Choisir un modèle pour les résidus (partie aléatoire du processus stochastique) et l'estimer.
- Prédire les réalisations futures à l'aide de ce modèle.

4.3.1 *Élimination de la tendance et de la saisonnalité*

4.3.1.1 Série temporelle avec tendance et sans périodicité

Soit une série temporelle de la forme :

$$X_t = Z_t + \epsilon_t \quad (2.20)$$

Une première méthode est l'estimation paramétrique de la tendance. On suppose que la tendance de la série temporelle est de forme polynomiale. Le but est de présumer le degré du polynôme à partir de sa représentation graphique et d'estimer les paramètres du polynôme par méthode des moindres carrés. Cependant, cette méthode peut devenir rapidement fastidieuse. On opte ainsi pour une estimation non paramétrique : la moyenne mobile. Le principe est de supposer la tendance linéaire sur un petit intervalle et de l'estimer avec la moyenne sur cet intervalle. Cette moyenne est dite mobile car elle est recalculée à chaque pas de temps Δt .

4.3.1.2 Série temporelle avec tendance et périodicité

Une autre méthode pour éliminer la tendance et la saisonnalité sans les estimer est la méthode des différences. Pour cela, on utilise les opérateurs de Box-Jenkins (Box et Jenkins 1976) :

- l'opérateur de recul **B** :

$$BX_t = X_{t-1} \quad (2.21)$$

- l'opérateur de différenciation **∇** qui permet d'éliminer la tendance de la série :

$$\nabla X_t = X_t - X_{t-1} = (1 - B)X_t \quad (2.22)$$

Ainsi, si la série X_t admet une tendance polynomiale d'ordre k , alors ∇X_t admet une tendance d'ordre $k-1$. En appliquant k fois ∇ on élimine donc la tendance.

- l'opérateur de désaisonnalisation **∇_s** qui permet d'éliminer la saisonnalité de période s :

$$\nabla_s X_t = X_t - X_{t-s} = (1 - B^s)X_t \quad (2.23)$$

Par exemple, si un processus admet une tendance polynomiale d'ordre k et une saisonnalité d'ordre s , alors $\nabla_s^k X_t = (1 - B)^k (1 - B^s)X_t$ est un processus désaisonné et sans tendance.

On peut évaluer la stationnarité d'une série temporelle, et donc déterminer si cette dernière nécessite une différenciation, à l'aide des tests de racine unitaire. Il existe par exemple le test ADF (*Augmented Dickey-Fuller*) (Dickey et Fuller 1981), réalisé sous l'hypothèse de la présence d'une racine unitaire dans la série temporelle, appelée hypothèse nulle. Si le résultat du test est au-dessus d'une certaine valeur critique (par exemple 0,05), alors l'hypothèse nulle est acceptée et la série est non stationnaire. Sinon, l'hypothèse nulle est rejetée et la série est considérée comme stationnaire.

On peut également citer le test de Kwiatkowski-Phillips-Schmidt-Shin (KPSS) (Kwiatkowski et al. 1992) qui est un des tests de stationnarité le plus couramment utilisé. Contrairement au test ADF, ce test est réalisé sous l'hypothèse nulle de stationnarité de la série étudiée.

4.3.1.3 Vérifications sur le résidu

L'objectif des méthodes présentées ci-dessus est d'obtenir une série résiduelle stationnaire (ou le plus stationnaire possible), et en particulier sans tendance et sans saisonnalité. Il est ensuite nécessaire de tester s'il y a dépendance entre les différents termes de la série obtenue. Si ce n'est pas le cas, on est en présence d'un bruit blanc et il est inutile d'aller plus loin si ce n'est d'estimer la moyenne et la variance du bruit blanc. Dans le cas contraire, on peut modéliser la série résiduelle par un processus ARMA. Il existe différents tests de bruits blancs, tels que le test du porte-manteau ou le test de Ljung et Box. Ces tests seront présentés plus précisément par la suite.

4.3.2 Les processus ARMA

4.3.2.1 Les fonctions d'autocovariance et d'autocorrélation

L'autocovariance d'ordre (ou de décalage) h est définie par :

$$\gamma(h) = Cov(X_t, X_{t-h}) \quad (2.24)$$

La fonction de covariance (ou d'autocovariance) pour un processus stationnaire X_t est donnée par :

$$h \rightarrow \gamma(h), \quad h = 0, 1, 2, \dots \quad (2.25)$$

La fonction d'autocovariance peut être « normalisée » et la nouvelle fonction obtenue est la fonction d'autocorrélation (ou ACF pour *AutoCorrelation Function*) :

$$h \rightarrow \rho(h) = \frac{\gamma(h)}{\gamma(0)}, \quad h = 0, 1, 2, \dots \quad (2.26)$$

Le graphe de cette fonction est appelé corrélogramme. Ces fonctions caractérisent la dépendance entre les variables de X_t .

Cependant, la fonction d'autocorrélation n'est pas suffisante pour expliquer comment présent et passé sont reliés car les variables du passé sont elles-mêmes reliées entre elles. Autrement dit, X_{t-h} dépend en général des variables $X_{t-h+1}, \dots, X_{t-1}$. On a donc recours à une nouvelle fonction, la **fonction d'autocorrélation partielle (PACF)** qui exprime le lien entre X_t et X_{t-h} lorsqu'on a retiré leur meilleure explication affine en termes de $X_{t-h+1}, \dots, X_{t-1}$. L'algorithme de Durbin-Watson permet d'estimer les autocorrélations partielles d'un processus stationnaire.

4.3.2.2 Les processus autorégressif AR(p)

Ces processus sont construits à partir de l'idée que l'observation au temps t s'explique linéairement par les observations précédentes. On appelle processus autorégressif d'ordre p , tout processus (X_t) stationnaire tel que :

$$X_t - \varphi_1 X_{t-1} - \dots - \varphi_p X_{t-p} = \varepsilon_t \quad (2.27)$$

où $\varphi_1, \varphi_2, \dots, \varphi_p$ sont des réels fixés et (ε_t) est un bruit blanc centré de variance σ^2 .

On pose le polynôme caractéristique $\varphi(B) = 1 - \varphi_1 B - \dots - \varphi_p B^p$. On peut donc écrire :

$$\varphi(B)X_t = \varepsilon_t \quad (2.28)$$

➤ Propriétés d'un processus AR(p)

L'autocovariance et l'autocorrélation d'un processus AR(p) décroît exponentiellement avec h tandis que l'autocorrélation partielle est nulle à tout ordre strictement supérieur à p . Par exemple, dans la Figure 7 est illustré **le processus AR(2)** : $X_t + 0.5X_{t-1} + 0.9X_{t-2} = \varepsilon_t$ (la figure du haut correspond à la simulation du processus AR(2)). On peut constater que d'une part l'autocorrélation du processus modélisé (ACF) décroît exponentiellement, et que d'autre part l'autocorrélation partielle (PACF) du

Chapitre 2 : Modèles nécessaires à la régulation

processus est nulle (aux incertitudes près) pour tout ordre strictement supérieur à 2. Par conséquent, le processus modélisé est un processus autorégressif d'ordre 2 (AR(2)).

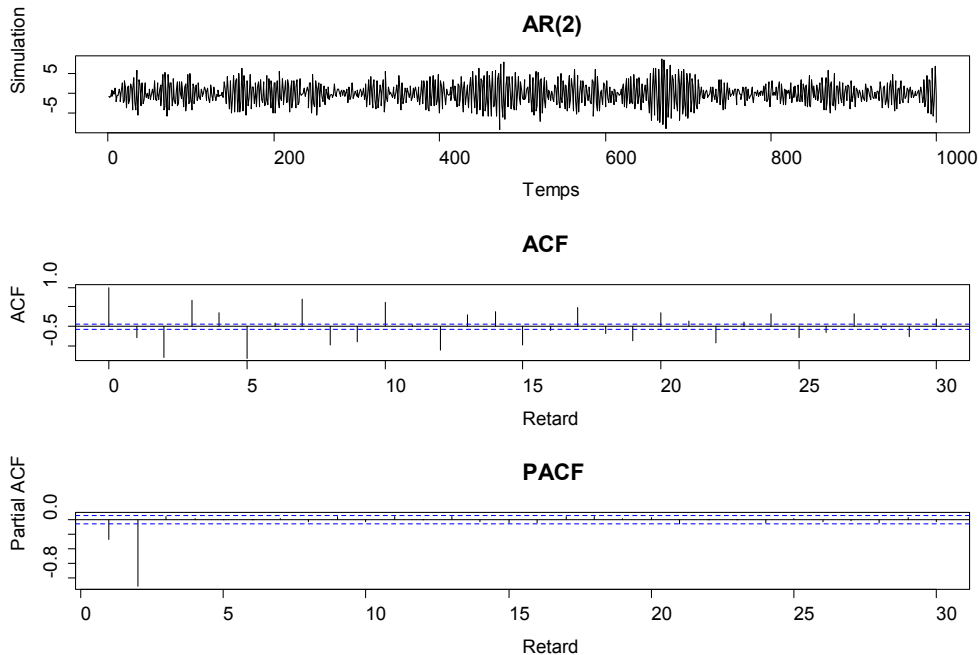


Figure 7: Graphe de trajectoire, corrélogramme et corrélogramme partiel du processus AR(2)

L'abscisse du corrélogramme et du corrélogramme partiel (retard) correspond à l'ordre (ou au décalage) des fonctions d'autocorrélation et d'autocorrélation partielle.

4.3.2.3 Les processus à moyenne mobile MA(q)

Ces processus sont construits à partir de l'idée que l'observation au temps t s'explique linéairement par les observations d'un bruit blanc.

On appelle processus à moyenne mobile d'ordre q tout processus (X_t) stationnaire tel que :

$$X_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (2.29)$$

où $\theta_1, \theta_2, \dots, \theta_q$ sont des réels fixés et ε_t est un bruit blanc de variance σ^2 .

On pose le polynôme caractéristique $\theta(B) = I - \theta_1 B - \dots - \theta_q B^q$. On peut donc écrire :

$$X_t = \theta(B)\varepsilon_t \quad (2.30)$$

➤ Propriétés d'un processus MA(q)

L'autocovariance et l'autocorrélation d'un processus MA(q) est nulle à tout ordre strictement supérieur à q tandis que l'autocorrélation partielle tend vers 0 à vitesse exponentielle lorsque h tend vers l'infini. Par exemple, dans la Figure 8, on peut remarquer que l'autocorrélation (ACF) du processus est nulle à tout ordre supérieur à 1 et que l'autocorrélation partielle (PACF) tend exponentiellement vers 0. Le processus modélisé est donc un processus à moyenne mobile d'ordre 1 (MA(1)).

Exemple d'un processus MA(1) : $X_t = \varepsilon_t - 0.8\varepsilon_{t-1}$

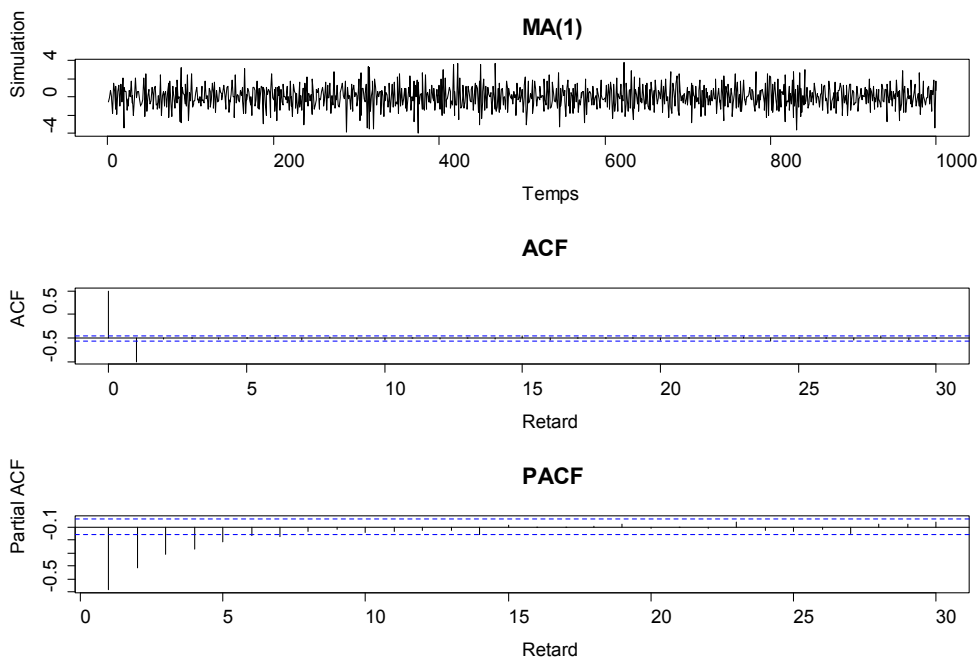


Figure 8: Graphe de trajectoire, corrélogramme et corrélogramme partiel du processus MA(1)

4.3.2.4 Les processus mixtes ARMA(p,q)

On appelle processus autorégressif à moyenne mobile d'ordre (p,q) tout processus (X_t) stationnaire tel que :

$$X_t - \varphi_1 X_{t-1} - \dots - \varphi_p X_{t-p} = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \tag{2.31}$$

Avec les polynômes caractéristiques, on a :

$$\varphi(B)X_t = \theta(B)\varepsilon_t \tag{2.32}$$

Il est immédiat qu'un ARMA(p,0) est un AR pur et qu'un ARMA(0,q) est un MA pur. Les seuls processus admettant simultanément une représentation MA pure et une représentation AR pure correspondent au cas ARMA(0,0), c'est-à-dire aux bruits blancs.

$\varphi(B)$ et $\theta(B)$ forment les deux polynômes caractéristiques du processus. On supposera que ces polynômes n'ont pas de racine commune, afin de s'assurer qu'il n'y a pas de représentation plus courte.

➤ Propriétés d'un processus ARMA(p,q)

L'autocovariance et l'autocorrélation d'un processus ARMA(p,q) vont tendre exponentiellement vers 0 lorsque h tend vers l'infini, à partir de l'ordre q+1. Cependant, à partir de cette seule propriété, il est difficile de déterminer graphiquement l'ordre d'un modèle ARMA.

4.3.2.5 Les processus ARMA saisonnier (modèle SARMA(p,q)(P,Q)_s)

Les modèles SARMA sont des cas particuliers des modèles ARMA. Soit une série temporelle X_t montrant une saisonnalité. Par une modélisation ARMA(p,q), nous obtenons le polynôme caractéristique :

$$\varphi(B)X_t = \theta(B)\varepsilon_t \quad (2.33)$$

Cependant, si la série présente une saisonnalité, le résidu de ε_t ne se comportera pas comme un bruit blanc, mais aura une structure de corrélation saisonnière. Pour traiter cela, on peut modéliser le résidu par un processus ARMA qui aura comme unité de temps la période de la saisonnalité (ses ordres seront alors notés P et Q). On notera le processus : SARMA(p,q)(P,Q). Ainsi, une série temporelle X_t suit un processus SARMA(p,q)(P,Q)_s avec période « s » si l'on peut écrire :

$$\varphi(B)\Gamma(B^s)X_t = \theta(B)\Psi(B^s)\varepsilon_t \quad (2.34)$$

où $\Gamma(B^s) = 1 - \gamma_1 B^s - \dots - \gamma_P B^{Ps}$, et $\Psi(B^s) = 1 - \psi_1 B^s - \dots - \psi_Q B^{Qs}$.

4.3.2.6 Les processus ARIMA(p,d,q) et SARIMA(p,d,q)(P,D,Q)_s

Les modèles ARMA ou SARMA sont utilisés pour modéliser des séries stationnaires. Cependant, en pratique, les séries temporelles étudiées (et en particulier les séries temporelles météorologiques) ne sont pas stationnaires et nécessitent donc un prétraitement pour éliminer les tendances et saisonnalités. Les processus ARIMA et SARIMA sont ainsi la généralisation des modèles ARMA et SARMA à des processus non stationnaires, admettant soit une tendance (ARIMA) soit une tendance et une saisonnalité (SARIMA).

Plus précisément (en prenant les notations définies au §4.3.1.2), une série temporelle X_t peut être modélisée par un processus ARIMA(p,d,q) si la série temporelle $Y_t = (1 - B)^d X_t$ peut être modélisée par un processus ARMA(p,q). Ainsi, les processus ARIMA(p,d,q) sont destinés à modéliser des séries temporelles présentant une tendance polynômiale d'ordre d. On modélise la série sous la forme :

$$\varphi(B)(1 - B)^d X_t = \theta(B)\varepsilon_t \quad (2.35)$$

De même, une série temporelle X_t peut être modélisée par un processus SARIMA(p,d,q)(P,D,Q)_s si la série temporelle $Y_t = (1 - B)^d (1 - B^s)^D X_t$ peut être modélisée par un processus SARMA(p,q)(P,Q)_s. Ainsi, les processus SARIMA(p,d,q)(P,D,Q)_s sont destinés à modéliser des séries temporelles présentant des variations saisonnières (ces variations pouvant elles-mêmes présenter un caractère aléatoire). On modélise ainsi la série sous la forme :

$$\varphi(B)\Gamma(B^s)(1 - B)^d (1 - B^s)^D X_t = \theta(B)\Psi(B^s)\varepsilon_t \quad (2.36)$$

4.3.3 Estimation et choix d'un modèle

A partir de l'observation d'une série temporelle, il est nécessaire de choisir un modèle (ou plusieurs), et estimer ses paramètres. Lorsque l'on hésite entre différents modèles possibles, des critères de choix de modèles sont utilisés pour sélectionner le meilleur d'entre eux.

4.3.3.1 Estimation du modèle

L'estimation des paramètres des modèles ARMA est faite par maximum de vraisemblance (ou MLE pour *Maximum Likelihood Estimation*). Cette technique cherche les valeurs des paramètres qui maximisent la probabilité d'obtenir les valeurs de la série temporelle observée. Cette maximisation est réalisée à l'aide d'algorithmes d'optimisation non linéaires (type Newton).

4.3.3.2 Choix du modèle

Une fois les paramètres des modèles estimés, l'utilisation de critères de choix de modèles permet de choisir le modèle qui effectue le meilleur compromis entre :

- l'ajustement à la série de données ;
- la complexité du modèle.

En effet, si l'on s'intéresse seulement à l'ajustement à la série de données, un modèle ARMA avec un très grand nombre de paramètres serait sélectionné. Cependant, plus il y a de paramètres à estimer et plus le nombre de données nécessaires à l'estimation est important. Or, pour une série temporelle donnée nous avons un nombre d'observations fixé, et donc plus le modèle sera complexe et moins bien les paramètres seront estimés.

Soit x_1, \dots, x_n une série d'observations indépendantes d'un processus aléatoire de loi g inconnue et soit $f(x_1, \dots, x_n | \theta)$ la densité de probabilité spécifiée par le paramètre θ . On appelle L la vraisemblance du paramètre θ :

$$L(\theta) = \prod_{j=1}^n f(x_j | \theta) \quad (2.37)$$

Les trois critères de choix de modèle les plus couramment utilisés sont :

- **le critère AIC** (*Akaike's Information Criterion*), qui sera généralement préféré si l'objectif de l'étude est de faire de la prévision :

$$AIC = -2 \log L(\theta) + 2\omega \quad (2.38)$$

où θ représente les paramètres du modèle et ω le nombre de ces paramètres ;

- **le critère AIC corrigé** :

$$AICc = AIC + \frac{2\omega(\omega + 1)}{n - \omega - 1} \quad (2.39)$$

où n représente le nombre d'observations ;

- **le critère BIC** (*Bayesian Information Criterion*), qui sera généralement préféré si l'objectif de l'étude est de s'ajuster à la série observée :

$$BIC = -2 \log L(\theta) + n\omega \quad (2.40)$$

Chapitre 2 : Modèles nécessaires à la régulation

Ces critères permettent ainsi de sélectionner les modèles ayant la plus grande vraisemblance tout en pénalisant la complexité du modèle. Le modèle sélectionné sera celui ayant la plus petite valeur du critère.

➤ Test du Bruit Blanc

Lorsque le processus est bien estimé, les résidus entre les valeurs observées et les valeurs estimées doivent se comporter comme un bruit blanc. Soit (ε_t) la série des résidus. S'ils obéissent à un bruit blanc, il ne doit pas exister d'autocorrélation dans la série. Différents tests permettent de le vérifier :

- Étude du corrélogramme et du corrélogramme partiel : on vérifie qu'il n'existe pas d'autocorrélation ou d'autocorrélation partielle significativement non nulle pour le processus étudié.
- Les tests du « porte-manteau » (deux tests sont utilisés en pratique) :

a) Test de Box et Pierce

On note $\rho(h)$ l'autocorrélation d'ordre h de la série des résidus (ε_t) . Pour un ordre K , le test de Box et Pierce est le test de l'hypothèse $H_0: \rho(1) = \dots = \rho(K) = 0$ contre l'hypothèse $\exists j \in [1, K]$ tel que $\rho(j) \neq 0$. Pour un processus ARMA(p,q), la statistique de ce test est :

$$Q_{BP} = n \sum_{h=1}^K \rho(h) \xrightarrow{n \rightarrow \infty} \chi^2(K - p - q) \quad (2.41)$$

L'hypothèse H_0 est rejetée au seuil de 5 % si Q_{BP} est supérieur au quantile 0,95 de la loi du χ^2 correspondant.

b) Test de Ljung-Box

Ces statistiques, définies pour un ordre K , correspondent à l'hypothèse nulle : $H_0: \rho(h) = 0 \forall h \leq K$ et sont reconstruites de la façon suivante :

$$Q_K = n(n+2) \sum_{h=1}^K \frac{\rho(h)^2}{n-h} \xrightarrow{n \rightarrow \infty} \chi^2(K - p - q) \quad (2.42)$$

4.4 Modélisation des conditions climatiques

4.4.1 Indicateurs de la qualité de la prévision

Les indicateurs de la qualité de la modélisation et de la prévision permettent d'évaluer la performance du modèle, c'est-à-dire de mesurer l'erreur de prévision. Différents indicateurs peuvent être utilisés pour cela.

Chapitre 2 : Modèles nécessaires à la régulation

Soit une série temporelle (X_t). Soit X_{t+h} la réalisation à $t + h$ de la grandeur à prévoir, et soit $\hat{X}_t(h)$ sa prédiction calculée au temps t pour le même instant $t + h$. Les indicateurs définis ci-dessous caractérisent l'erreur commise sur N mesures.

On définit l'erreur de prévision e à l'instant t de la grandeur à l'instant $t + h$ comme :

$$e(t + h|t) = X_{t+h} - \hat{X}_t(h) \quad (2.43)$$

Il existe différents indicateurs permettant de juger de la qualité de prévision. On peut citer par exemple Diagne et al. (2013) ou Siebert (2008) :

i) Le biais

Le biais ou MBE (*Mean Biased Error*) est défini comme la moyenne de l'erreur sur la période considérée :

$$MBE(h) = \frac{1}{N} \sum_{t=1}^N e(t + h|t) \quad (2.44)$$

Le biais est utilisé pour déterminer si un modèle est plus biaisé qu'un autre.

ii) L'erreur moyenne absolue

L'erreur moyenne absolue ou MAE (*Mean Absolute Error*) est un des indicateurs le plus utilisé et est défini par :

$$MAE(h) = \frac{1}{N} \sum_{t=1}^N |e(t + h|t)| \quad (2.45)$$

Il s'agit de la moyenne des déviations ou erreurs absolues sur toutes les données.

iii) MSE et RMSE

Un autre indicateur couramment utilisé est le RMSE (*Root Mean Square Error*) qui correspond à :

$$RMSE(h) = \sqrt{MSE(h)} \quad (2.46)$$

où on définit MSE (*Mean Squared Error*) comme :

$$MSE(h) = \frac{1}{N} \sum_{t=1}^N e(t + h|t)^2 \quad (2.47)$$

iv) MAPE

On peut également définir le MAPE (*Mean Absolute Percentage Error*) tel que :

$$MAPE(h) = Moyenne(|\frac{e(t + h|t)}{X_{t+h}} * 100|) \quad (2.48)$$

Dans cette étude, les indicateurs MBE et MAE seront utilisés. Le premier a été choisi car il permet de représenter l'erreur globale sur le cumul des prédictions. Ainsi, il permettra d'analyser si un modèle aura tendance à surestimer ou sous-estimer les prédictions par rapport aux mesures. Le deuxième a été retenu car il est moins sensible aux erreurs importantes que l'indicateur RMSE qui

pénalise lourdement les gros écarts. Ainsi, une diminution du MAE signifiera une amélioration en moyenne de la prédiction alors qu'une diminution du RMSE signifiera plutôt une limitation des grosses erreurs de prédiction.

4.4.2 Méthodes de modélisation développées

Dans le cadre de cette étude, deux méthodes de modélisation ont été développées.

4.4.2.1 Modélisation directe

La première méthode correspond à la modélisation « directe » de la température et du rayonnement solaire. Elle consiste à utiliser seulement les données d'une station météorologique (données séparées en données d'apprentissage et données de validation), de déterminer un modèle ARMA sur les données d'apprentissage et d'analyser la qualité de prévision du modèle sur les données de validation.

4.4.2.2 Modélisation des écarts (contextualisation)

La deuxième méthode correspond à la modélisation de l'écart (ou contextualisation) entre deux stations (une station dont on souhaite prévoir l'évolution des conditions météorologiques, et une autre dont on dispose des prévisions météorologiques). Cette méthode se base sur l'idée d'utiliser la prévision de Météo France (ou d'autres fournisseurs) pour prévoir la température ou le rayonnement solaire qu'il y aura localement. En effet, les prévisions fournies par les modèles physiques sont plus précises que celles fournies par les modèles purement mathématiques. Cependant, il s'agit de prévisions météorologiques à l'échelle régionale et non locale. L'idée est alors d'utiliser les modèles mathématiques pour prévoir l'écart entre les données météorologiques fournies par les modèles physiques (données plus précises mais régionales) et les données météorologiques locales (autour du bâtiment à réguler). Cette méthode permet de s'appuyer sur la précision des données issues des modèles physiques tout en gardant le caractère local des prévisions météorologiques.

Par exemple, on utilise un modèle ARMA pour modéliser l'écart de température (ou de rayonnement solaire) entre deux stations : une première station où nous disposons des prévisions de Météo France et une deuxième où l'on souhaite prévoir la température (ou le rayonnement solaire). Notons X_t la série temporelle de la station où nous souhaitons réaliser les prévisions et soit Y_t la série temporelle de la station dont nous disposons des prévisions de Météo France. Enfin, notons ε_t l'écart entre Y_t et X_t , soit : $\varepsilon_t = X_t - Y_t$. Ainsi, avec les notations du §4.4.1, la prévision de X_t calculée au temps $t + h$ vaut $\hat{X}_t(h) = \hat{\varepsilon}_t(h) + Y_{t+h}$, où $\hat{\varepsilon}_t(h)$ correspond à la prévision de l'écart au temps $t + h$ et où Y_{t+h} correspond à la prévision à $t + h$ donnée par Météo France. Le but de la deuxième méthode est de modéliser ε_t à l'aide d'un modèle ARMA.

Cette méthode de modélisation des écarts (ou contextualisation) peut permettre de prendre en compte le phénomène d'îlot de chaleur urbain. Ce dernier correspond à l'écart de température observé entre une agglomération et son environnement périphérique moins urbanisé. Essentiellement nocturne,

Chapitre 2 : Modèles nécessaires à la régulation

il est favorisé par trois facteurs prépondérants (Météo-France et Agence Parisienne du Climat, 2013) : le mode d'occupation des sols, les propriétés radiatives et thermiques des matériaux (par exemple leur albédo) et la morphologie de la ville. Par exemple, l'îlot de chaleur urbain centré sur Paris se traduit par des différences nocturnes de température de l'ordre de 2°C à 3°C en moyenne annuelle entre Paris et les zones rurales alentour.

4.4.3 Données utilisées

Cette étude a pour objectif d'évaluer les performances des modélisations directe et indirecte présentées précédemment. L'exemple d'application concerne la prévision météorologique d'une station de Paris. Dans le cadre de la modélisation des écarts (contextualisation), la station régionale considérée est celle d'Orly.

4.4.3.1 Origine des données

Les données météorologiques utilisées pour la modélisation de la température sont issues du site <http://www.meteociel.fr> fournissant les données horaires de la température des stations météorologiques de Paris (Saint-Germain-des-Prés) et d'Orly pour l'année 2013. Certaines données – moins de 0,3 % d'entre elles – étaient manquantes. Celles-ci ont été calculées comme étant la moyenne des températures des heures précédentes et suivantes. Les données recueillies correspondent aux températures horaires selon l'heure de Paris (*Central European Summer Time*, correspondant au temps universel UTC+1h en hiver, UTC+2h en été). Étant donné que les données recueillies pour le rayonnement solaire sont exprimées en heure universelle, celles de la température ont été également exprimées en heure universelle.

Les données météorologiques utilisées pour la modélisation du rayonnement solaire sont issues de la base de données HelioClim-3 de SoDa (Solar Radiation Data) pour les stations de Paris et d'Orly. Ces données sont issues d'observations satellite.

Perez et al. (1994) ont montré que les valeurs issues de satellites marquent une différence de l'ordre de 20 % par rapport aux mesures. De plus, les données manquantes concernant la température diminuent également la qualité des données et donc la fiabilité du modèle météorologique. Ainsi, l'utilisation de données (température de l'air extérieur et rayonnement solaire) issues directement de mesures sur le bâtiment permettrait d'améliorer la fiabilité des modèles développés.

4.4.3.2 Analyse statistique des données

Le phénomène d'îlot de chaleur urbain entre Paris et Orly peut être mis en évidence par une analyse statistique de la répartition sur l'année de l'écart de température entre ces deux stations. Pour cela, l'outil *box plot* est utilisé pour figurer le profil statistique de la série. Il permet de représenter une distribution de valeurs sous forme simplifiée avec :

- la médiane (trait épais) ;
- une boîte, s'étendant du premier quartile au troisième quartile ;
- des moustaches, qui s'étendent jusqu'à la valeur distante d'au maximum 1,5 fois la distance interquartile ;
- des ronds, qui correspondent à des valeurs supérieures ou inférieures aux moustaches.

La Figure 9 présente le *box plot* de la série des écarts de température nocturne (de 22h à 6h) entre Paris et Orly. On peut remarquer que sur l'ensemble de l'année, la médiane est en moyenne légèrement inférieure à 2°C. On peut également constater que la boîte est plus étendue sur le mois d'août. Ceci peut s'expliquer par le fait que les conditions anticycloniques de la période estivale sont plus favorables à la survenue d'îlots de chaleur urbain que les perturbations océaniques de l'hiver (Météo-France et Agence Parisienne du Climat, 2013).




Figure 9: *Box plot* de la série des écarts de température nocturne entre Paris et Orly pour l'année 2013

4.4.4 Modélisation de la température

4.4.4.1 Première méthode : modélisation directe de la température

Pour la modélisation directe de la température, un modèle ARMA a été développé pour chaque mois de l'année. Seuls les résultats du mois d'août (correspondant au mois où l'îlot de chaleur est le plus marqué) seront détaillés.

4.4.4.1.1 Modélisation du mois d'août

➤ Etude de la tendance et de la saisonnalité

Les 14 premiers jours du mois d'août ont été utilisés pour déterminer l'ordre du modèle ARMA permettant de modéliser l'évolution de la température à Paris sur le mois d'août.




Figure 10: Température à Paris (mois d'août 2013)

Le graphe de l'évolution de la température à Paris lors du mois d'août (Figure 10) montre que cette série temporelle n'est pas stationnaire (son espérance et sa variance ne sont pas constantes au cours du temps). L'étude ACF de cette série est donc nécessaire.

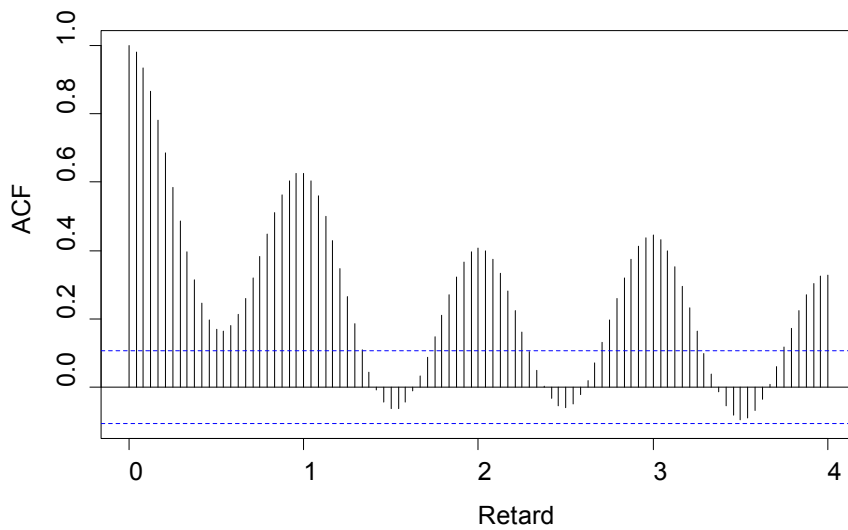


Figure 11: ACF de la température à Paris (mois d'août 2013)

Dans la Figure 11, les retards en abscisse sont indiqués en jours. Ainsi, un retard de 1 correspond à 24 h, un retard de 2 correspond à 48 h et ainsi de suite. On peut observer que l'ACF de la température présente des pics aux retards multiples de 24 qui ne s'atténuent que très lentement. On peut donc en déduire une non-stationnarité saisonnière. Cette non-stationnarité s'explique par la périodicité de 24 h de la série. De plus, on peut remarquer que l'ACF de la température présente un pic important au retard 1. Ces observations amènent à penser que les différenciations à l'ordre 1 ($d=1$) et à l'ordre 24 ($D=1$, $s=24$ h) sont nécessaires pour obtenir une série stationnaire.

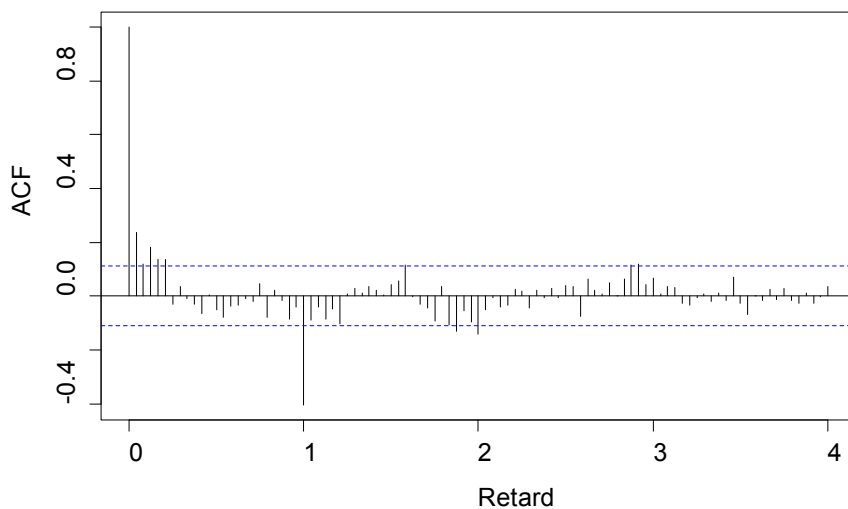


Figure 12: ACF de la température différenciée (Paris, mois d'août 2013)

On peut constater que l'ACF de la température différenciée (Figure 12) à l'ordre 24 et à l'ordre 1 $((1 - B)(1 - B^{24})X_t)$ montre un pic à 24 h (1 jour), caractéristique d'une série stationnaire avec saisonnalité. On peut donc conclure que la série temporelle de l'évolution de la température à Paris au mois d'août peut être modélisée par un modèle SARIMA($p,1,q$)($P,1,Q$)₂₄.

Chapitre 2 : Modèles nécessaires à la régulation

➤ Détermination du modèle

Pour déterminer l'ordre du modèle correspondant le mieux à la série temporelle, le logiciel R (R Core Team 2014), mettant en œuvre différents packages pour l'étude des séries temporelles et des modèles ARMA, a été choisi. Plus précisément, la fonction « *auto.arima* » du package « *forecast* » (Hyndman et Khandakar 2007) a été utilisée pour la sélection du modèle SARIMA se basant sur les critères automatiques (AIC, AICc, BIC). Le modèle déterminé par la fonction est un **SARIMA (1,1,0) (0,1,1)₂₄**.

➤ Prévisions

Après avoir déterminé l'ordre du modèle SARIMA à utiliser pour modéliser notre série de données, l'objectif est de prévoir la température sur un horizon de temps donné et de comparer la prévision avec les données de validation. L'horizon de temps choisi correspond à $h + 24$ à partir de la journée de prévision, c'est-à-dire que le modèle SARIMA prévoit les 24 prochaines heures de la station météorologique. Par exemple, si nous sommes à la 12^{ème} heure du jour J, alors $h + 1$ correspond à la 13^{ème} heure du jour J, $h + 3$ à la 15^{ème} heure du jour J et $h + 24$ correspond à la 12^{ème} heure du jour J+1.

Pour déterminer les coefficients du modèle SARIMA connaissant l'ordre du modèle (SARIMA (1, 1, 0) (0, 1, 1)₂₄), les données d'apprentissage correspondent aux deux semaines précédant le jour J de prévision (principe de la fenêtre glissante). Ces coefficients sont déterminés par la fonction « *auto.arima* » sur les données d'apprentissage. Ces coefficients sont à chaque fois mis à jour lors de la modification des données d'apprentissage. Les résultats de la prévision du 15 au 30 août sont présentés dans le Tableau 2. Ils correspondent à la moyenne sur 16 jours des indicateurs MAE et MBE.

Tableau 2 : Résultats de la prévision de la température (mois d'août 2013)

Indicateur	MAE	MAE	MAE	MAE	MAE	MBE	MBE	MBE	MBE	MBE
Horizon	1 h	3 h	6 h	12 h	24 h	1 h	3 h	6 h	12 h	24 h
Paris (mois d'août)/ Température (°C)	0,34	0,72	1,20	1,77	2,36	0,00	0,00	0,01	0,01	-0,08

On peut remarquer que les prévisions à court terme ($h + 1$, $h + 3$) réalisées par la modélisation directe sont performantes avec un MAE de 0,34°C et 0,72°C respectivement. De plus, la valeur des MBE indique que ces prévisions ne sont que très peu biaisées. Cependant, pour un horizon plus lointain, les performances se détériorent rapidement. Ainsi, pour une prévision à $h + 24$, l'erreur absolue est en moyenne de 2,36°C indiquant la difficulté pour la modélisation directe de faire une prévision fiable à des horizons de temps plus grands. Enfin, on peut remarquer que les prévisions pour tous les horizons sont peu biaisées.

➤ Analyse des résidus

Les différents tests de blancheur du résidu ont pu montrer que le résidu se comporte comme un bruit blanc.

4.4.4.2 Deuxième méthode : modélisation de l'écart (contextualisation)

Dans cette méthode, ce n'est pas la température de la station locale qui est prédite, mais son écart avec la station régionale.

4.4.4.2.1 Modélisation du mois d'août

➤ Etude de la tendance et de la saisonnalité

Les 14 premiers jours du mois d'août ont été également utilisés pour déterminer l'ordre du modèle ARMA permettant de modéliser l'évolution de l'écart de température entre Paris et Orly sur le mois d'août.

Le graphe de l'évolution de l'écart de température entre Paris et Orly (Figure 13) montre que cette série temporelle n'est pas stationnaire (son espérance et sa variance ne sont pas constantes au cours du temps). L'étude ACF de cette série est donc nécessaire.

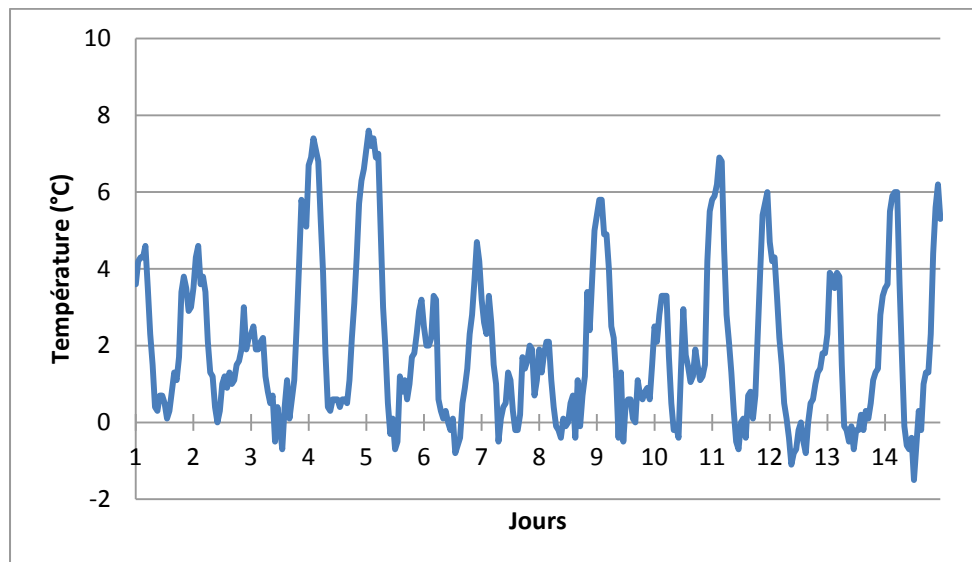


Figure 13: Écarts de température entre Paris et Orly (mois d'août 2013)

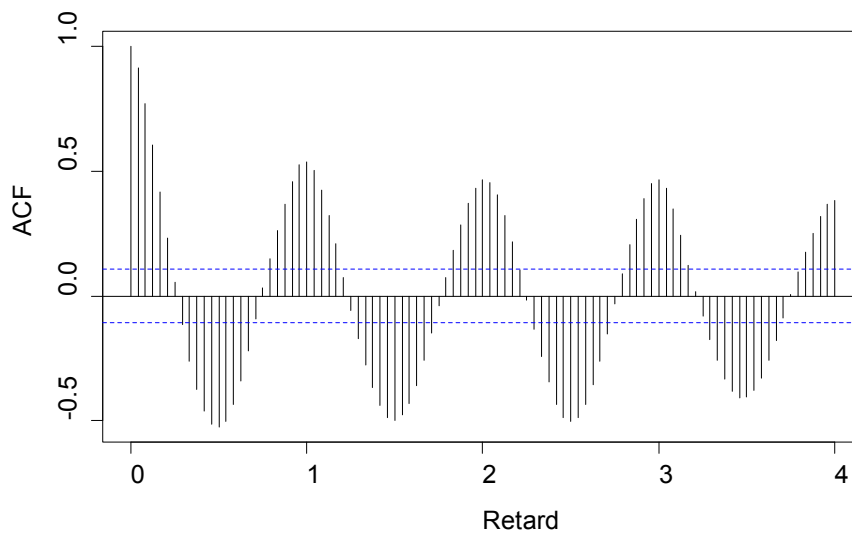


Figure 14: ACF des écarts de température entre Paris et Orly (mois d'août 2013)

Dans la Figure 14, on peut observer que l'ACF présente des pics (positifs) aux retards multiples de 24 h (1 jour) ainsi qu'un pic important au retard 1 h. Ces observations amènent à penser que les différenciations à l'ordre 1 et à l'ordre 24 sont nécessaires pour obtenir une série stationnaire.




Figure 15: ACF des écarts différenciés de température entre Paris et Orly (mois d'août 2013)

On peut observer sur la Figure 15 la présence d'un pic à 24 h (1 jour), caractéristique d'une série stationnaire avec saisonnalité. On peut donc conclure que la série temporelle de l'évolution de l'écart de température entre Paris et Orly peut être modélisée par un modèle SARIMA(p,1,q)(P,1,Q)₂₄.

➤ Détermination du modèle

L'ordre du modèle déterminé par la fonction est un **SARIMA (0, 1, 0) (2, 1, 0)₂₄**.

Chapitre 2 : Modèles nécessaires à la régulation

➤ Prévisions

Les données d'apprentissage suivent le même principe que celles pour la modélisation directe de la température. Les résultats de la prévision sont présentés dans le Tableau 3. Ils correspondent à la moyenne sur 16 jours (du 15 au 30 août) des indicateurs MAE et MBE.

Tableau 3 : Résultats de la prévision des écarts de température (mois d'août 2013)

Indicateur	MAE	MAE	MAE	MAE	MAE	MBE	MBE	MBE	MBE	MBE
Horizon	1 h	3 h	6 h	12 h	24 h	1 h	3 h	6 h	12 h	24 h
Écarts (mois d'août)/ Température (°C)	0,64	1,03	1,39	1,80	1,40	0,00	0,00	-0,01	-0,04	-0,09

On peut remarquer que, comme pour la modélisation directe, la prévision à court terme ($h + 1$ par exemple) est performante (MAE de 0,64°C) et présente un biais négligeable. Ces performances sont cependant inférieures à celle de la modélisation directe. Au contraire, pour un horizon plus lointain, les performances de la modélisation des écarts sont supérieures à celles de la modélisation directe avec un MAE à $h + 24$ de 1,40°C (à comparer à un MAE de 2,36°C pour la modélisation directe). De plus, on peut noter que les prévisions sont peu biaisées dans l'ensemble.

➤ Analyse des résidus

Les différents tests de blancheur du résidu ont pu montrer que le résidu se comporte comme un bruit blanc.

4.4.4.3 Analyse des résultats sur l'ensemble de l'année

Le Tableau 28 de l'Annexe A récapitule les résultats obtenus concernant la modélisation de la température sur l'ensemble de l'année. Il permet de comparer les erreurs de la modélisation directe par rapport à celles de la modélisation des écarts. Le Tableau 4 présente un récapitulatif de ces résultats sur l'année (les résultats correspondent à la moyenne des indicateurs MAE et MBE mensuels).

Tableau 4 : Récapitulatif des résultats sur l'année 2013 de la modélisation de la température

Indicateur	MAE	MAE	MAE	MAE	MAE	MBE	MBE	MBE	MBE	MBE
Horizon	1 h	3 h	6 h	12 h	24 h	1 h	3 h	6 h	12 h	24 h
Modélisation directe	0,36	0,76	1,21	1,71	2,09	0	-0,01	-0,02	-0,03	-0,03
Modélisation écarts	0,51	0,75	0,97	1,15	1,09	0	-0,01	-0,02	-0,02	-0,03

On peut tout d'abord constater que pour la prévision à $h + 1$, la modélisation directe est plus performante que la modélisation des écarts. En effet, sur l'année, la modélisation directe permet d'obtenir une meilleure prévision de la température à $h + 1$ que la modélisation des écarts avec 0,36°C et 0,51°C respectivement. Pour la prévision à $h + 3$ les résultats sont quant à eux très proches avec en moyenne sur l'année 0,76°C pour la modélisation directe et 0,75°C pour la modélisation des écarts.

Concernant les prévisions à $h + 6$, $h + 12$ et $h + 24$, la modélisation des écarts est plus performante que la modélisation directe. Cette différence de performance est d'autant plus

Chapitre 2 : Modèles nécessaires à la régulation

remarquable pour la prévision à $h + 24$: l'erreur moyenne absolue de prévision obtenue par la modélisation des écarts est en moyenne de 1,09°C sur l'ensemble de l'année, alors qu'elle est de 2,09°C pour la modélisation directe. Ces résultats sont résumés dans la Figure 16, où l'on peut voir l'évolution sur l'année de l'écart moyen absolu des prévisions à $h + 1$ (MAE 1h), et $h + 24$ (MAE 24h) pour les deux types de modélisation.

Enfin, on peut constater que les erreurs moyennes (c'est-à-dire le biais, noté MBE) sont faibles pour la modélisation directe et la modélisation des écarts (Tableau 4). Par exemple, pour la modélisation directe les erreurs de prévision à $h + 1$ et $h + 24$ sont de 0°C (avec un écart type de 0,01°C) et de -0,03°C (avec un écart type de 0,35°C) respectivement. De même, pour la modélisation des écarts, les erreurs de prévision à $h + 1$ et $h + 24$ sont de 0°C (avec un écart type de 0,02°C) et de -0,03°C (avec un écart type de 0,11°C) respectivement (Tableau 28 de l'Annexe A).

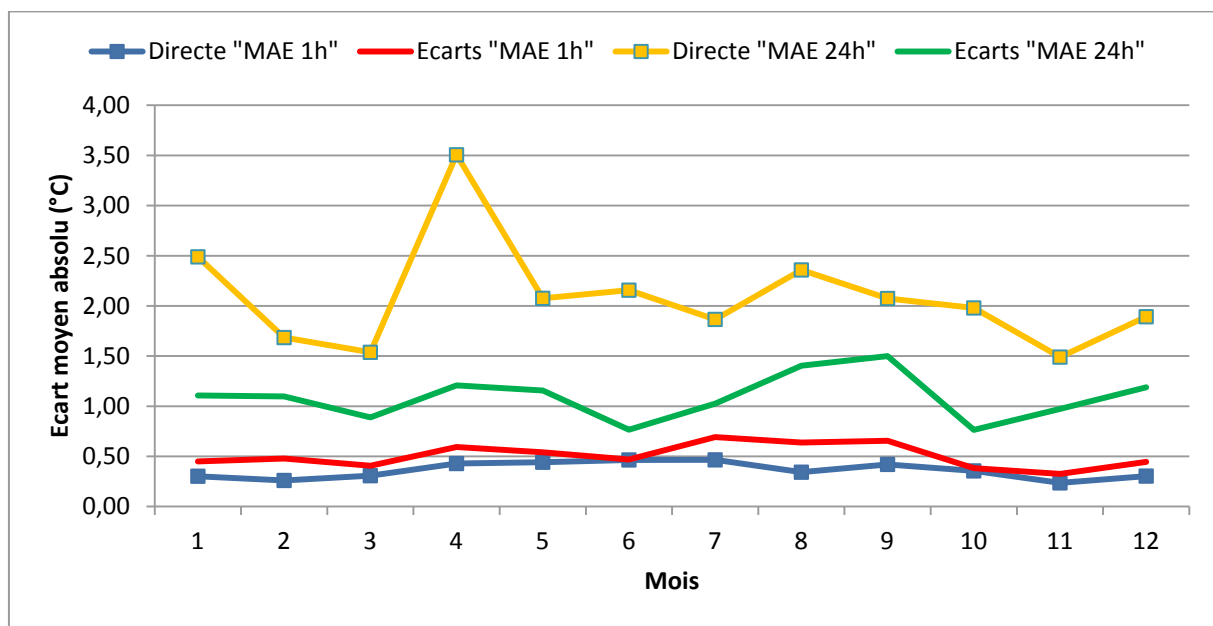


Figure 16 : Résultats des modélisations (directe et écarts) pour la prévision à 1 h et 24 h

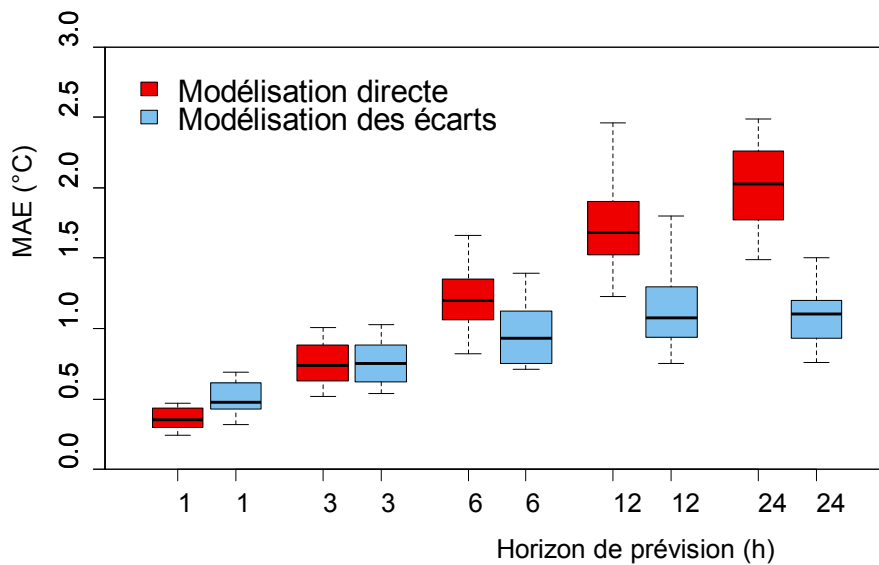


Figure 17 : Box plot des MAE obtenus par les modélisations de la température suivant l'horizon de prévision

L'utilisation de l'outil *box plot* (§4.4.3.2) dans la Figure 17 permet de présenter la dispersion statistique de l'écart moyen absolu (MAE) obtenu par les deux types de modélisation de la température suivant les différents horizons de prévision. Ce graphique illustre les remarques faites précédemment. On peut par exemple noter qu'à l'horizon $h + 1$ les performances de la modélisation directe sont nettement supérieures à celle de la modélisation des écarts avec une dispersion statistique plus faible. Le constat est inversé pour les horizons de temps plus grand ($h + 6$, $h + 12$ et $h + 24$) où la modélisation des écarts permet d'obtenir des résultats plus précis et moins dispersés statistiquement (en particulier pour l'horizon $h + 24$).

Il est également intéressant d'analyser la pertinence des résultats obtenus par la modélisation des conditions climatiques locales. En effet, il est utile d'étudier si les résultats obtenus par la modélisation de la météorologie locale (modélisation directe ou des écarts) sont plus précis que ceux obtenus par une prévision régionale. Ne disposant pas d'un modèle de prévision pour la station régionale, un modèle de prévision régional « parfait » a été considéré. Ce modèle de prévision parfait fait correspondre la prévision régionale à la mesure régionale (par exemple, la prévision de la température à $h + 1$ réalisée par le modèle régional correspond à la mesure de la température régionale à $h + 1$). Il est à noter que pour la modélisation des écarts, la prévision régionale utilisée est également considérée comme parfaite. L'utilisation de ce modèle parfait revient alors à comparer les résultats obtenus par la modélisation des conditions climatiques locales avec l'écart moyen entre les températures de Paris et Orly sur les données de validation. Les écarts moyens absolus entre les températures à Paris et Orly sont résumés dans le Tableau 6.

Chapitre 2 : Modèles nécessaires à la régulation

Tableau 5 : Écarts moyens absolus par mois entre les températures à Paris et Orly sur l'année 2013

Indicateur	MAE	MAE	MAE	MAE	MAE	MAE	MAE	MAE	MAE	MAE	MAE	MAE
Mois	01	02	03	04	05	06	07	08	09	10	11	12
Écarts entre Paris et Orly (°C)	1,75	1,9	1,4	1,84	1,3	1,15	1,31	1,6	1,64	1,63	1,34	1,7

On peut constater qu'en moyenne la modélisation des écarts est toujours plus performante que la prévision régionale parfaite (Figure 18 et Figure 19). Ainsi, même pour la prévision à $h + 24$, qui correspond à l'horizon où les performances sont les plus faibles pour la modélisation des écarts, les résultats obtenus par la modélisation de la météorologie locale sont meilleurs que ceux obtenus par la prévision régionale. La modélisation directe est quant elle plus performante que la prévision régionale « parfaite » pour les horizons de temps courts mais pas pour des horizons de temps longs (Figure 19).

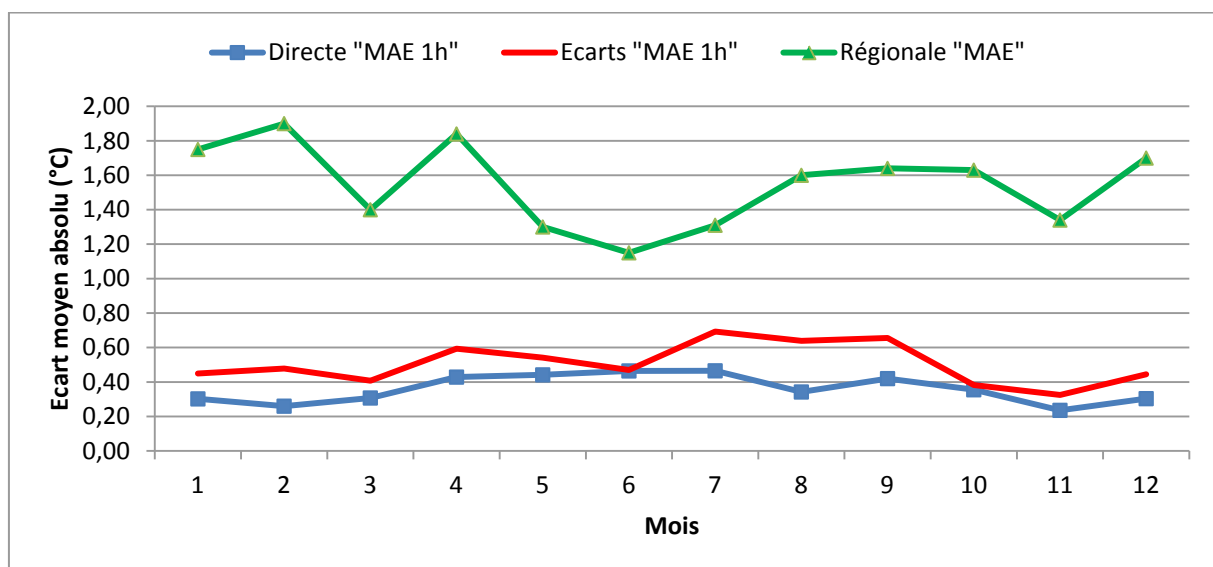


Figure 18 : Résultats des différents types modélisations de la température pour la prévision à 1 h

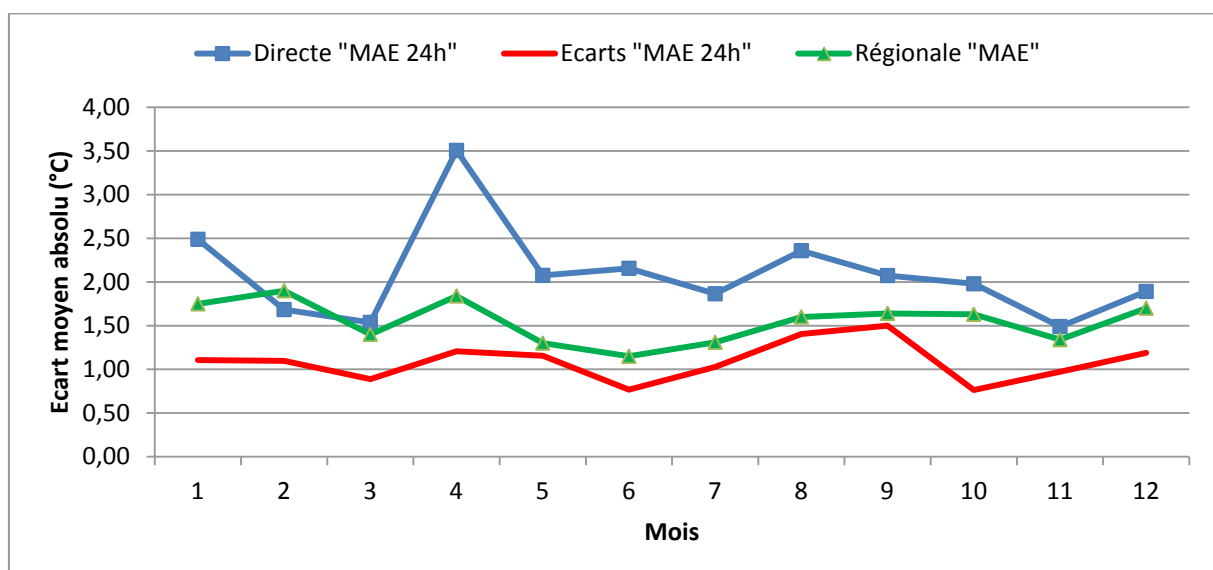


Figure 19: Résultats des différents types modélisations de la température pour la prévision à 24 h

Chapitre 2 : Modèles nécessaires à la régulation

Ces résultats confirment l'intérêt de la modélisation des écarts pour des horizons de prévision longs (supérieurs à trois heures). Cette méthode permet ainsi de profiter de la précision des prévisions issues des modèles physiques tout en gardant le caractère local des prévisions météorologiques. Cependant, pour des horizons de prévision plus courts (inférieurs à trois heures), la modélisation directe qui présente, dans cette étude, des résultats légèrement plus précis, est à privilégier pour obtenir des résultats plus précis.

4.4.5 Modélisation du rayonnement solaire

4.4.5.1 Méthodologie suivie

La méthodologie suivie pour modéliser le rayonnement solaire est là même que celle présentée dans le §4.4.4. Pour évaluer la performance des modèles identifiés, seules les prévisions concernant la journée ont été retenues dans le calcul des MAE et MBE.

4.4.5.2 Analyse des résultats sur l'ensemble de l'année

Le Tableau 29 de l'Annexe B rassemble les résultats obtenus pour la modélisation du rayonnement solaire. Le Tableau 6 présente un récapitulatif de ces résultats sur l'année.

Tableau 6 : Récapitulatif des résultats sur l'année 2013 de la modélisation du rayonnement (en W/m^2)

Indicateur	MAE	MAE	MAE	MAE	MAE	MBE	MBE	MBE	MBE	MBE
Horizon	1 h	3 h	6 h	12 h	24 h	1 h	3 h	6 h	12 h	24 h
Modélisation directe	45	76	81	81	88	0,4	0,3	-3	-3	-4
Modélisation écarts	25	27	26	26	27	0,2	0,2	-0,2	-0,8	0,1

Contrairement à la modélisation de la température, on peut constater que la modélisation des écarts est plus performante que la modélisation directe pour l'ensemble des horizons de prévision. Par exemple, pour la prévision à $h + 1$, l'erreur moyenne absolue sur les 12 mois est de $25 W/m^2$ pour la modélisation des écarts alors qu'elle est de $45 W/m^2$ pour la modélisation directe. De même, pour la prévision à $h + 24$, l'erreur moyenne absolue sur les 12 mois est de $27 W/m^2$ pour la modélisation des écarts alors qu'elle est de $88 W/m^2$ pour la modélisation directe. Ces résultats sont résumés dans la Figure 20 où l'on peut voir l'évolution sur l'année de l'écart moyen absolu des prévisions à $h + 1$ (MAE 1 h) et $h + 24$ (MAE 24 h) pour les deux types de modélisation.

On peut également constater que les erreurs moyennes (MBE) sont faibles pour la modélisation des écarts avec des erreurs moyennes de prévision à $h + 1$ et $h + 24$ de $0,2 W/m^2$ (avec un écart type de $1,5 W/m^2$) et $0,1 W/m^2$ (avec un écart type de $2,2 W/m^2$) respectivement (Tableau 29 de l'Annexe B).

La Figure 21 permet de juger de l'importance de l'erreur faite par la modélisation pour la prévision du rayonnement solaire à midi (avec comme horizon $h + 1$ et $h + 24$) en la comparant à la moyenne mesurée à midi. On peut constater que l'erreur est en proportion plus importante lors des mois d'hiver que des mois d'été. De plus, on peut remarquer que l'erreur obtenue par la modélisation directe à

Chapitre 2 : Modèles nécessaires à la régulation

l'horizon $h + 24$ est beaucoup plus importante que celle obtenue à l'horizon $h + 1$, contrairement à la modélisation des écarts pour laquelle les erreurs sont du même ordre de grandeur.

L'utilisation de l'outil *box plot* (§4.4.3.2) dans la Figure 22 permet de présenter la dispersion statistique de l'écart moyen absolu (MAE) obtenu par les deux types de modélisation du rayonnement suivant les différents horizons de prévision.




Figure 20: Résultats des modélisations (directe et écarts) pour la prévision à 1 h, et 24 h

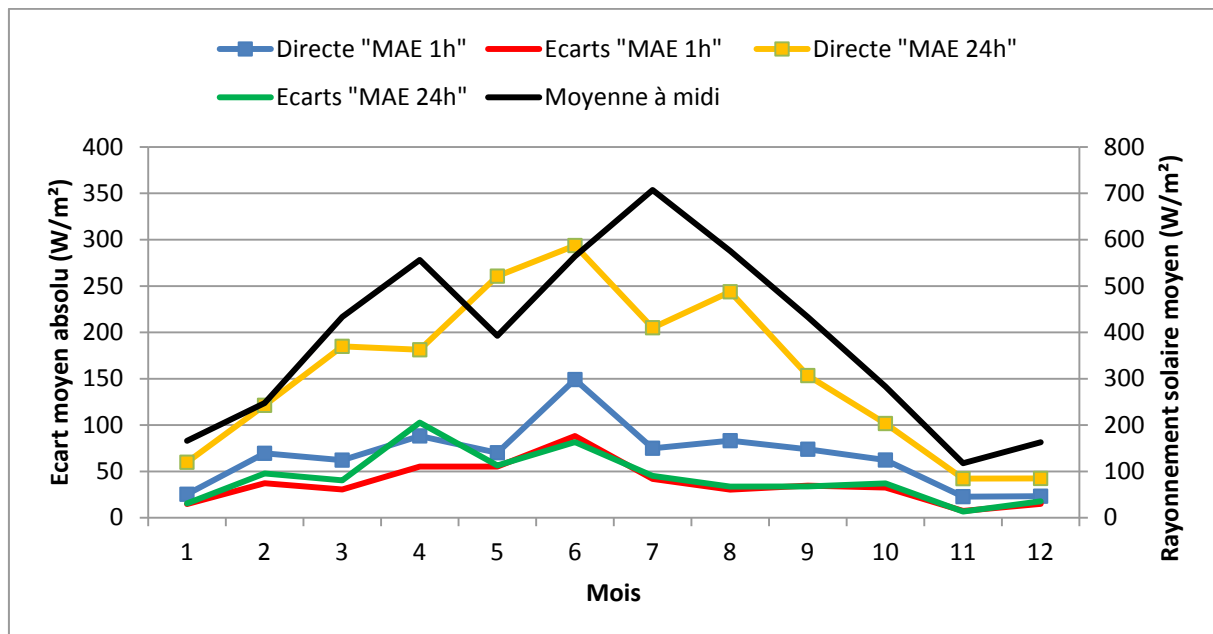


Figure 21: Comparaison entre les résultats de la prévision à midi et de la moyenne mesurée à midi

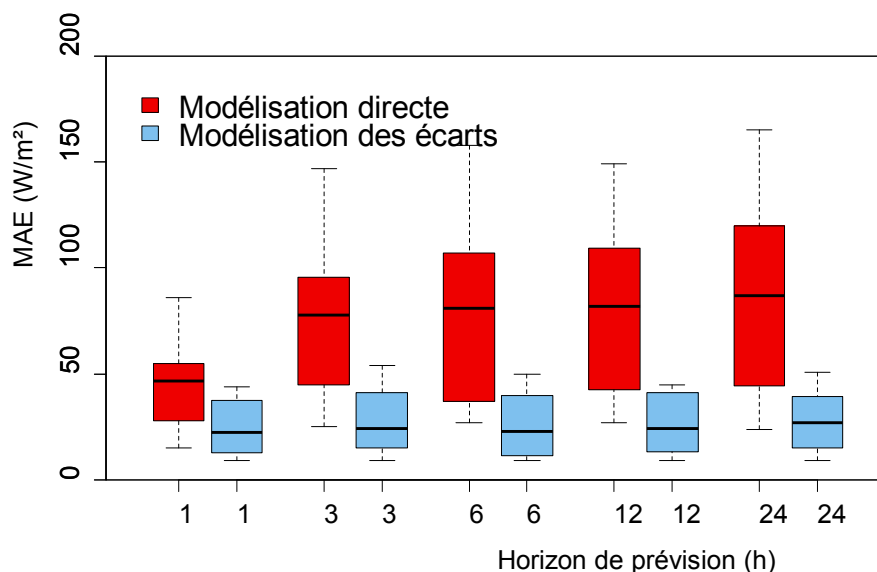


Figure 22: Box plot des MAE obtenus par les modélisations du rayonnement suivant l'horizon de prévision

Ce graphique illustre les remarques faites précédemment, à savoir que les performances de la modélisation des écarts sont nettement supérieures à celles de la modélisation directe, et cela pour tous les horizons de prévision. On peut également constater une plus faible dispersion statistique pour la modélisation des écarts par rapport à la modélisation directe.

Comme dans le cas de la modélisation de la température, il est intéressant d'analyser la pertinence des résultats obtenus par la modélisation des conditions climatiques locales en les comparant à ceux obtenus par une prévision régionale « parfaite ». Pour rappel, l'utilisation d'un tel modèle revient à comparer les résultats obtenus par la modélisation des conditions climatiques locales avec l'écart moyen entre le rayonnement à Paris et Orly sur les données de validation. Les écarts moyens absolus entre le rayonnement à Paris et Orly sont résumés dans le Tableau 7.

Tableau 7 : Écarts moyens absolus par mois entre le rayonnement à Paris et Orly sur l'année 2013

Indicateur	MAE	MAE	MAE	MAE	MAE	MAE	MAE	MAE	MAE	MAE	MAE	MAE
Mois	01	02	03	04	05	06	07	08	09	10	11	12
Écarts entre Paris et Orly (W/m²)	10	20	27	31	34	32	26	21	21	16	7	10

On peut constater (Figure 23 et Figure 24) que la prévision régionale « parfaite » est plus performante que la modélisation directe et même que la modélisation des écarts (les écarts restent cependant proches), contrairement à la modélisation de la température.

Chapitre 2 : Modèles nécessaires à la régulation

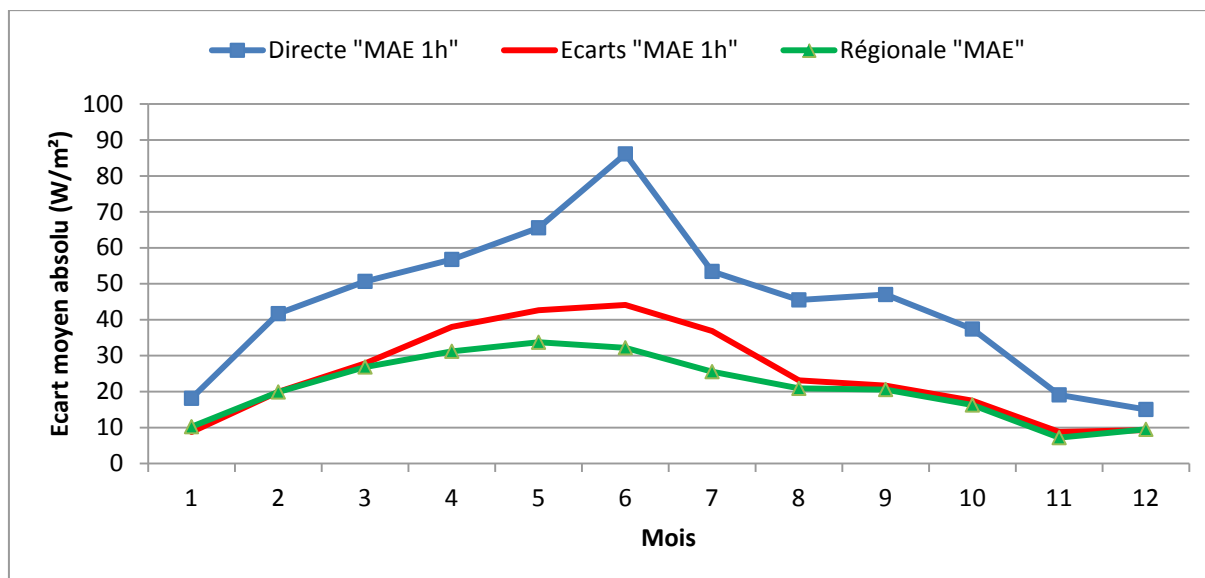


Figure 23 : Résultats des différents types modélisations du rayonnement pour la prévision à 1 h

Ces résultats confirment également l'intérêt de la modélisation des écarts par rapport à la modélisation directe. En effet, cette méthode permet de profiter de la précision des prévisions issues des modèles physiques tout en gardant le caractère local des prévisions météorologiques. Cependant, on constate qu'en ce qui concerne le rayonnement, la modélisation des écarts n'est pas plus performante que la prévision régionale parfaite (la modélisation des écarts n'apporte pas plus de précisions quant au rayonnement local que les prévisions régionales). Dans ce cas d'étude, la modélisation des écarts pour le rayonnement ne présente donc pas d'intérêt par rapport à la prévision régionale. Il faut cependant rappeler qu'il ne s'agit pas de mesures de rayonnement, mais d'estimations obtenues à partir d'observations par satellite.

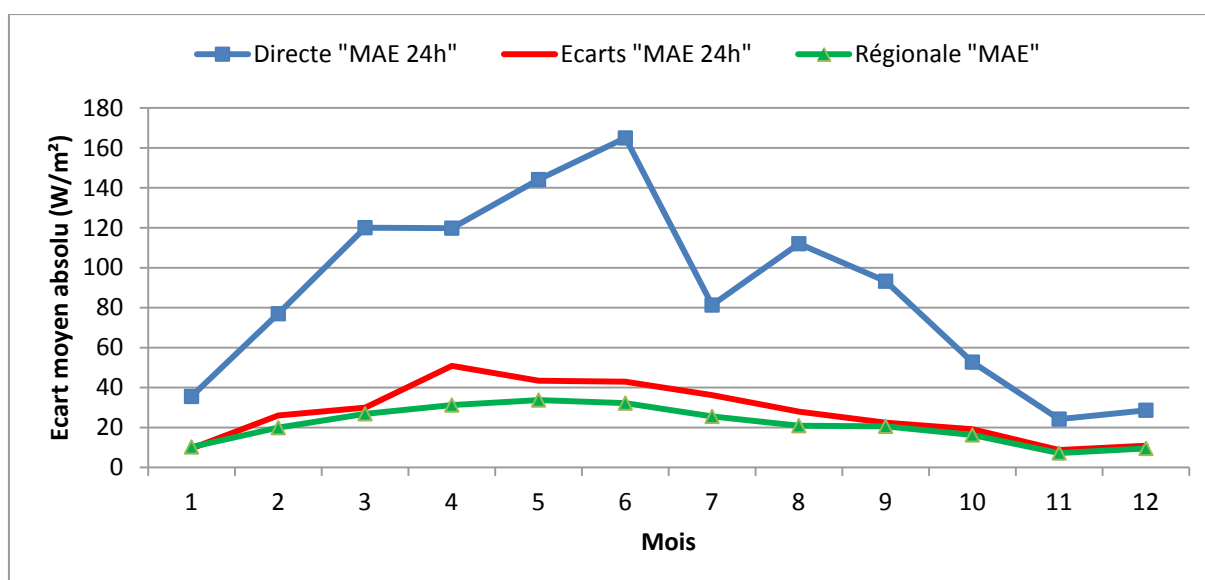


Figure 24 : Résultats des différents types modélisations du rayonnement pour la prévision à 24 h

4.5 Conclusion

L'objectif de cette étude était de développer une méthode de prévision à court terme de variables climatiques locales. Un état de l'art sur la modélisation des conditions climatiques a permis d'identifier les deux principales grandeurs à modéliser (la température extérieure et le rayonnement solaire) ainsi que les modèles, physiques ou mathématiques, les plus couramment utilisés. Suite à cette étude bibliographique, les modèles ARMA ont été choisis pour modéliser les conditions climatiques locales, et leur fonctionnement a été présenté.

Deux méthodes de modélisation ont été proposées : la modélisation directe des variables climatiques et la modélisation des écarts (ou contextualisation). La première méthode repose sur l'utilisation de l'historique des données météorologiques d'une station pour prévoir l'évolution des deux variables climatiques. La deuxième méthode repose quant à elle sur la modélisation de l'écart entre deux stations (une station dont on souhaite calculer les prévisions météorologiques, et une autre dont on dispose des prévisions météorologiques fournies par Météo France). Cette méthode a pour avantage de s'appuyer sur la précision des données issues des modèles physiques (Météo France) tout en gardant le caractère local des prévisions météorologiques.

Pour la prévision de la température, les résultats ont montré une plus grande précision concernant la modélisation des écarts pour des horizons de prévision supérieurs à trois heures. Par exemple, l'erreur moyenne absolue de prévision à $h + 24$ obtenue par la modélisation des écarts est en moyenne de $1,09^{\circ}\text{C}$ sur l'ensemble de l'année, alors qu'elle est de $2,09^{\circ}\text{C}$ pour la modélisation directe. Cependant, pour des horizons de prévision inférieurs à trois heures, la modélisation directe présente de meilleurs résultats. Ainsi, pour la prévision de la température à $h + 1$ l'erreur moyenne absolue sur l'année est de $0,36^{\circ}\text{C}$ pour la modélisation directe et $0,51^{\circ}\text{C}$ pour la modélisation des écarts. Concernant la prévision du rayonnement solaire, les performances de la modélisation des écarts sont supérieures à celles de la modélisation directe, et cela pour tous les horizons. Par exemple, l'erreur moyenne absolue de prévision à $h + 24$ sur les 12 mois est de 27 W/m^2 pour la modélisation des écarts alors qu'elle est de 88 W/m^2 pour la modélisation directe.

Les résultats ont ensuite été comparés à ceux obtenus en considérant une prévision locale identique à la prévision régionale (prévision régionale « parfaite »). Pour la modélisation de la température, la modélisation des écarts montre une plus grande précision que la prévision régionale. Concernant la modélisation du rayonnement solaire, la précision de la modélisation des écarts est légèrement inférieure à celle de la prévision régionale. Il faut cependant rappeler que les mesures du rayonnement sont issues d'observations par satellite.

Ces résultats confirment l'intérêt de modéliser les écarts entre deux stations (en particulier pour la température, dans une moindre mesure pour le rayonnement solaire) pour s'appuyer sur la précision des prévisions météorologiques fournies par les modèles physiques. De plus, cette méthode ne nécessite pas de supercalculateurs (contrairement aux modèles physiques) pour créer un modèle du climat local. Dans le cadre de la gestion énergétique des bâtiments, il est intéressant d'identifier les

conséquences de la précision des prévisions météorologiques sur la stratégie de régulation optimale. Par conséquent, les erreurs de prévisions de la température et du rayonnement obtenues respectivement par la modélisation des écarts et la prévision régionale seront utilisées pour évaluer la robustesse des stratégies de régulation (chapitre 4).

5. CONCLUSION DU CHAPITRE

Dans ce chapitre, les principaux modèles nécessaires à la mise en place d'une régulation ont été présentés. Le modèle thermique dynamique du bâtiment COMFIE sera utilisé. Ce dernier repose sur une modélisation multizone couplée à une réduction modale permettant une bonne précision ainsi que des temps de calculs réduits. La simulation de ce modèle de bâtiment nécessite de connaître les sollicitations auxquelles le bâtiment est soumis, telles que l'occupation et le climat. Ainsi, la prise en compte de l'occupation par des scénarios prédéfinis reposera sur une approche déterministe en considérant une zone de confort thermique définie par une température minimale et maximale. Le système de chauffage électrique sera quant à lui directement intégré dans le modèle du bâtiment. Concernant le climat, un cas idéal où les données météorologiques seront connues par avance avec exactitude permettra de développer des stratégies de régulation. Un modèle de prévision météorologique local sera ensuite utilisé pour évaluer la robustesse des stratégies de régulation développées ainsi que l'impact des erreurs de prévision sur la régulation, en prenant en compte les résultats obtenus par la modélisation des écarts pour la prévision de la température, et ceux obtenus par la prévision régionale (observations par satellite) pour la prévision du rayonnement.

Les modèles numériques et la simulation fournissent des outils pour appréhender le comportement du bâtiment. Mais des écarts subsistent entre les performances énergétiques prévues par la simulation et les consommations réelles. Il est alors nécessaire, dans le but de calculer les stratégies de gestion énergétique les plus performantes possibles, de calibrer le modèle de bâtiment à partir de relevés in situ. Ainsi, nous nous intéresserons dans le chapitre 3 aux méthodes de calibrage de modèle.

Chapitre 3

Calibrage de modèle

Un écart important peut être constaté entre les performances énergétiques prévues par la simulation et les consommations réelles. Le calibrage du modèle de bâtiment à partir de relevés in situ est alors indispensable pour s'assurer de disposer d'un modèle fiable permettant de calculer les stratégies de gestion énergétique les plus performantes possibles. Ce chapitre a pour objectif de présenter une nouvelle méthodologie de calibrage de modèle. Nous en présenterons les principes généraux, avant de nous intéresser tout particulièrement au calibrage bayésien. Enfin, une nouvelle méthodologie sera exposée et testée sur un cas d'application.

PLAN DU CHAPITRE 3

1.	<u>LE CALIBRAGE DE MODÈLE</u>	99
1.1	LES LOGICIELS DE SIMULATION THERMIQUE DYNAMIQUE	99
1.2	LES STANDARDS INTERNATIONAUX	100
1.3	LES INCERTITUDES DANS LE BÂTIMENT	101
1.4	LES DIFFÉRENTES MÉTHODES DE CALIBRAGE EXISTANTES	102
1.4.1	LES MÉTHODES HEURISTIQUES	102
1.4.2	LES MÉTHODES AVANCÉES	102
1.4.3	LES MÉTHODES BAYÉSIENNES	103
2.	<u>LE CALIBRAGE BAYÉSIEN</u>	103
2.1	INTRODUCTION : L'APPROCHE STATISTIQUE	103
2.2	LES MÉTHODES MCMC	105
2.3	LES MÉTHODES MCMC UTILISANT UN MÉTAMODÈLE	106
2.4	LE CALCUL BAYÉSIEN APPROCHÉ	108
2.4.1	PRINCIPE	108
2.4.2	INTERPRÉTATION DE L'ALGORITHME DE REJET APPROXIMATIF	109
2.4.3	LES ALGORITHMES ABC-MCMC	111
2.4.4	LES ALGORITHMES ABC-SMC	111
3.	<u>MÉTHODOLOGIE</u>	113
3.1	ÉTAPE 1 : RÉCUPÉRATION DES DONNÉES	113
3.2	ÉTAPE 2 : CRÉATION DU MODÈLE	114
3.3	ÉTAPE 3 : ANALYSE DE SENSIBILITÉ	114
3.3.1	PLAN D'ÉCHANTILLONNAGE DE LA MÉTHODE DE CIBLAGE	114
3.3.2	CALCUL DES INDICES POUR L'ANALYSE DE SENSIBILITÉ	115
3.4	ÉTAPE 4 : CALIBRAGE DU MODÈLE	116
3.5	ÉTAPE 5 : ÉVALUATION DES RÉSULTATS	117
3.5.1	PROPAGATION DES INCERTITUDES	117
3.5.2	ÉVALUATION DE L'EFFICACITÉ DU CALIBRAGE	118
4.	<u>CAS D'APPLICATION</u>	118
4.1	COLLECTE DES DONNÉES (ÉTAPE 1)	118
4.1.1	PRÉSENTATION DU BÂTIMENT	118

Chapitre 3 : Calibrage de modèle

4.1.2	PROTOCOLE EXPÉRIMENTAL	120
4.2	HYPOTHÈSES DE MODÉLISATION DU BÂTIMENT (ÉTAPE 2)	122
4.2.1	ZONAGE DE LA MAISON	122
4.2.2	DÉBITS DE VENTILATION	123
4.2.3	CONSIGNES DE TEMPÉRATURE	123
4.2.4	INFILTRATIONS	123
4.2.5	PONTS THERMIQUES	123
4.2.6	PUISSANCE DISSIPÉE PAR LES SYSTÈMES	123
4.2.7	OCCULTATION DES VITRAGES	123
4.2.8	ÉTATS DE SURFACE	124
4.2.9	MASQUES PROCHES	124
4.2.10	ALBÉDO	124
4.2.11	INITIALISATION DE LA SIMULATION	124
4.3	ANALYSE DE SENSIBILITÉ : MÉTHODE DE MORRIS (ÉTAPE 3)	124
4.4	CALIBRAGE DU MODÈLE (ÉTAPE 4)	128
4.5	EVALUATION DES RÉSULTATS (ÉTAPE 5)	132
5.	<u>CONCLUSION DU CHAPITRE</u>	<u>138</u>

1. LE CALIBRAGE DE MODÈLE

1.1 Les logiciels de simulation thermique dynamique

La simulation numérique est un outil utilisé dans de nombreux domaines de recherche et développement tels que la mécanique, la mécanique des fluides ou en encore la climatologie. Elle a pour objectif de représenter un phénomène physique réel et permet d'étudier son fonctionnement ainsi que de prédire son évolution.

Dans le cadre du bâtiment, les outils de simulation étaient initialement utilisés lors de la phase de conception. Les logiciels de simulation thermique dynamique permettaient alors d'optimiser l'enveloppe et de dimensionner les équipements du bâtiment.

Cependant, dans le contexte du suivi et de l'évaluation des performances énergétiques des bâtiments existants, leur utilisation s'est étendue à d'autres phases de vie du bâtiment. Ces logiciels peuvent ainsi être employés pour réaliser des audits énergétiques, garantir la performance énergétique des bâtiments, mettre au point les systèmes de régulation ou encore évaluer économiquement et techniquement les rénovations énergétiques envisagées (Coakley et al. 2011).

Les modèles utilisés dans les logiciels de simulation énergétique des bâtiments étant des modèles physiques (modèle de type boîte blanche), ils présentent l'avantage de permettre des variations paramétriques. En particulier, l'utilisateur peut modifier l'enveloppe ou le fonctionnement d'un bâtiment et évaluer directement l'impact de ces modifications sur les performances et le comportement de ce bâtiment.

Cependant, le développement d'un modèle fiable nécessite de connaître précisément le bâtiment à modéliser (géométrie du bâtiment, systèmes installés), et de renseigner de nombreux paramètres (qui peuvent être difficilement accessibles ou mesurables). Ainsi, plusieurs études ont souligné les différences qui peuvent exister entre les performances prévues par le modèle et les mesures sur le terrain (Ahmad et Culp 2006 ; C. Turner et Frankel 2008). En effet, étant donné la complexité des bâtiments et les nombreux paramètres incertains à renseigner, il est difficile d'obtenir une modélisation précise du comportement réel de ces bâtiments. Il devient ainsi indispensable de calibrer ces modèles pour assurer la fiabilité de leurs prédictions. En conciliant mesures in-situ et sorties du modèle, l'objectif est alors d'obtenir une représentation plus fiable et plus précise du comportement réel du bâtiment. Plus précisément, il s'agit de résoudre le problème inverse suivant : « à partir de données d'observations, estimer les paramètres du modèle qui expliquent ces données d'observations ».

Le calibrage de modèle présente plusieurs difficultés. Tout d'abord, le problème inverse posé est fortement sous-déterminé, c'est-à-dire que sa résolution amène à une multitude de solutions au lieu d'une solution unique. De plus, le calibrage des logiciels de simulation énergétique nécessite

l'identification de centaines de paramètres. Enfin, il n'existe pas une méthodologie clairement établie et suivie par l'ensemble de la communauté. Ainsi, les approches où l'utilisateur règle manuellement les différents paramètres jusqu'à ce qu'un critère de précision soit atteint sont couramment utilisées (Coakley et al. 2014). Cependant, différents standards internationaux suggèrent l'utilisation du calibrage de modèle et proposent quelques bonnes pratiques à suivre.

1.2 Les standards internationaux

Plusieurs standards internationaux fournissent les orientations à suivre pour mettre en place un plan de mesure et de vérification de la performance énergétique d'un bâtiment. On peut citer par exemple :

- le protocole IPMVP (*International Performance Measurement and Verification Protocol*) (EVO 2009) ;
- l'ASHRAE Guideline 14-2002 (ASHRAE 2002).

Ces protocoles proposent, entre autres, l'utilisation de la simulation numérique pour calculer les gains réalisés suite à la mise en œuvre de solutions d'efficacité énergétique. Par exemple, l'option D du protocole IPMVP suggère l'utilisation d'un modèle de bâtiment calibré sur des données mesurées pour évaluer la performance de ces solutions.

L'emploi d'un modèle de simulation nécessite l'utilisation d'indicateurs pour évaluer sa fiabilité par rapport à des données mesurées. Les indicateurs couramment utilisés dans ce contexte par les standards internationaux sont les suivants :

- le biais moyen *MBE* (*Mean Biased Error*) (%) : entre les données mesurées et les données simulées.

$$MBE(\%) = \frac{\sum_{i=1}^N (m_i - s_i)}{\sum_{i=1}^N (m_i)} \quad (3.1)$$

où m_i et s_i sont respectivement les données mesurées et simulées à chaque instant i et N le nombre de pas de temps considérés ($N = 12$ si l'on souhaite calibrer le modèle sur des données mensuelles et $N = 8760$ si l'on utilise des données horaires).

- le coefficient de variation de l'erreur quadratique moyenne *CVRMSE* (*Coefficient of Variation of Root Mean Square Error*) : permettant d'évaluer l'ajustement du modèle aux données mesurées sans la compensation des erreurs.

$$CVRMSE(\%) = \frac{\sqrt{(\sum_{i=1}^N (m_i - s_i)^2 / N)}}{\bar{m}} \quad (3.2)$$

où \bar{m} est la moyenne des données mesurées.

Chapitre 3 : Calibrage de modèle

L'ASHRAE Guideline 14-2002 fournit les critères d'acceptation à atteindre par ces indicateurs pour considérer le modèle comme calibré. Ils sont résumés dans le tableau suivant. Cependant, ces critères ne sont pas applicables lorsque l'on souhaite calibrer le modèle à partir de données de température mesurées.

Tableau 8 : Critères d'acceptation pour le calibrage des modèles

Critères d'acceptation	Critère mensuel (%)		Critère horaire (%)	
	<i>MBE</i>	<i>CVRMSE</i>	<i>MBE</i>	<i>CVRMSE</i>
ASHRAE Guideline 14-2002	5	15	10	30

Il est à noter que le modèle calibré respectant ces critères n'est pas unique et que, par conséquent, il peut exister plusieurs modèles d'un même bâtiment considérés comme calibrés.

1.3 Les incertitudes dans le bâtiment

Les sorties des logiciels de simulation thermique dynamique sont soumises à de nombreuses incertitudes qu'il est indispensable de prendre en compte. Ainsi, de nombreuses études se sont portées sur l'évaluation de l'impact des incertitudes sur les sorties des logiciels de simulation thermique dynamique (Lomas et Eppel 1992 ; Macdonald 2002). Cette évaluation permet d'expliquer les différences pouvant exister entre la simulation et les mesures. Par exemple, Spitz (2012) dresse dans sa thèse un aperçu des différentes sources d'incertitudes qui peuvent expliquer ce biais. Par exemple, lors de la phase de conception, de nombreuses incertitudes portent sur le choix du fichier météorologique utilisé, ou encore sur la définition des scénarios d'occupation. D'autres sources d'erreurs sont également possibles lors de la phase de mise en œuvre. Par exemple, une différence peut exister entre les caractéristiques physiques des matériaux choisis lors de la phase de conception et celles des matériaux réellement utilisés. De même, une mauvaise mise en œuvre peut amener à des ponts thermiques plus importants que prévus. Enfin, lors de la phase d'exploitation, un mauvais fonctionnement des systèmes peut également amener à une détérioration des performances.

Ces sources d'incertitudes peuvent être classées en quatre grandes catégories (de Wit et Augenbroe 2002; Coakley et al. 2014) :

- Incertitudes de spécification (des matériaux, des systèmes, de la géométrie) correspondant au manque d'informations sur les propriétés exactes des matériaux utilisés, sur la géométrie du bâtiment ou encore sur le fonctionnement des systèmes énergétiques.
- Incertitudes de modélisation survenant lors du développement du modèle à partir des hypothèses, approximations et simplifications considérées (zonage, simplification de la géométrie, phénomènes physiques simplifiés ou négligés, etc.).
- Incertitudes de simulation introduites lors de la discrétisation et de la résolution numérique du modèle.

- Incertitudes sur les sollicitations et les scénarios correspondant à la définition des différents scénarios d'usage ainsi que des conditions environnementales.

1.4 Les différentes méthodes de calibrage existantes

De nombreuses méthodes de calibrage existent dans la littérature. Il est possible de les classer en trois grandes familles (Heo et al. 2014). Un état de l'art complet sur les différentes méthodes existantes dans la littérature a été réalisé par Coakley et al. (2014)

1.4.1 Les méthodes heuristiques

Les méthodes heuristiques correspondent aux méthodes ne prenant pas en compte les incertitudes existant dans les logiciels de simulation thermique dynamique. L'objectif de ces méthodes consiste à calibrer manuellement les différents paramètres du modèle jusqu'à respecter un critère de précision désiré (Pedrini et al. 2002). Le processus de calibrage nécessite une expertise non négligeable de l'utilisateur pour sélectionner les paramètres à calibrer et les valeurs des paramètres à tester. Par exemple, ces méthodes peuvent reposer sur une analyse graphique (utilisation d'histogrammes) pour comparer les résultats de la simulation aux mesures (Bou-Saada et Haberl 1995 ; McCray et al. 1995).

1.4.2 Les méthodes avancées

Des études plus récentes prennent en compte les incertitudes des paramètres du modèle dans le processus de calibrage. Les paramètres à calibrer sont alors affectés d'une borne d'incertitudes et d'une estimation la plus probable de leur valeur. Des techniques de type Monte-Carlo sont ensuite utilisées pour propager ces incertitudes et déterminer un ensemble de solutions respectant un critère de précision donné. Ainsi, le processus de calibrage ne calcule plus une solution unique pour les différents paramètres à calibrer, mais un ensemble de solutions (Reddy et al. 2007). Des techniques d'analyse de sensibilité peuvent également être utilisées pour déterminer les paramètres les plus influents dans le modèle, réduire le nombre de paramètres à calibrer et ainsi affiner leurs distributions de probabilités. Ces méthodes sont indispensables par exemple pour évaluer avec plus de confiance les solutions de rénovation énergétique envisagées.

Plus récemment, Raftery et al. (2011) ont suggéré une méthodologie appelée « *Evidence-based calibration* » qui consiste en un processus de calibrage à partir de données factuelles. Toute modification d'un paramètre doit alors être clairement justifiée dans l'objectif d'améliorer le comportement du modèle. Ainsi, les différentes sources d'information utilisées pour calibrer les paramètres sont hiérarchisées selon leurs origines. Par exemple, une information obtenue à partir d'une mesure sera jugée plus fiable qu'une information tirée d'une documentation. Pour assurer la reproductibilité des résultats, les modifications réalisées lors du processus de calibrage doivent être indiquées et conservées en mémoire (à l'aide d'un logiciel de gestion de versions par exemple). De

nombreuses études utilisant cette méthode ainsi que des analyses de sensibilité et d'incertitudes peuvent être trouvées dans la littérature (Coakley et al. 2011 ; Bertagnolio et al. 2012 ; Coakley et al. 2012).

1.4.3 Les méthodes bayésiennes

Les méthodes avancées ont l'inconvénient de ne pas considérer l'ensemble des sources d'incertitudes et d'erreurs pouvant expliquer les différences entre les données simulées et les données mesurées. En effet, les erreurs de mesures et les erreurs de modélisation et de simulation ne sont pas considérées dans le processus de calibrage. Une alternative consiste à utiliser des méthodes bayésiennes. Ces dernières ont été employées dans de nombreux domaines pour calibrer des modèles complexes (Pritchard et al. 1999 ; A. E. Raftery et al. 2005 ; Van Oijen et al. 2005 ; Wood 2010). Dans le contexte du bâtiment, l'application du calibrage bayésien à des logiciels de simulation thermique dynamique a été formalisée par Heo et al. (2012). La présentation de ces méthodes fait l'objet de la partie suivante.

2. LE CALIBRAGE BAYÉSIEN

2.1 Introduction : l'approche statistique

Le calibrage bayésien s'inscrit dans le cadre de l'approche statistique du calibrage où les incertitudes pesant sur les paramètres à calibrer sont modélisées par des distributions de probabilité *a priori* (ou PDF pour *probability density function*). L'objectif est alors d'affiner ces distributions de probabilité en comparant les sorties du modèle numérique avec des mesures *in situ*. Des distributions de probabilité *a posteriori* des paramètres sont alors estimées. Cette approche statistique se différencie de l'approche classique (ou non statistique) où l'objectif est d'estimer une valeur unique pour les différents paramètres à calibrer (par la méthode des moindres carrés par exemple).

Dans un processus de calibrage, il est important de distinguer les variables d'entrée des paramètres du modèle (Campbell 2006). Les variables d'entrée, notées « u », correspondent à des données connues (ou au moins observables) et variables dans le temps. Ces variables permettent de décrire et de modéliser différents scénarios observés (par exemple des scénarios météorologiques). Les paramètres du modèle, notés « θ », correspondent quant à eux à des données inconnues mais constantes, et sont modélisés par des distributions de probabilité *a priori* représentant l'incertitude épistémique (dû à un manque de connaissance) pesant sur ces paramètres. Ces derniers sont ainsi supposés invariables sur l'ensemble de la simulation. Cette distinction n'est pas importante dans une analyse de sensibilité mais indispensable dans un processus de calibrage où seuls les paramètres du modèle, et non les variables d'entrée, sont à calibrer.

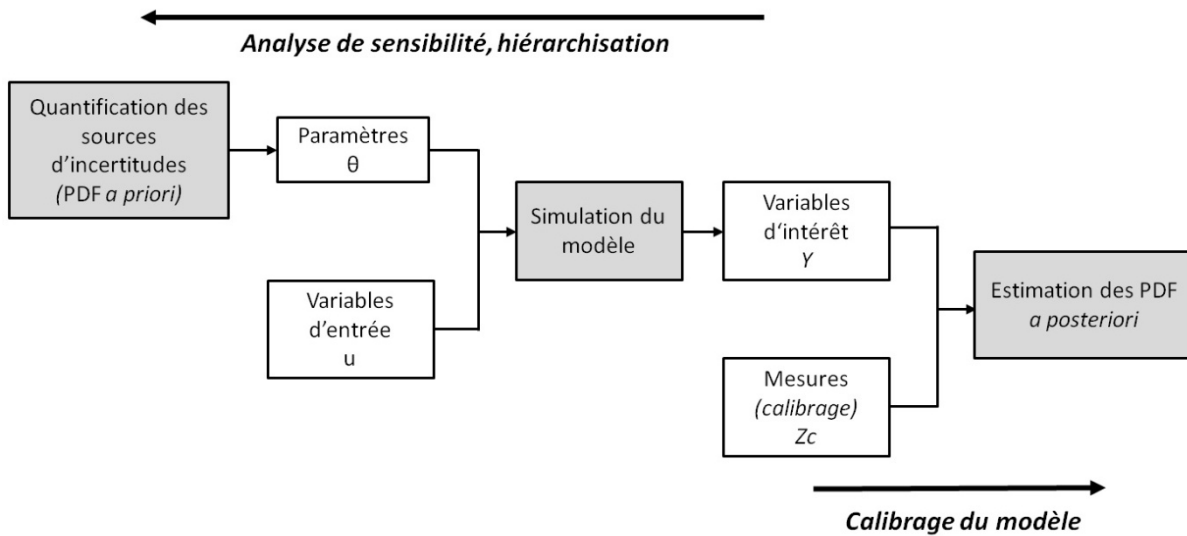


Figure 25 : Représentation de l'analyse de sensibilité et du calibrage de modèle

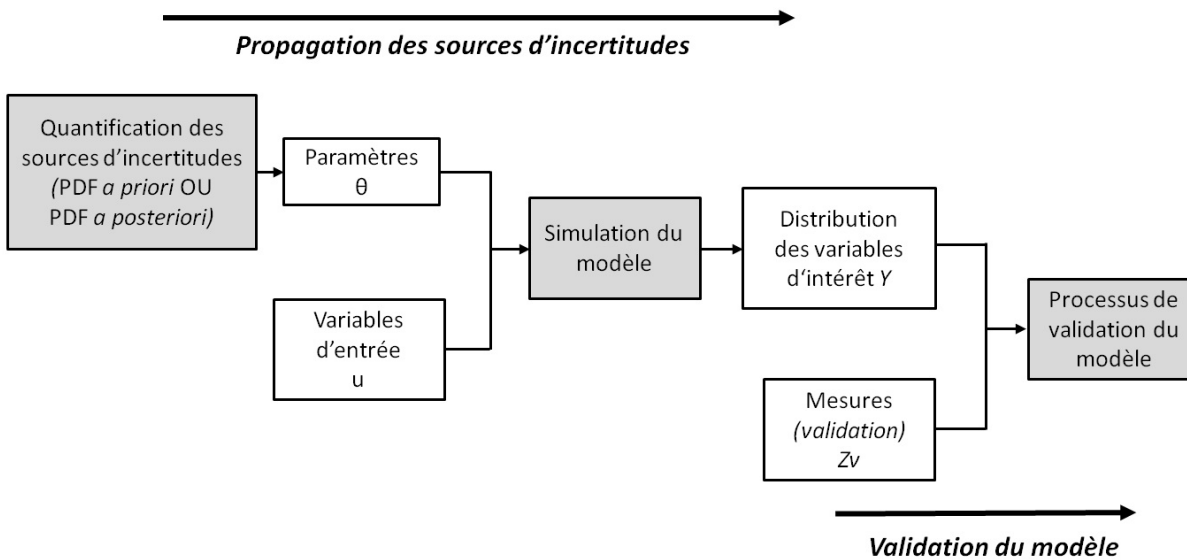


Figure 26 : Représentation de la propagation des incertitudes et de la validation de modèle

De nombreuses méthodes, intimement liées, peuvent être utilisées pour étudier un modèle numérique. Une étape importante correspond à l'analyse de sensibilité (Figure 25). Son objectif est d'identifier les paramètres du modèle et les variables d'entrée qui ont une influence forte sur les sorties du modèle. Cette analyse permet ainsi de hiérarchiser les différents paramètres et variables et d'orienter, par exemple, les campagnes de mesures à mener (il est inutile de mener une campagne de mesures, potentiellement longue et coûteuse, sur un paramètre non influent).

Ensuite, la méthode de calibrage permet de mettre à jour (dans le contexte bayésien) les fonctions de densité de probabilité des paramètres « θ » à partir d'une comparaison entre les sorties

du modèle et les données expérimentales (observations « Z »). Le processus minimise les écarts dans l'objectif d'améliorer les capacités de prédiction du modèle.

Enfin, une troisième méthode, liée à l'analyse de sensibilité, correspond à l'analyse d'incertitudes. Cette dernière permet, à travers la propagation des différentes sources d'incertitudes, d'estimer la distribution des variables d'intérêt « Y » et de donner des informations sur l'incertitude associée aux prédictions du modèle. Cette méthode est utilisée par exemple dans le cadre plus large de la validation de modèle consistant à quantifier la « confiance » qu'un utilisateur peut avoir dans les capacités prédictives de son modèle en comparaison à un ensemble de données expérimentales. On mesure alors la capacité du modèle numérique à représenter de manière adéquate les phénomènes physiques mesurés.

Dans le processus de calibrage, la mise à jour des distributions de probabilité est réalisée selon le théorème de Bayes qui stipule que la distribution de probabilité *a posteriori*, $p(\theta|Z)$, est proportionnelle au produit de la distribution de probabilité *a priori*, $p(\theta)$, et de la fonction de vraisemblance, $p(Z|\theta)$:

$$p(\theta|Z) = \frac{p(\theta) \times p(Z|\theta)}{p(Z)} \quad (3.3)$$

Le dénominateur $p(Z)$, indépendant de θ , peut être interprété comme un facteur permettant de normer $(\theta|Z)$. La fonction de vraisemblance permet ici de caractériser les sorties du modèle en fonction des valeurs prises par les paramètres « θ ». Elle mesure à quel point les sorties du modèle sont proches des observations « Z » en fonction des paramètres testés. Ainsi, la probabilité d'obtenir les observations à partir du modèle pilote le processus de mise à jour des fonctions de densité de probabilité. Différentes méthodes peuvent être employées pour estimer la distribution *a posteriori*, $p(\theta|Z)$ et se distinguent selon la connaissance de la fonction de vraisemblance $p(Z|\theta)$.

Tout d'abord, si la fonction de vraisemblance est connue analytiquement, alors des méthodes de Monte-Carlo par Chaînes de Markov ou méthodes MCMC pour *Markov Chain Monte Carlo* peuvent être utilisées (§2.2). Ensuite, si elle n'est pas connue analytiquement mais qu'une approximation analytique peut être obtenue, des méthodes MCMC utilisant des métamodèles peuvent être employées (§2.3). Enfin, si l'obtention d'une expression analytique de la fonction de vraisemblance est impossible, des méthodes basées sur le calcul bayésien approché (ou ABC pour *Approximate Bayesian Computation*) existent (§2.4).

2.2 Les méthodes MCMC

Les méthodes de Monte-Carlo par chaînes de Markov sont couramment utilisées pour estimer la distribution *a posteriori* des paramètres $p(\theta|Z)$ sans avoir à déterminer sa forme analytique. Ces méthodes permettent de générer des échantillons à partir d'une loi de probabilité dont la forme n'est pas connue complètement de manière analytique (la loi est connue à une constante près). Plus précisément dans l'équation (3.3), la distribution de probabilité *a priori*, $p(\theta)$, et la fonction de

vraisemblance, $p(Z|\theta)$ sont connues, tandis que le dénominateur $p(Z)$ est inconnu mais peut être considéré comme une constante puisque ne dépendant pas de θ .

Dans le cadre de l'estimation bayésienne, un algorithme MCMC est une méthode itérative qui propose de construire une chaîne de Markov convergeant vers la loi *a posteriori*, $p(\theta|Z)$. Une chaîne de Markov est un processus stochastique qui vérifie les conditions de Markov selon lesquelles toute l'information nécessaire pour prévoir l'état futur est contenue dans l'état présent du processus. Il existe de nombreux algorithmes MCMC dont le plus couramment utilisé est l'algorithme de Metropolis-Hastings. La première étape consiste à tirer une valeur initiale θ_0 de la distribution *a priori*, $p(\theta)$. On va ensuite tirer aléatoirement un candidat θ^* dans une distribution $q(\cdot|\theta_0)$ conditionnée par θ_0 (par exemple une loi normale centrée en θ_0 et de variance σ^2). Selon une probabilité dépendant de la vraisemblance (appelé ratio d'acceptation-rejet, ou probabilité d'acceptation), le candidat θ^* est accepté (on pose alors $\theta_1 = \theta^*$) ou rejeté (on pose alors $\theta_1 = \theta_0$). Cette procédure est enfin répétée jusqu'à obtenir une chaîne de valeur $\{\theta_0, \theta_1, \dots, \theta_n\}$ qu'on peut supposer être un échantillon de la distribution *a posteriori*, $p(\theta|Z)$.

Les algorithmes MCMC peuvent être très efficaces pour estimer la distribution *a posteriori*, $p(\theta|Z)$, mais ils nécessitent la connaissance de la fonction de vraisemblance, ce qui est difficile voire impossible dans le cas des modèles numériques complexes (comme les logiciels de simulation thermique dynamique). L'utilisation d'un métamodèle pour approximer l'expression analytique de la fonction de vraisemblance peut alors être une solution.

2.3 Les méthodes MCMC utilisant un métamodèle

Le calibrage bayésien par métamodèle repose sur l'approche développée par Kennedy et O'Hagan (2001) permettant de relier les observations aux sorties du modèle. Cette approche prend en compte trois types d'erreurs : les incertitudes pesant sur les paramètres du modèle, l'écart existant entre les sorties du modèle et la réalité, et les erreurs de mesure. Ainsi, la relation entre les observations et les sorties du modèle dans les conditions connues u peut être modélisée par :

$$Z = \eta(u, \theta) + \delta(u) + e(u) \quad (3.4)$$

où Z sont les observations, $\eta(u, \theta)$ correspond aux sorties du modèle calculées avec les conditions connues u et les paramètres de calibrage θ , et $e(u)$ l'erreur de mesure. L'erreur de modèle $\delta(u)$ permet de modéliser l'écart existant entre les sorties du modèle et la réalité. En effet, les logiciels de simulation (et en particulier les logiciels de simulation thermique dynamique) sont basés sur des approximations des phénomènes physiques et sont donc incapables de reproduire fidèlement la réalité même en balayant l'ensemble des valeurs de θ possibles. Par conséquent, l'erreur de modèle est indépendante des paramètres de calibrage. L'objectif du calibrage est de mettre à jour les fonctions de densité de probabilité *a priori* des paramètres θ en comparant les prédictions du modèle et les observations (Campbell 2006).

Chapitre 3 : Calibrage de modèle

Une remarque peut être faite quant aux méthodes avancées présentées dans le §1.4.2. Ces dernières comparent les sorties du modèle avec les observations pour définir une distribution de solutions concernant les paramètres à calibrer. Ces méthodes peuvent alors être considérées comme des méthodes de calibrage statistique. En effet, même si elles ne définissent pas clairement la relation qui existe entre les observations, la réalité et les sorties du modèle, cela ne signifie pas qu'il n'existe pas un tel modèle implicite. Généralement, le modèle correspond à l'équation (3.4) sans le modèle d'erreur $\delta(u)$ (ou de manière équivalente, en considérant que l'espérance de $\delta(u)$ pour tout u est nulle). Ainsi, le modèle sous-jacent est en général :

$$Z = \eta(u, \theta) + e'(u) \quad (3.5)$$

où $e'(u)$ ne correspond plus simplement à une erreur de mesure, mais à une erreur de moyenne nulle incluant d'autres sources d'erreur.

Dans l'objectif d'estimer la fonction de vraisemblance, Kennedy et O'Hagan (2001) proposent d'utiliser des processus gaussien pour modéliser les sorties du modèle $\eta(u, \theta)$ et l'erreur de modèle $\delta(u)$. Un processus aléatoire $f(\cdot)$ est un processus gaussien si la distribution jointe de $f(s_1), \dots, f(s_n)$ est une loi normale multidimensionnelle. Un processus gaussien a de plus la propriété d'être entièrement caractérisé par sa moyenne et sa fonction de covariance :

$$f(s) \sim PG(m(s), c(s, s')) \quad (3.6)$$

où $m(s) = E[f(s)]$ et $c(s, s') = Cov(f(s), f(s'))$.

Ainsi la sortie du logiciel de simulation énergétique sous des conditions connues et des paramètres de calibrage choisis est supposée suivre une distribution normale (bien qu'elle soit déterministe) (Heo et al. 2014). Les sorties du logiciel sous différentes conditions suivent alors une loi normale multidimensionnelle avec une structure de covariance spécifique. Il en est de même pour la modélisation de l'erreur de modèle. La définition de ces processus gaussien implique l'utilisation d'hyper-paramètres dans les matrices de covariance qui doivent également être identifiés. Les détails sur la définition des structures de covariance et l'identification des hyper-paramètres sont résumés dans Kennedy et O'Hagan (2001). Cette formulation mathématique permet alors de calculer la fonction de vraisemblance $p(Z|\theta)$ pour n'importe quelle valeur de θ testée (Riddle et Muehleisen 2014). En utilisant le théorème de Bayes, il est ainsi possible de mettre à jour les distributions *a priori* des paramètres à calibrer en prenant en compte l'erreur de modèle et les erreurs de mesure. Comme la distribution *a posteriori* ne peut être calculée complètement analytiquement ($p(Z)$ est inconnue), des méthodes de Monte-Carlo par chaîne de Markov (§2.2) peuvent être utilisées pour approximer numériquement cette distribution (Campbell 2006 ; Heo et al. 2012 ; Riddle et Muehleisen 2014).

Dans le contexte du bâtiment, cette méthodologie a été appliquée avec succès par Heo dans ses travaux de thèse (Heo 2011). L'objectif était de développer une méthodologie pour calibrer les logiciels de simulation énergétique des bâtiments en limitant l'utilisation du jugement expert dans le processus de calibrage. Appliquée dans le cadre de l'évaluation de l'efficacité des solutions de rénovation énergétique, cette méthodologie repose sur les étapes suivantes (Heo et al. 2014) :

Chapitre 3 : Calibrage de modèle

- quantifier les sources d'incertitudes et déterminer les distributions *a priori* des paramètres à calibrer ;
- réaliser un criblage pour déterminer les paramètres les plus influents ;
- explorer l'espace des entrées des paramètres à calibrer et générer les sorties associées ;
- estimer les distributions *a posteriori* des paramètres par le calibrage bayésien ;
- valider statistiquement le modèle calibré.

Les auteurs ont démontré l'intérêt de l'utilisation du calibrage bayésien pour la prise en compte des incertitudes dans le processus de calibrage. Cette méthodologie permet d'automatiser le processus, de quantifier le risque lié à chaque décision de rénovation énergétique et de limiter l'utilisation du jugement expert. Cependant, ce processus de calibrage repose sur une formulation mathématique sophistiquée, nécessitant des développements informatiques conséquents et un changement de paradigme par rapport aux méthodes de calibrage classiques. De plus, cette méthode ne s'applique qu'à des données énergétiques agrégées (comme des consommations mensuelles) qui ne tiennent pas compte des corrélations temporelles dans les données (Heo et al. 2014). Par conséquent, son extension à des mesures horaires de température n'est pour l'instant pas possible. Or, dans le cadre de la régulation, nous souhaitons améliorer la précision de notre modèle concernant la simulation des températures horaires des zones de notre bâtiment. Une alternative consiste alors à utiliser une autre méthode, le calcul bayésien approché (ou ABC), utilisant uniquement les simulations numériques pour réaliser l'inférence et pouvant s'appliquer à des séries temporelles.

2.4 Le calcul bayésien approché

2.4.1 Principe

Le calcul bayésien approché (ABC) rassemble l'ensemble des algorithmes développés ne nécessitant pas l'évaluation explicite de la fonction de vraisemblance pour réaliser l'inférence bayésienne (*likelihood-free inference*). Ces méthodes sont particulièrement intéressantes dans le cadre des logiciels de simulation numérique où la fonction de vraisemblance n'est pas connue. Originellement développé par Pritchard et al. (1999), le calcul bayésien approché permet de réaliser l'inférence bayésienne en n'utilisant que les simulations générées par le modèle sans requérir à l'évaluation de la fonction de vraisemblance.

Le premier algorithme ABC se base sur l'algorithme de rejet et se comporte comme suit (algorithme de rejet approximatif) :

1. tirer aléatoirement θ^* de la distribution a priori $p(\theta)$ ($\theta^* \sim p(\theta)$) ;
2. simuler le modèle en fonction de θ^* et générer les variables d'intérêt Y ($Y \sim \eta(u, \theta^*)$) ;

Chapitre 3 : Calibrage de modèle

- accepter θ^* si la distance entre les données simulées Y et les données observées Z est inférieure à un seuil cible ϵ_c ($\rho(Y, Z) \leq \epsilon_c$).

La Figure 27 illustre le fonctionnement de l'algorithme de rejet approximatif. Il est important de noter ici que l'ensemble des paramètres acceptés θ^* n'appartiennent pas à la véritable distribution de probabilité *a posteriori* $p(\theta|Z)$ mais à une approximation de cette dernière $p(\theta|\rho(Y, Z) \leq \epsilon_c)$. Lorsque $\epsilon_c = 0$, cet algorithme donne des résultats exacts et permet de tirer des paramètres dans la véritable distribution *a posteriori* $p(\theta|Z)$. A l'opposé, si $\epsilon_c \rightarrow +\infty$, les paramètres sont alors tirés dans la distribution *a priori* $p(\theta)$. Ainsi, la distribution *a posteriori* sera d'autant mieux approximée que la valeur de ϵ_c sera petite, mais engendrera un taux de rejet plus important à l'étape 3 de l'algorithme et donc des temps de calcul plus importants pour une taille d'échantillon voulue. Le seuil cible ϵ_c représente donc un compromis entre précision et temps de calcul.

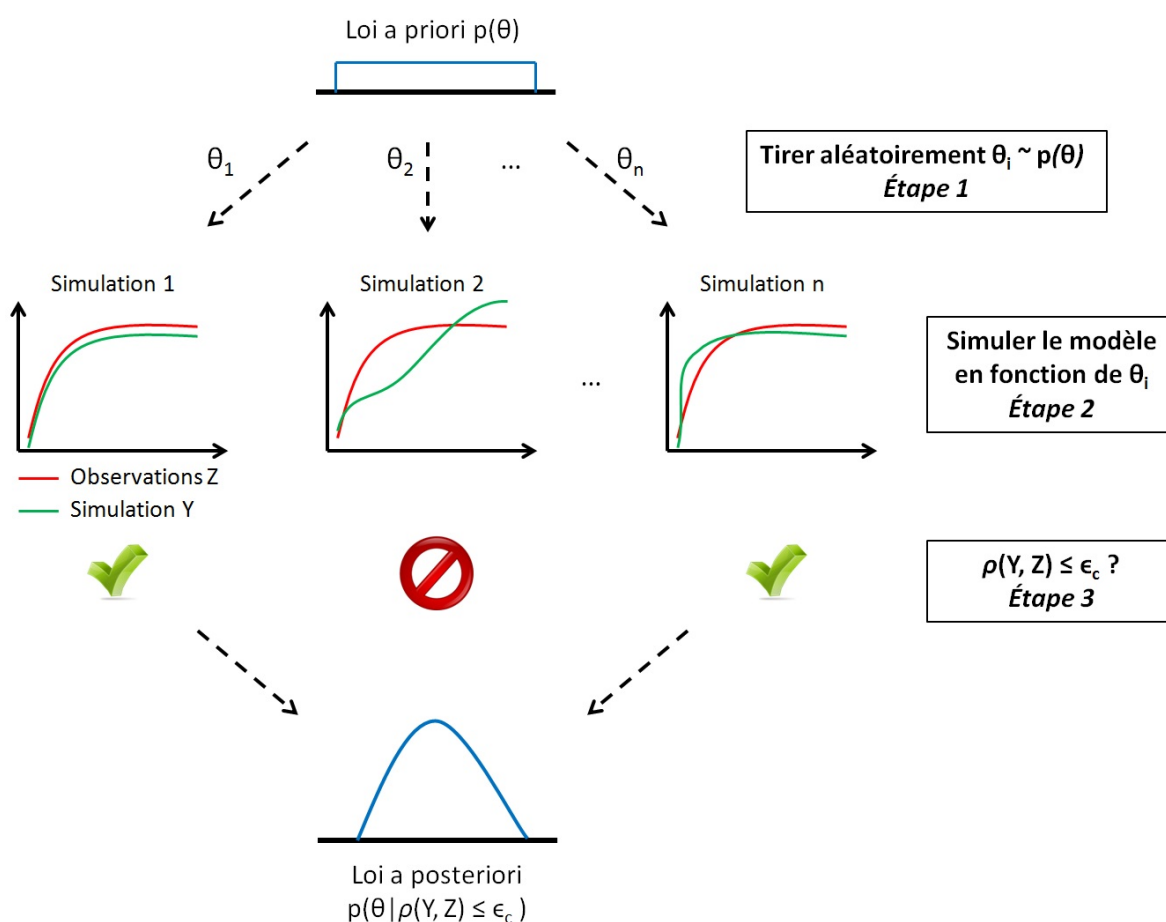


Figure 27 : Principe de l'algorithme de rejet approximatif

2.4.2 Interprétation de l'algorithme de rejet approximatif

Wilkinson (2013) a démontré que l'algorithme de rejet approximatif pouvait être interprété comme réalisant l'inférence exacte en présence d'une erreur de modèle (ou de mesure) uniforme. Plus précisément, il est possible de considérer que la distribution *a posteriori* trouvée par

Chapitre 3 : Calibrage de modèle

l'algorithme peut être interprétée comme la distribution exacte *a posteriori* d'un nouveau modèle où l'on considère en plus une distribution uniforme des termes d'erreur.

L'idée essentielle est de supposer qu'il existe un écart entre la meilleure prédiction possible du modèle et les données mesurées. Cet écart peut alors représenter une erreur de mesure, une erreur de modèle ou encore les deux à la fois. Ainsi, dans l'objectif de relier les sorties du modèles aux mesures, il est important de prendre en compte ce modèle d'erreur lors de l'inférence. Le cadre théorique est donc très proche de celui développé par Kennedy et O'Hagan (2001). On suppose alors que les données mesurées Z correspondent à la simulation du modèle à sa meilleure valeur de paramètre $\hat{\theta}$ (meilleure prédiction possible) plus un terme d'erreur indépendant e (Wilkinson 2013) :

$$Z = \eta(u, \hat{\theta}) + e(u) \quad (3.7)$$

Par exemple, dans l'algorithme de rejet approximatif, si $\rho(Y, Z) = |Y - Z|$, cela revient à supposer que l'erreur e dans l'équation (3.7) suit une loi uniforme sur $[-\epsilon_C, \epsilon_C]$. L'algorithme permet alors de réaliser l'inférence exacte du modèle statistique décrit dans l'équation (3.7) et de déterminer la distribution *a posteriori* $p(\theta|Z, e \sim U[-\epsilon_C, \epsilon_C])$.

Wilkinson (2013) propose alors une généralisation de l'algorithme de rejet approximatif en modélisant la distribution de probabilité de l'erreur e par $p_e(\cdot)$. L'objectif de l'algorithme est de déterminer la distribution *a posteriori* des meilleurs paramètres $\hat{\theta}$, en prenant en compte l'erreur e , les données mesurées Z et la distribution *a priori* des paramètres θ . L'algorithme se déroule comme suit (algorithme de rejet approximatif probabiliste) :

1. tirer aléatoirement $\theta^* \sim p(\theta)$;
2. simuler $Y \sim \eta(u, \theta^*)$;
3. accepter θ^* avec la probabilité $r = \frac{p_e(Z-Y)}{c}$.

La constante c permet de s'assurer que $\frac{p_e(Z-Y)}{c}$ correspond à une probabilité. Cet algorithme est équivalent à l'algorithme de rejet approximatif si l'on suppose que la probabilité d'acceptation correspond à :

$$\frac{p_e(Z-Y)}{c} = \begin{cases} 1 & \text{si } \rho(Y, Z) \leq \epsilon_C \\ 0 & \text{sinon} \end{cases} \quad (3.8)$$

Ainsi, si la distribution de probabilité $p_e(\cdot)$ est modélisée avec attention et qu'elle représente fidèlement l'écart entre le modèle et la réalité, on peut supposer que $\hat{\theta}$ représente la valeur « réelle » (physique) de θ , et que $p(\hat{\theta}|Z, e \sim p_e(\cdot))$ est la distribution *a posteriori* de $\hat{\theta}$ à la lumière des données et du modèle (Wilkinson 2013).

De nombreux algorithmes ont été développés par la suite pour améliorer le taux d'acceptation de l'algorithme de rejet approximatif. Nous présentons dans la suite de ce chapitre les deux principales méthodes : les algorithmes ABC utilisant les méthodes MCMC et les algorithmes ABC s'inspirant des méthodes de Monte-Carlo séquentielles (ou SMC pour *Sequential Monte Carlo*) (Csilléry et al. 2010 ; B. M. Turner et Van Zandt 2012).

2.4.3 Les algorithmes ABC-MCMC

Dans l'objectif de diminuer dans l'algorithme de rejet approximatif le taux de rejet, Marjoram et al. (2003) ont proposé d'utiliser une approche MCMC ne nécessitant pas l'utilisation ou l'évaluation de la fonction de vraisemblance dans le calcul de la probabilité d'acceptation contrairement aux méthodes MCMC classiques.

L'algorithme proposé, reposant sur l'algorithme de Metropolis-Hastings, est alors le suivant :

1. tirer une valeur initiale θ_0 de la distribution *a priori* $p(\theta)$;
2. pour $i = 0, 1, 2, \dots$
 - a) tirer aléatoirement un candidat θ^* dans une distribution $q(\cdot | \theta_i)$ conditionnée par θ_i ;
 - b) simuler $Y \sim \eta(u, \theta^*)$;
 - c) calculer la probabilité d'acceptation :

$$\alpha = \begin{cases} \min \left(1, \frac{p(\theta^*)q(\theta_i | \theta^*)}{p(\theta_i)q(\theta^* | \theta_i)} \right) & \text{si } \rho(Y, Z) \leq \epsilon_c \\ 0 & \text{si } \rho(Y, Z) > \epsilon_c \end{cases}$$

- d) tirer aléatoirement β dans une distribution uniforme sur $[0, 1]$:
 si $\beta < \alpha$, on pose $\theta_{i+1} = \theta^*$, sinon $\theta_{i+1} = \theta_i$.

Le choix de la distribution $q(\cdot)$ est important en pratique pour assurer la convergence de la méthode. En effet, si le « saut » généré dans l'espace des valeurs possibles des paramètres par la distribution $q(\cdot)$ est trop important, cela génèrera des candidats souvent refusés pouvant laisser la chaîne « bloquée », ce qui entraîne un nombre élevé d'itérations. De même, si le « saut » est trop petit, cela amènera la chaîne à bouger trop lentement et donc nécessitera également un nombre important d'itérations. De plus, dans le cas spécifique des algorithmes ABC-MCMC, les candidats doivent satisfaire deux conditions (les candidats doivent tout d'abord respecter la distance minimale entre les données simulées et les données d'observation, et ensuite être acceptés avec une probabilité α) pouvant amener à un taux de rejet des candidats très important. Enfin, l'algorithme ABC-MCMC ne peut être parallélisé pour réduire les temps de calculs (B. M. Turner et Van Zandt 2012). En conséquence, les algorithmes ABC-MCMC ne sont pas retenus pour réaliser le calibrage du modèle de simulation thermique dynamique. D'autres algorithmes reposant sur les méthodes de Monte-Carlo séquentielles peuvent alors être utilisés.

2.4.4 Les algorithmes ABC-SMC

Comme pour les algorithmes ABC-MCMC, l'objectif des algorithmes ABC-SMC est de déterminer N valeurs de paramètres satisfaisant le seuil de tolérance ϵ_c . La démarche développée par ces derniers est de définir une séquence décroissante de seuils de tolérance ($\epsilon_1 \geq \epsilon_2 \geq \dots \geq \epsilon_c$) pour atteindre le seuil de tolérance cible ϵ_c . L'algorithme détermine alors à chaque seuil de tolérance une distribution intermédiaire de N_{ABC} valeurs de paramètres satisfaisant ce seuil de tolérance. Ainsi, au lieu d'explorer l'espace complet des valeurs de paramètres comme dans l'algorithme de rejet

approximatif, ces algorithmes se concentrent sur les parties de l'espace où les valeurs de paramètres ont une grande probabilité de respecter le seuil de tolérance fixé.

Contrairement aux algorithmes ABC-MCMC, les algorithmes ABC-SMC ne travaillent pas sur un seul candidat θ^* à la fois, mais testent un ensemble de candidats (appelés également « particules ») simultanément. Ces particules sont ensuite perturbées et filtrées à chaque itération de l'algorithme, les amenant à se rapprocher de plus en plus de la distribution *a posteriori* recherchée. Par exemple, pour passer de la distribution satisfaisant le seuil de tolérance ϵ_1 à la distribution à ϵ_2 , on va tirer aléatoirement une valeur de paramètre dans la distribution ϵ_1 , puis la faire bouger à l'aide d'un noyau de transition et enfin vérifier si les données simulées avec cette nouvelle valeur de paramètre respectent le seuil de tolérance ϵ_2 . Cependant, ce processus amène à un biais. En effet, les valeurs de paramètre satisfaisant le seuil de tolérance ϵ_2 n'ont pas été tirées dans la distribution *a priori* $p(\theta)$ mais dans la distribution correspondant au seuil de tolérance ϵ_1 . Pour éviter ce biais, on associe à chaque valeur de paramètre un poids ω_i qui est égal à la probabilité que la valeur de paramètre ait été tirée dans la distribution *a priori* divisée par la probabilité que la valeur de paramètre ait été tirée dans la distribution précédente.

La première application de ce type de méthode a été proposée par Sisson et al. (2007) avec l'algorithme ABC-PRC (*Partial Rejection Control*). Cependant, Beaumont et al. (2009) ont démontré que cet algorithme présentait un biais dans l'approximation de la distribution *a posteriori*. Ils ont alors proposé un nouvel algorithme corrigeant ce biais, appelé *Population Monte Carlo ABC* (ABC-PMC). La définition du poids et du noyau de transition (noyau gaussien) utilisés dans l'algorithme ainsi que les démonstrations associées se trouvent dans l'article de Beaumont et al. (2009).

L'algorithme ABC-PMC se déroule comme suit :

Soit une séquence décroissante de seuils de tolérance $\epsilon_1 \geq \epsilon_2 \geq \dots \geq \epsilon_C$

1. A l'itération $j = 1$

Pour $i = 1, \dots, N_{ABC}$,

Répéter

Tirer $\theta_i^{(1)} \sim p(\theta)$ et simuler $Y \sim \eta(x, \theta_i^{(1)})$

jusqu'à $\rho(Y, Z) \leq \epsilon_j$

Poser $\omega_i^{(1)} = 1/N_{ABC}$

fin

Poser σ_1^2 correspondant au double de la variance empirique de $(\theta_i^{(1)})_{1 \leq i \leq N}$

2. A l'itération $2 \leq j \leq C$

Pour $i = 1, \dots, N_{ABC}$,

Répéter

Choisir θ_i^* dans l'ensemble $\theta_j^{(t-1)}$ avec la probabilité $\omega_j^{(t-1)}$

Générer $\theta_i^t | \theta_i^* \sim \mathcal{N}(\theta_i^*, \sigma_t^2)$ ⁶ et simuler $Y \sim \eta(x, \theta_i^t)$

jusqu'à $\rho(Y, Z) \leq \epsilon_j$

⁶ où $\mathcal{N}(\theta_i^*, \sigma_t^2)$ est la loi normale d'espérance θ_i^* et de variance σ_t^2

$$\text{Poser } \omega_i^{(t)} \propto \frac{p(\theta_i^{(t)})}{\sum_{j=1}^N \omega_j^{(t-1)} \sigma_t^{-1} \varphi(\sigma_t^{-1}(\theta_i^{(t)} - \theta_j^{(t-1)}))} \text{ avec } \varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}$$

fin

Poser σ_{t+1}^2 correspondant au double de la variance empirique de $(\theta_i^{(t)})_{1 \leq i \leq N}$

Cet algorithme a l'avantage d'être facilement implémentable, robuste et présente de bons résultats (Beaumont et al. 2009; Lenormand et al. 2013). De plus, il peut être parallélisé permettant ainsi de diminuer fortement les temps de calcul. Par conséquent, cet algorithme sera utilisé dans la méthodologie développée pour calibrer le logiciel de simulation thermique dynamique COMFIE.

3. MÉTHODOLOGIE

Dans ce chapitre, nous souhaitons calibrer le modèle de simulation thermique dynamique à partir de la comparaison des températures horaires simulées par le modèle thermique et des températures mesurées.

La méthodologie développée pour réaliser le calibrage s'inspire de celle développée par Coakley et al. (2011) et se déroule en cinq étapes :

1. récupération de l'ensemble des données disponibles sur le bâtiment ;
2. création du modèle de bâtiment ;
3. analyse de sensibilité ;
4. calibrage du modèle (estimations des PDF *a posteriori*) ;
5. évaluation du modèle calibré.

Ces étapes sont détaillées dans les sections suivantes.

Pour mener à bien le processus de calibrage, les données mesurées à disposition doivent être séparées en données utilisées par l'analyse de sensibilité (étape 3, §3.3) et par le calibrage du modèle (étape 4, §3.4), et en données de validation utilisées pour l'évaluation de l'efficacité du processus de calibrage (étape 5, §3.5).

3.1 Étape 1 : récupération des données

L'objectif de cette étape est de minimiser les incertitudes de spécification dans le processus de calibrage. Pour cela, il est nécessaire de récolter l'ensemble des sources d'information disponibles pour la modélisation du bâtiment. Il peut s'agir par exemple des différents documents décrivant le bâtiment (données de construction, géométrie du bâtiment, propriétés physiques des matériaux), de données de fonctionnement des systèmes, de données mesurées dans le bâtiment (taux d'infiltration par exemple), de données d'occupation (capteurs de présence), de données météorologiques (station météorologique) ou encore de données sur les incertitudes pesant sur les différents paramètres ou les mesures. Il est important que les différentes sources d'information soient répertoriées et classées pour faciliter le suivi de la modélisation.

3.2 Étape 2 : création du modèle

L'objectif de cette étape est de minimiser les incertitudes de modélisation ainsi que les incertitudes pesant sur la définition des sollicitations et des scénarios. Il est important de prêter une attention toute particulière à la modélisation du bâtiment avec le logiciel de simulation thermique dynamique. Les différentes hypothèses de modélisation doivent être clairement identifiées, répertoriées et justifiées. Ces hypothèses peuvent correspondre par exemple à la définition du nombre de zones thermiques, à la modélisation des systèmes énergétiques, à la modélisation des différents scénarios d'usage (privilégier les mesures aux données par défaut) ainsi qu'à la modélisation des sollicitations. Cette étape doit être réalisée de manière itérative pour s'assurer que toutes les données recensées dans l'étape 1 ont été utilisées.

3.3 Étape 3 : analyse de sensibilité

L'objectif de cette étape est de déterminer les paramètres incertains les plus influents dans le modèle de bâtiment. En effet, il est inenvisageable du point de vue du temps de calcul de réaliser le calibrage du modèle en considérant l'ensemble des paramètres incertains. L'objectif de l'analyse de sensibilité est alors d'identifier les paramètres incertains les plus influents qui seront alors retenus pour réaliser le calibrage dans l'étape 4.

Une méthode de criblage peut être utilisée pour déterminer ces paramètres influents. La méthode de Morris (Morris 1991 ; Campolongo et al. 2007) a été retenue car elle ne nécessite pas d'hypothèses sur le modèle, elle est peu coûteuse en temps de calcul et elle permet de prendre en compte les interactions entre les différents paramètres (contrairement aux analyses de sensibilité locales).

La méthode de Morris fait partie des méthodes dites « un-par-un » ou « *one at a time* (OAT) ». En effet, elle réalise d'une part une discrétisation régulière de l'espace des paramètres (ainsi seuls des points appartenant à la grille peuvent être échantillonnés) et d'autre part elle ne fait varier qu'un paramètre à la fois entre les simulations successives pour évaluer l'influence de ces paramètres.

3.3.1 Plan d'échantillonnage de la méthode de criblage

On suppose que notre modèle dispose de K paramètres incertains. On estime tout d'abord l'incertitude pesant sur les différents paramètres en fixant une valeur haute et basse. Ensuite, la gamme de variation de chaque facteur est divisée en Q niveaux $\{0, \frac{1}{Q-1}, \frac{2}{Q-1}, \dots, 1\}$. Cette transformation linéaire permet ainsi de comparer des paramètres de natures différentes. Enfin, l'échantillonnage de la méthode de Morris consiste à répéter r fois une trajectoire aléatoire passant par $K + 1$ nœuds de l'espace discrétisé des paramètres $\hat{\Omega}$ de telle sorte que chaque paramètre ne

Chapitre 3 : Calibrage de modèle

varie qu'une seule fois par trajectoire. Plus précisément, chaque trajectoire doit respecter les propriétés suivantes :

- le nœud de départ est choisi au hasard dans $\widehat{\Omega}$;
- le saut entre deux nœuds successifs de la trajectoire est proportionnel à $\delta = \frac{1}{Q-1}$;
- l'ordre dans lequel les paramètres sont modifiés est tiré de manière aléatoire.

La Figure 28 illustre le fonctionnement de l'échantillonnage dans la méthode de Morris.




Figure 28 : Exemple d'échantillonnage par la méthode de Morris avec $K = 3$ facteurs, $Q = 3$ niveaux, et $r = 3$ trajectoires (a), (b), et (c) (tiré de Munaretto (2014))

Pour garantir l'uniformité dans la distribution des points échantillonnés, Morris propose de choisir une longueur de saut égale à $\Delta = \frac{Q}{2(Q-1)}$ avec un niveau de discrétisation Q pair (Faivre et al. 2013).

3.3.2 Calcul des indices pour l'analyse de sensibilité

Pour chaque trajectoire i , la méthode de Morris calcule un effet élémentaire pour chaque paramètre θ_j correspondant à la variation de la sortie du modèle η entre deux points successifs de la trajectoire (pour simplifier les notations, $\eta(u, \theta)$ est remplacé ici par $\eta(\theta)$) :

$$E_j^{(i)} = \pm \frac{\eta(\theta_1^{(i)}, \dots, \theta_j^{(i)} \pm \Delta, \dots, \theta_K^{(i)}) - \eta(\theta_1^{(i)}, \dots, \theta_j^{(i)}, \dots, \theta_K^{(i)})}{\Delta} \quad (3.9)$$

Une fois les r répétitions réalisées, on détermine :

- la moyenne des effets élémentaires :

$$\mu_j = \frac{1}{r} \sum_{i=1}^r E_j^{(i)} \quad (3.10)$$

- la moyenne absolue des effets élémentaires :

$$\mu_j^* = \frac{1}{r} \sum_{i=1}^r |E_j^{(i)}| \quad (3.11)$$

- l'écart-type des effets élémentaires :

$$\sigma_j = \sqrt{\frac{1}{r-1} \sum_{i=1}^r (E_j^{(i)} - \mu_j)^2} \quad (3.12)$$

Pour éviter que des effets élémentaires de signe opposé ne se compensent, μ_j^* est préféré à μ_j . μ_j^* permet ainsi de représenter le degré d'influence qu'à le paramètre θ_j sur la sortie du modèle, alors que σ_j donne des informations quant aux potentielles implications des paramètres d'entrées dans des interactions ou des non-linéarités. Les paramètres incertains peuvent alors être tracés dans un graphique de Morris (Figure 29) et classés selon trois catégories :

- paramètres ayant des effets négligeables (groupe n°1) ;
- paramètres ayant des effets linéaires (groupe n°2) ;
- paramètres ayant des effets non-linéaires et/ou avec interactions (groupe n°3).




Figure 29 : Exemple de résultats par la méthode de Morris, adapté de Iooss (2009)

Lors de cette étape, les paramètres sont classés à partir de la distance entre l'origine et le point relatif au paramètre θ_j dans le graphique μ^* vs σ (Munaretto 2014) dans l'objectif de déterminer et de sélectionner les paramètres les plus influents :

$$d_j^* = \sqrt{\mu_j^{*2} + \sigma_j^2} \quad (3.13)$$

3.4 Étape 4 : calibrage du modèle

L'objectif de cette étape est de minimiser les incertitudes épistémiques pesant sur les paramètres incertains les plus influents identifiés à l'étape 3.

Dans un premier temps, il est important de définir avec précision la distribution de probabilité *a priori* des paramètres influents, représentant la connaissance (supposée) que l'on a sur ces paramètres. Ensuite, l'algorithme ABC-PMC (§2.4.4) est mis en œuvre pour réaliser le calibrage du modèle. Le cadre théorique utilisé est celui développé par Wilkinson (2013). Nous considérons ainsi que les données mesurées T^{mes} correspondent à la meilleure prédiction du modèle plus un terme d'erreur indépendant e , représentant l'erreur du modèle (cf. §2.4.2). Les erreurs de mesure seront quant à elles considérées lors de l'évaluation des résultats et de la propagation des incertitudes (étape 5). Dans l'objectif de calculer une distance entre les données simulées par le modèle et les données observées, la définition d'une grandeur d'intérêt est nécessaire. Ainsi, pour chaque simulation i , la distance quadratique moyenne notée $\rho(T_i^{sim}, T^{mes})$ est calculée par :

$$\rho(T_i^{sim}, T^{mes}) = RMSE_i = \sqrt{\left(\sum_{k=1}^N (T_i^{sim}(k\Delta t) - T^{mes}(k\Delta t))^2 / N\right)} \quad (3.14)$$

avec Δt le pas de temps de simulation, $T_i^{sim}(k\Delta t)$ et $T^{mes}(k\Delta t)$ la température respectivement simulée et mesurée à l'instant $k\Delta t$. La définition de cette distance a l'avantage de pouvoir pénaliser les écarts importants entre les données simulées et les données observées. L'algorithme ABC-PMC permet alors de réaliser l'inférence du modèle statistique décrit dans l'équation (3.7) et de déterminer la distribution *a posteriori*, $p(\theta|T^{mes}, \rho(T_i^{sim}, T^{mes}) \leq \epsilon_c)$, des paramètres les plus influents.

3.5 Étape 5 : évaluation des résultats

L'objectif de cette étape est d'évaluer, par la propagation des incertitudes, le degré d'incertitudes sur les résultats du modèle avant et après calibrage dans le but d'apprécier l'efficacité du processus de calibrage.

3.5.1 Propagation des incertitudes

La propagation des incertitudes permet d'estimer la distribution des sorties du modèle et ainsi donner des informations sur l'incertitude associée aux prédictions du modèle. Plus précisément, cette méthode vise à évaluer le degré d'incertitude relatif aux résultats du modèle induit par les incertitudes pesant sur les paramètres du modèle. La Figure 30 illustre le fonctionnement de cette méthode où l'objectif est de déterminer le profil d'incertitudes du modèle (en vert) paramétré par deux paramètres dont les profils d'incertitudes sont connus (en gris).




Figure 30 : Illustration de la propagation des incertitudes, adapté de Makowski (2014)

Cette méthode se déroule en quatre étapes :

- définir la fonction de densité de probabilité de chaque paramètre ;
- échantillonner les paramètres incertains ;
- simuler le modèle avec les paramètres échantillonnés ;
- évaluer le profil d'incertitudes de la sortie du modèle à partir des résultats des simulations.

3.5.2 Évaluation de l'efficacité du calibrage

Suite à la propagation des incertitudes sur les modèles calibré et non calibré, il est possible de calculer pour chaque modèle une RMSE moyenne sur les données de validation correspondant à :

$$RMSE = \frac{\sum_{i=1}^{N_{pro}} RMSE_i}{N_{pro}} \quad (3.15)$$

où N_{pro} est le nombre de simulations réalisées lors de la propagation des incertitudes. La comparaison entre la RMSE obtenue par le modèle calibré et le modèle non calibré permettra alors d'évaluer l'efficacité du processus de calibrage.

4. CAS D'APPLICATION

4.1 Collecte des données (étape 1)

4.1.1 Présentation du bâtiment

Le bâtiment étudié correspond à la maison I-BB (Béton banché) de la plateforme « INCAS » de l'INES (Institut National de l'Énergie solaire), située au Bourget-du-Lac. D'une architecture simple et compacte, elle dispose d'une surface intérieure de 89 m² et comporte deux étages. La maison a été conçue pour correspondre à la performance du label « PassivHaus », grâce notamment à une forte

Chapitre 3 : Calibrage de modèle

isolation, de très faibles ponts thermiques, des vitrages performants, ou encore une étanchéité à l'air de l'enveloppe soignée.



Figure 31 : Maison I-BB (façades sud et ouest)

Les dimensions intérieures sont de 7,5 m en longueur et de 6,5 m en largeur. La maison est bâtie sur un vide sanitaire de 80 cm de hauteur et est surmontée de combles indépendants du volume chauffé. Son orientation est décalée de 15° dans le sens trigonométrique par rapport à l'axe nord-sud. La toiture est à deux pans avec une orientation Nord/Sud et un débord de 60 cm à l'est, à l'ouest et au nord. La façade sud du bâtiment comprend une grande surface vitrée (28 % de la façade) protégée du soleil par un balcon d'une largeur de 1,3 m et une avancée de toiture de 1 m (Figure 32). La paroi nord ne comprend que deux petites fenêtres (2,5 % de la façade) de type triple vitrage afin de minimiser les pertes thermiques pendant la période hivernale. Les façades est et ouest disposent quant à elles d'un ratio de surface vitrée de 5 % et 10 % respectivement.

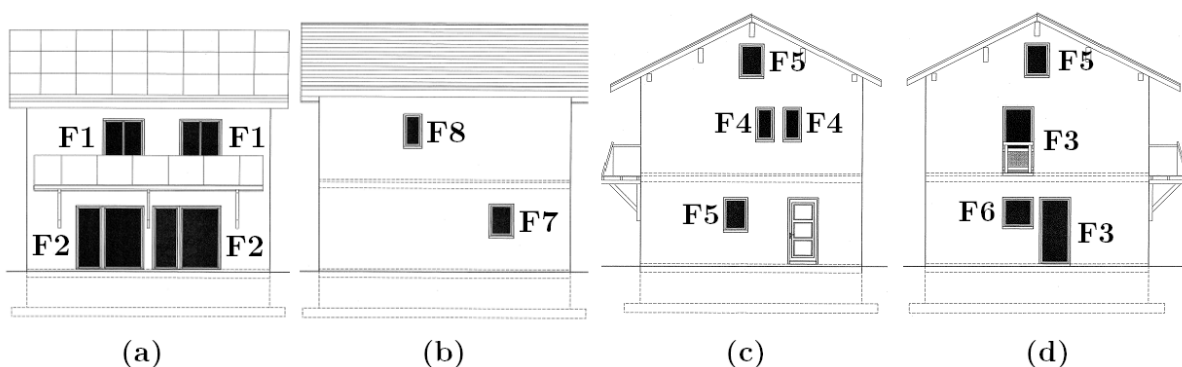


Figure 32 : Plan des façades de la maison I-BB, (a) sud, (b) nord, (c) ouest, (d) est. Source (CEA 2010)

Les menuiseries ont des cadres PVC dont le coefficient de déperdition thermique est égal à 1,45 W/(m².K). Les façades Sud, Est et Ouest possèdent des doubles vitrages 4-16-4 à faible émissivité avec remplissage argon. Le coefficient de déperdition thermique de ces vitrages est égal à 1,1 W/(m².K) avec un facteur solaire de 0,6. La façade nord est quant à elle équipée par des triples vitrages 4-12-4-12-4 à faible émissivité avec remplissage argon. Ces vitrages ont un coefficient de déperdition thermique égal à 0,7 W/(m².K) et un facteur solaire égal à 0,45.

Chapitre 3 : Calibrage de modèle

La maison I-BB est fortement isolée (isolation par l'extérieur) avec une inertie lourde comme montré dans le Tableau 9.

Tableau 9 : Composition des parois de la maison étudiée

	Murs extérieurs	Combles	Plancher bas	Plancher intermédiaire	Cloisons intérieures
Composition (ext → int)	20 cm de polystyrène extrudé 15 cm de béton banché	40 cm de laine de verre 1,5 cm de plaque de plâtre	20 cm de polystyrène extrudé Béton coulé sur place de 16 cm Chape en béton de 8 cm	Plancher poutrelles et entrevous de 16 cm 4 cm de dalle 8 cm de chape	1,5 cm de plâtre 4 cm de laine de verre 1,5 cm de plâtre
U (W/(m ² .K))	0,15	0,09	0,15	2,2	0,96

La maison est équipée d'une VMC (Ventilation Mécanique Contrôlée) de type double flux à deux ventilateurs : l'un pour le circuit d'air neuf et l'autre pour le circuit d'air vicié. L'air neuf est soufflé dans le séjour et les chambres tandis que des bouches situées dans les toilettes et la salle de bain assurent l'extraction de l'air vicié. L'échangeur à plaques permet une récupération de chaleur jusqu'à 90 %. Les ventilateurs sont dimensionnés pour imposer des débits nominaux de 135 ($Q_{v,nom-1}$) ou 270 m³/h ($Q_{v,nom-2}$). Un by-pass permet le rafraîchissement par ventilation directe. Le chauffage est assuré par une résistance électrique d'une puissance de 1,2 kW située au départ du réseau de distribution de l'air neuf. Pour plus de détails sur la maison I-BB, il est conseillé au lecteur de se rapporter à la thèse de Munaretto (2014).

4.1.2 Protocole expérimental

L'étude consiste à comparer des mesures de température d'air intérieur réalisées dans la maison I-BB avec les températures évaluées par le logiciel de simulation thermique dynamique COMFIE. L'objectif est d'améliorer les prédictions du modèle grâce au calibrage de ce dernier. Cette étude s'inscrit dans le prolongement des études réalisées par Munaretto (2014) et Recht et al. (2014) sur la validation empirique de l'outil COMFIE.

4.1.2.1 Description des scénarios

La période d'étude considérée, qui s'étend du 1^{er} janvier au 22 avril 2012, correspond à un protocole expérimental subdivisé en six scénarios, avec une prise en compte séparée ou combinée de différents phénomènes physiques. Ainsi, selon les scénarios, les expérimentateurs de l'INES ont modifié un voire plusieurs paramètres d'exploitation, tels que la consigne de chauffage, l'ouverture/fermeture des volets, ou encore le régime et le débit de la VMC.

Chapitre 3 : Calibrage de modèle

Les six scénarios sont décrits ci-dessous (Figure 33) :

- **scénario n°1** : consigne de chauffage à 20°C ; by-pass de l'échangeur ; débit nominal de renouvellement d'air $Q_{v,nom-1}$; volets fermés ; séparation physique entre l'étage et le rez-de-chaussée (RDC) ;
- **scénario n°2** : température en évolution libre ; système de chauffage et de ventilation éteints (off) ;
- **scénario n°3** : séparation physique entre les deux niveaux retirée ;
- **scénario n°4** : mêmes conditions que le scénario n°1 mais avec une consigne de chauffage à 24°C ;
- **scénario n°5** : chauffage éteint (off), ouverture des volets, séparation physique entre les deux niveaux retirée ;
- **scénario n°6** : renouvellement d'air avec un débit nominal augmenté noté $Q_{v,nom-2}$.

	Scénario n°1	Scénario n°2	Scénario n°3	Scénario n°4	Scénario n°5	Scénario n°6
Consigne	20°C	Off	Off	24°C	Off	Off
Régime VMC	BP	Off	Off	BP	BP	BP
Débit VMC	$Q_{v,nom-1}$	0	0	$Q_{v,nom-1}$	$Q_{v,nom-1}$	$Q_{v,nom-2}$
Volets	Fermés	Fermés	Fermés	Fermés	Ouverts	Ouverts
Séparation RDC/R+1	Avec	Avec	Sans	Avec	Sans	Sans

Timeline: 01/01/2012, 16/01/2012, 09/02/2012, 20/02/2012, 15/03/2012, 31/03/2012, 22/04/2012

Figure 33 : Description du protocole expérimental

Dans notre cas d'application, nous avons choisi de séparer en deux catégories les différents scénarios. Ainsi, les scénarios n°1, 2, 3 et 5 ont été utilisés pour identifier les paramètres les plus influents (étape 3, analyse de sensibilité) et déterminer leur lois de distribution *a posteriori* (étape 4, calibrage). Les scénarios n°4 et 6 ont quant à eux été utilisés pour comparer les données simulées par l'outil COMFIE avant et après calibrage (étape 5, propagation d'incertitudes) et ainsi évaluer et quantifier l'apport du calibrage du modèle. Les scénarios n°4 et 6 ont été choisis comme données de validation car ils sont proches respectivement du scénario n°1 et du scénario n°5. On peut ainsi évaluer le comportement du modèle calibré dans des conditions expérimentales relativement proches. De plus, les scénarios n°4 et 6 ont l'intérêt de mettre en avant des processus physiques différents avec l'ouverture ou non des volets.

4.1.2.2 Données météorologiques

Les données météorologiques utilisées correspondent aux données mesurées (température extérieure, rayonnement solaire global et diffus horizontal) au pas de temps horaire à l'aéroport du Bourget-du-Lac situé à quelques centaines de mètres de la maison I-BB.

Les informations relatives au site sont :

- longitude : 5,8814° ;
- latitude : 45,6876° ;
- altitude : 233 m ;
- température moyenne du sol à 10 m : 9°C.

Le Bourget-du-Lac est entouré de massifs montagneux induisant des masques lointains. Cependant, ces derniers n'ont pas été modélisés car ils sont déjà pris en compte par les données météorologiques : la station météorologique est à quelques centaines de mètres de la maison I-BB.

4.1.2.3 Mesures des températures intérieures

A l'intérieur de la maison, les températures d'air sont mesurées par des sondes de platine protégées par un bouclier thermique pour éviter que le rayonnement n'influence la mesure. Elles sont mesurées dans chacune des pièces, au centre du volume, à une hauteur de 1,10 m. Pour effectuer la comparaison entre l'outil de simulation COMFIE et l'expérimentation, une bande d'incertitudes de $\pm 1^\circ\text{C}$ a été considérée sur la mesure, en raison des incertitudes intrinsèques des capteurs, des effets induits par le bouclier thermique et de l'inhomogénéité de température dans les pièces (Spitz 2012).

4.2 Hypothèses de modélisation du bâtiment (étape 2)

Il est conseillé au lecteur intéressé de se reporter à la thèse de Munaretto (2014) s'il souhaite plus de précision sur les hypothèses de modélisation.

4.2.1 Zonage de la maison

Nous avons considéré dans cette étude un modèle thermique du bâtiment monozone. En effet, le cadre général de cette thèse concerne la régulation et l'application de différentes méthodes d'optimisation. Il est donc nécessaire de disposer d'un modèle de bâtiment rapide à simuler dans l'objectif de minimiser les temps de calcul. Cependant, ce choix amène à une diminution de la précision des températures simulées. Par conséquent, les températures intérieures mesurées dans les pièces de la maison ont été agrégées au prorata des surfaces intérieures de ces pièces afin de les comparer avec la température intérieure simulée par le modèle.

L'outil de simulation dynamique COMFIE est basé sur un modèle 1D au niveau des parois. Le choix d'une convention de surface est donc essentiel lorsque les dimensions d'un bâtiment sont décrites sur l'un de ces modèles numériques. En convention extérieure, le volume chauffé sera fortement surévalué tandis qu'en convention intérieure, la surface des parois déperditives sera sous-estimée. Afin de réduire l'erreur de modélisation, une convention au milieu du béton a été considérée pour la maison I-BB, ce qui permet de représenter plus fidèlement l'inertie thermique des locaux.

4.2.2 Débits de ventilation

Les informations constructeurs affirment que les débits nominaux sont égaux à $Q_{v,nom-1} = 135 \text{ m}^3/\text{h}$ et $Q_{v,nom-2} = 270 \text{ m}^3/\text{h}$. Cependant, suite à une campagne de mesures menée par le CEA, les débits nominaux $Q_{v,nom-1}$ et $Q_{v,nom-2}$ ont été estimés à 110 et 160 m^3/h respectivement et ont été retenus dans l'étude.

4.2.3 Consignes de température

Sur la période de l'étude, les températures de consigne n'ont jamais été atteintes en pratique (l'échangeur de chaleur de la VMC était by-passé), la puissance de chauffage était donc maximale sur tous les scénarios où le chauffage était allumé.

4.2.4 Infiltrations

Suite aux tests de porte soufflante effectués in situ par le CETE de Lyon en février 2010, nous avons fixé le débit d'infiltration à 0,03 vol/h.

4.2.5 Ponts thermiques

Les ponts thermiques ont été calculés à l'aide d'un logiciel basé sur une discrétisation en éléments finis (TRISCO).

4.2.6 Puissance dissipée par les systèmes

Les différentes puissances dissipées à l'intérieur de la maison par les multiples appareils électriques (commutateur, transformateurs, centrale de traitement des mesures, capteurs divers, moteur de la VMC) ont été prises en compte. Un total de 208 W pour l'ensemble de la zone a alors été considéré.

4.2.7 Occultation des vitrages

Des volets roulants sont installés sur l'ensemble des menuiseries. La résistance additionnelle des volets a été fixée à 0,20 $\text{m}^2 \cdot \text{K}/\text{W}$. Cette valeur reste cependant très incertaine car nous disposons de peu d'informations sur ce sujet.

4.2.8 États de surface

Toutes les surfaces intérieures à l'exception des planchers sont de couleur blanche, de même que les enduits extérieurs (Tableau 10). Les planchers sont quant à eux de couleur brun clair (carrelage).

Tableau 10 : Propriétés radiatives des revêtements de la maison I-BB

Type de surface	ϵ_{GLO} [-]	α_{CLO} [-]
Enduit extérieur	0,9	0,65
Peinture intérieure	0,9	0,2
Carrelage	0,9	0,7

4.2.9 Masques proches

Les différents masques proches induits par le balcon (avancée du balcon, garde corps), l'avancée de la toiture et le retrait de toutes les menuiseries ont été pris en compte.

4.2.10 Albédo

Le sol jouxtant la maison est du sable blanc ; de l'herbe se trouve à proximité. Or la valeur de l'albédo est différente entre ces deux revêtements. Un albédomètre a été mis en place afin de mesurer la réflectivité moyenne du sol environnant et une valeur de 0,35 a été mesurée. Une incertitude relativement élevée pèse sur ce paramètre car la valeur de l'albédo est sujette à des variations au cours de l'année.

4.2.11 Initialisation de la simulation

La température de zone a été initialisée à la température mesurée expérimentalement à la première heure (le bâtiment ayant été chauffé à 20°C les semaines précédentes) et les profils de température des parois correspondent à ceux en régime permanent avec les températures d'air extérieur et de zone comme conditions aux limites.

4.3 Analyse de sensibilité : méthode de Morris (étape 3)

Pour identifier les paramètres à calibrer les plus influents, la méthode de Morris a été utilisée. Comme expliqué dans le §3.3.2, les différents paramètres θ_j ont été classés selon leurs distances d_j^* . Plus précisément, la distance d_j^* a été calculée sur chaque scénario s (scénarios n°1, 2, 3 et 5), puis normalisée selon l'équation suivante :

$$D_{j,s}^* = \frac{d_{j,s}^* - \min_j(d_{j,s}^*)}{\max_j(d_{j,s}^*) - \min_j(d_{j,s}^*)} \quad (3.16)$$

Chapitre 3 : Calibrage de modèle

Le maximum des $D_{j,s}^*$ sur les quatre phases du protocole est choisi pour classer les paramètres. Les phénomènes physiques mis en avant dans chaque scénario étant différents, le but est de retenir tout facteur qui serait influent, ne serait-ce que sur une seule phase du protocole.

L'influence de 102 paramètres incertains a ainsi été évaluée dans ce cas d'application. Ces paramètres concernent toutes les hypothèses de modélisation prises dans l'étape de modélisation. Les incertitudes considérées sur chaque paramètre ainsi que les abréviations utilisées se trouvent dans le Tableau 30 de l'Annexe C.

Concernant les paramètres de la méthode de criblage, nous avons considéré : $r = 100$, $Q = 6$ et $\Delta = \frac{Q}{2 \times (Q-1)} = 0,6$.

Les résultats du criblage sont présentés de la Figure 34 à la Figure 36. De manière générale, on peut noter l'influence de la puissance dissipée (Pdi) sur l'ensemble des scénarios.

On constate dans le scénario n°1 (Figure 34) la forte influence du débit de ventilation $Q_{v,nom-1}$. Ceci est normal car il s'agit du débit de ventilation appliqué lors de ce scénario. De même, étant donné que le chauffage était actif, la puissance de chauffage (Pch) est également très influente. Enfin, on peut remarquer la résistance thermique des volets roulants Roc qui peut s'expliquer par l'incertitude forte qui pèse sur cet indicateur.

Le modèle de bâtiment considéré étant monozone, les scénarios n°2 et 3 sont identiques. Par conséquent, les résultats du criblage sont rassemblés pour ces deux scénarios (Figure 35). De manière logique, on constate l'apparition de la capacité thermique volumique du béton banché ($Cvl - \text{Béton banché}$) et de la chape béton ($Cvl - \text{Chape béton}$). En effet, le chauffage est coupé à la fin du scénario n°1. Par conséquent, l'évolution de la température du bâtiment dépend fortement de l'inertie thermique du bâtiment, ce dernier étant isolé par l'extérieur. On peut également remarquer que les scénarios n°2 et 3 sont encore influencés par la puissance de chauffage et le débit de ventilation. Ceci est dû à la persistance de leur influence après le scénario n°1. Le chauffage étant éteint lors de cette période expérimentale, on note l'augmentation de l'influence de la résistance des volets roulants.

Le scénario n°5 (Figure 36), correspondant à l'ouverture des volets, fait émerger les paramètres relatifs aux apports solaires, à savoir l'albédo (Alb), le facteur solaire de la fenêtre F2 ($Sow - F2$) ainsi que l'absorptivité de l'enduit ($Alp - \text{Enduit}$). Les volets étant ouverts, la résistance thermique des occultations disparaît. Bien que le chauffage soit coupé, le scénario n°5 est encore influencé par la puissance de chauffage utilisée lors du scénario n°4.

Enfin, sur l'ensemble des scénarios, on peut noter l'influence de la puissance dissipée (Pdi).

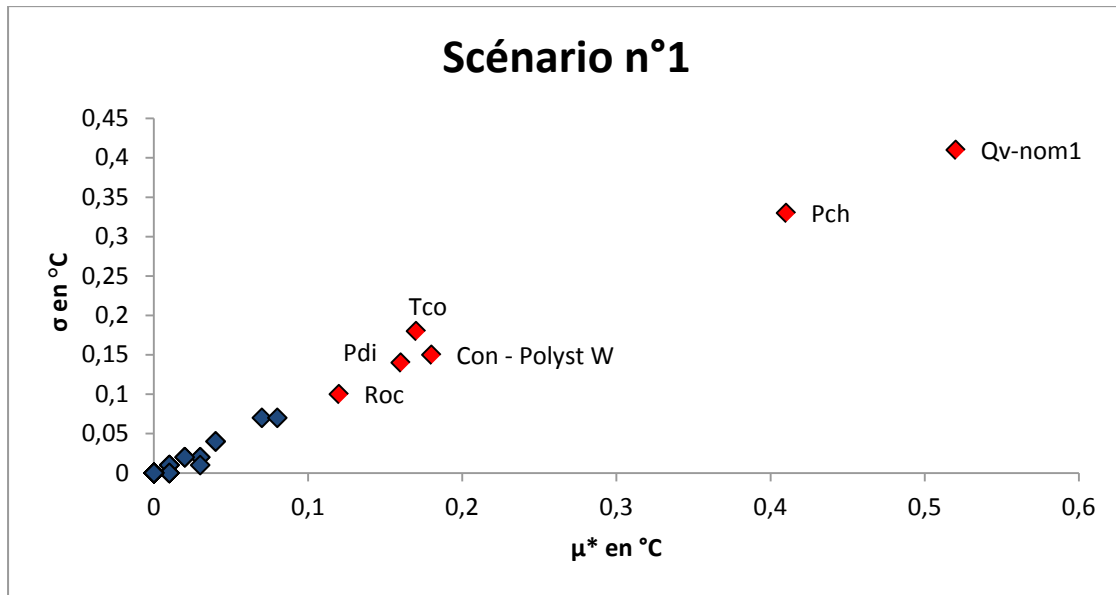


Figure 34 : Graphe de Morris, scénario n°1




Figure 35 : Graphe de Morris, scénario n°2 et 3

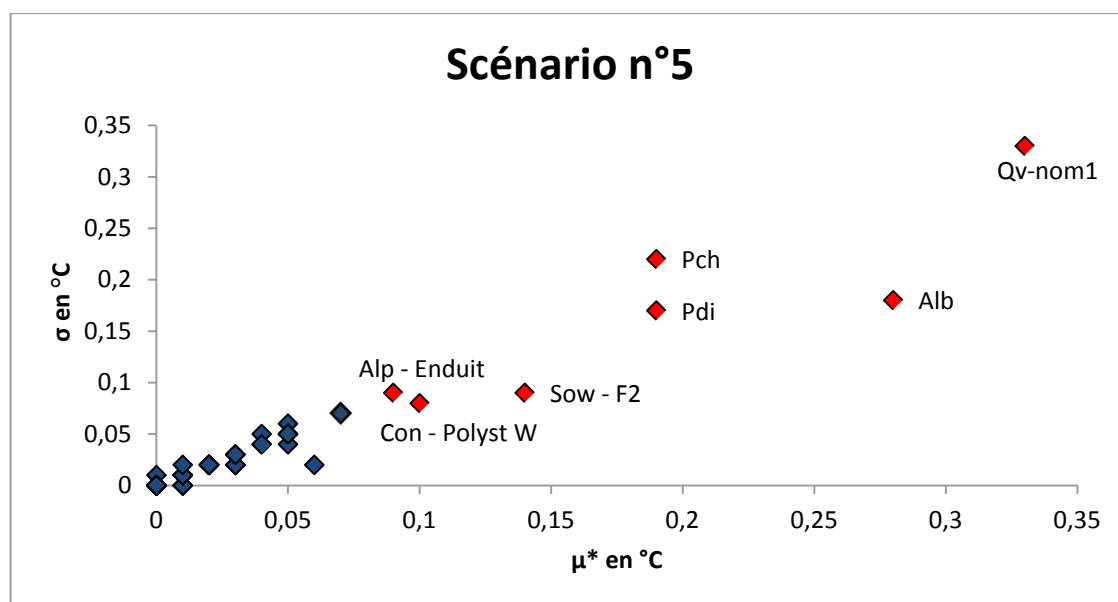


Figure 36 : Graphe de Morris, scénario n°5

Suite à la présentation des résultats du criblage, l'ensemble des paramètres ont été classés selon leur distance $D_{j,s}^*$ dans l'objectif de sélectionner les paramètres les plus influents sur l'ensemble des scénarios. Les résultats de ce classement sont présentés dans la Figure 37. Suite à ce classement, seuls les six premiers paramètres ont été sélectionnés pour l'étape de calibrage, car d'une part ils se détachent des autres paramètres, et d'autre part ce nombre de paramètre permet d'éviter des temps de calcul prohibitifs lors du calibrage. Ces paramètres correspondent au débit de ventilation $Q_{v,nom-1}$, à la puissance dissipée Pdi , à la puissance de chauffage Pch , à la capacité thermique volumique du béton banché $Cvl - \text{Béton banché}$, à l'albédo Alb , et à la conductivité thermique du polystyrène extrudé $Con - \text{Polyst W}$.

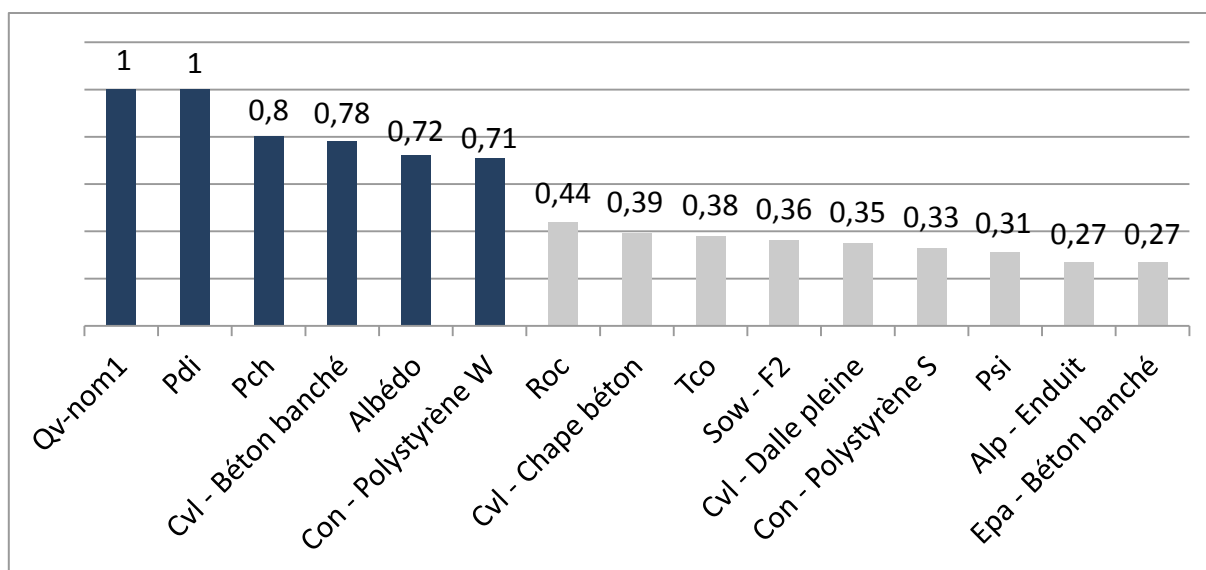


Figure 37 : Classement des facteurs incertains selon $\max_s(D_{j,s}^*)$

4.4 Calibrage du modèle (étape 4)

Dans un premier temps, il est nécessaire de définir les distributions de probabilité *a priori* des paramètres sélectionnés à l'étape 3. Les distributions considérées dans ce cas d'application sont résumées dans le Tableau 11 (Munaretto 2014).

Tableau 11 : Distributions de probabilité *a priori* considérées

Paramètre	Loi <i>a priori</i>	Unité
$Q_{v,nom-1}$	Loi normale (150,7 ; 15,07)	[m ³ /h]
P_{di}	Loi normale (208 ; 20,8)	[W]
P_{ch}	Loi normale (1200 ; 20)	[W]
Cvl – Béton banché	Loi normale (2120 ; 212)	[kJ/(m ³ .K)]
Alb	Uniforme (0,28 ; 0,42)	[-]
Con – Polyst W	Loi normale (0,03 ; 0,003)	[W/(m.K)]

Suite à la définition des distributions de probabilité *a priori*, il est possible d'estimer, à partir des données mesurées, les distributions de probabilité *a posteriori* en utilisant l'algorithme ABC-PMC présenté au §2.4.4. Tout d'abord, pour chaque simulation i , la distance $\rho(T_i^{sim}, T^{mes}) = RMSE_i$ a été calculée sur les données de calibrage correspondant aux scénarios 1, 2, 3 et 5. Ensuite, une séquence décroissante de seuils de tolérance de $\epsilon_1 = 20^\circ C$ à $\epsilon_C = 0,4^\circ C$ a été considérée. Enfin, le nombre de valeurs de paramètres satisfaisant à chaque étape le seuil de tolérance (N_{ABC}) a été fixé à 300. L'utilisation de l'algorithme de calibrage a nécessité six heures de calcul.

Les résultats sont présentés de la Figure 38 à la Figure 43. Sur chaque figure sont représentées la distribution de probabilité *a priori*, les 300 valeurs du paramètre sélectionnées par l'algorithme et la distribution de probabilité *a posteriori* estimée. Pour chaque paramètre, un test d'ajustement à une loi normale (test du Khi deux) a été réalisé sur les 300 valeurs du paramètre retenues. Seules les valeurs de paramètre obtenues pour l'albédo ne satisfont pas ce test.

On peut tout d'abord constater que les distributions de probabilité *a posteriori* du débit de ventilation $Q_{v,nom-1}$, et de la puissance dissipée P_{di} sont très proches de leurs distributions *a priori* (Figure 38 et Figure 39) avec un ajustement de 2 % de l'espérance dans les deux cas. Pour la puissance de chauffage (Figure 40) on constate que l'espérance de la distribution de probabilité passe de 1,2 kW à 1,23 kW (ajustement de 3 %) avec une légère augmentation de l'écart-type. Le constat est différent en ce qui concerne la capacité thermique volumique du béton banché (Figure 41) où l'on note que l'espérance de la distribution de probabilité passe de 2120 kJ/(m³.K) à 2586 kJ/(m³.K) (20 % d'écart) avec une légère diminution de l'écart-type. Cette différence peut s'expliquer par le fait que le calibrage cherche à compenser des erreurs non prises en compte. Par exemple, les capacités thermiques volumiques de la chape béton et de la dalle pleine n'ont pas été retenues comme paramètres à calibrer dans le processus de calibrage. Les résultats pour l'albédo ne sont quant à eux pas probants (Figure 42). En effet, les valeurs du paramètre retenues par l'algorithme ne satisfont pas le test d'ajustement à une loi normale. L'utilisation d'un intervalle d'incertitude trop restreint peut expliquer ce résultat. On peut par exemple supposer que la loi

Chapitre 3 : Calibrage de modèle

a posteriori de l'albédo aurait pu être une loi normale si l'intervalle d'incertitude avait été compris entre 0,2 et 0,4. On peut cependant remarquer que toutes les valeurs du paramètre sont inférieures à 0,38. Par conséquent, la distribution de probabilité *a posteriori* de l'albédo considérée dans la suite de l'étude sera une loi uniforme entre 0,28 et 0,38. Enfin, pour la conductivité thermique du polystyrène extrudé, on peut noter une diminution de l'espérance de la distribution de probabilité *a posteriori* par rapport à la distribution *a priori*, avec respectivement 0,027 W/(m.K) et 0,03 W/(m.K), avec une légère augmentation de l'écart-type.




Figure 38 : Distributions de probabilité *a priori* et *a posteriori* de $Q_{v,nom-1}$

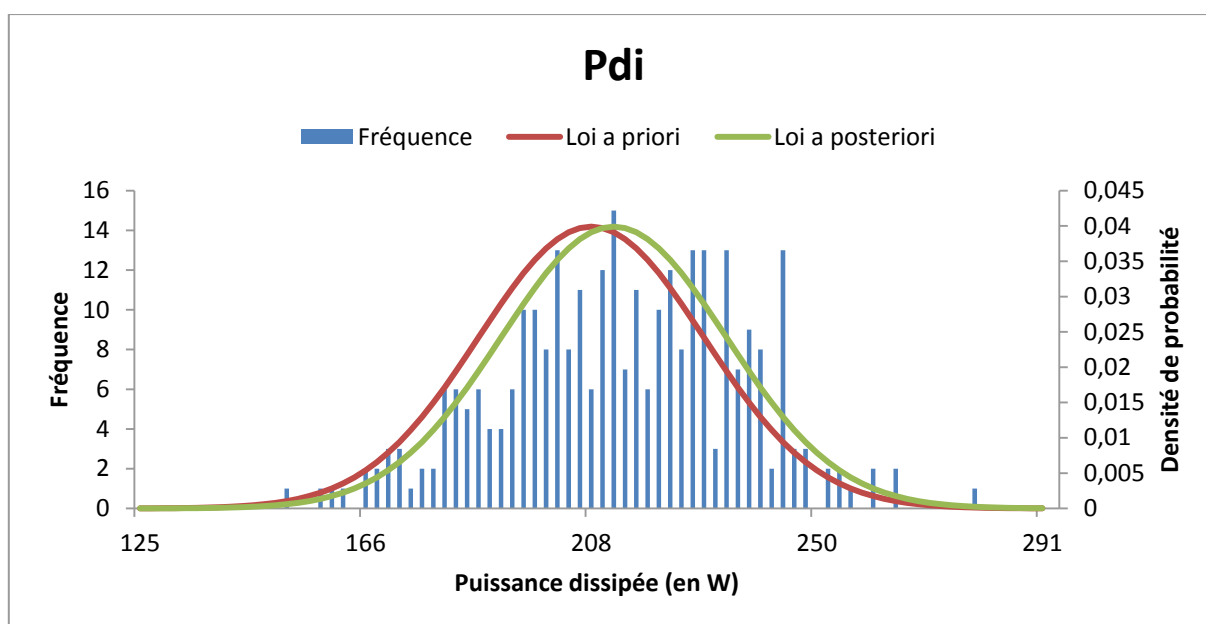


Figure 39 : Distributions de probabilité *a priori* et *a posteriori* de P_{di}




Figure 40 : Distributions de probabilité *a priori* et *a posteriori* de *Pch*




Figure 41 : Distributions de probabilité *a priori* et *a posteriori* de *Cv1* – Béton banché

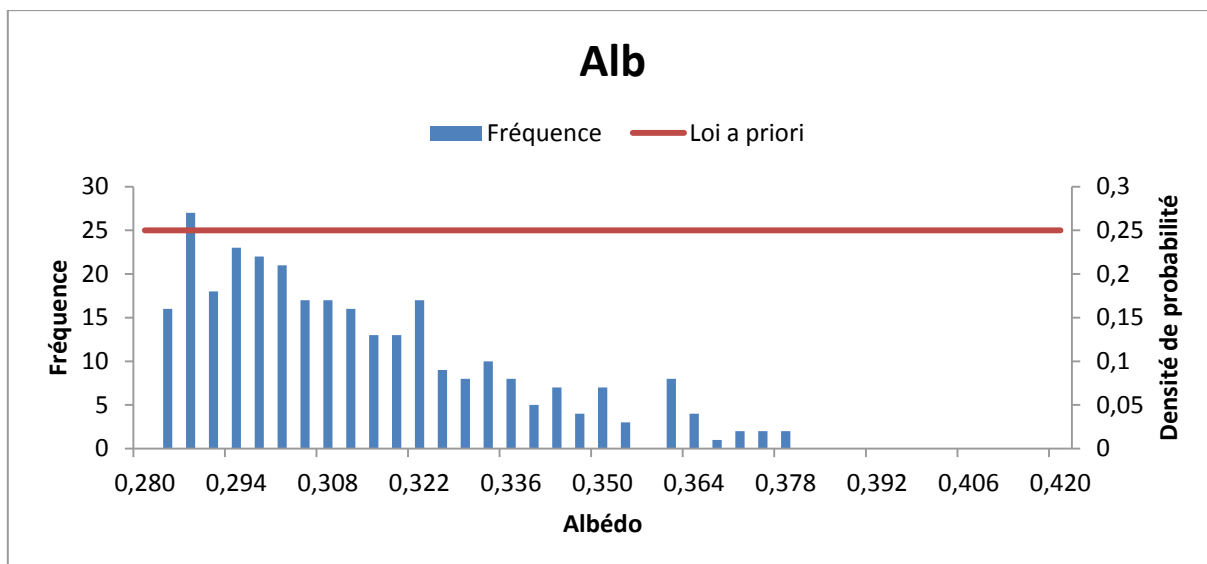


Figure 42 : Distributions de probabilité *a priori* et *a posteriori* de *Alb*

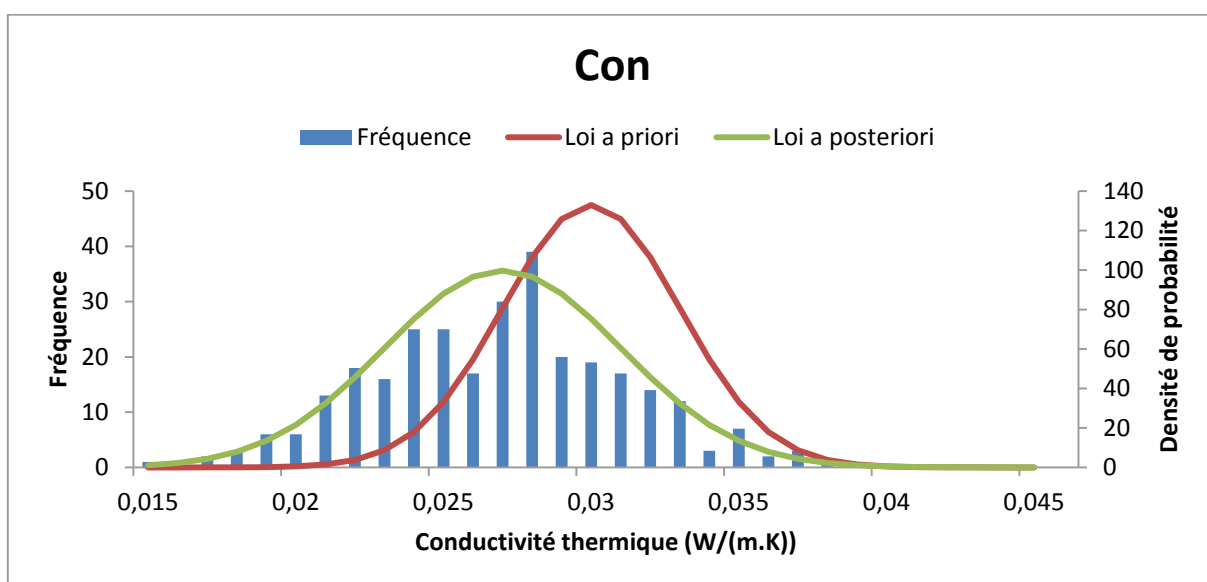


Figure 43 : Distributions de probabilité *a priori* et *a posteriori* de *Con – Polyst W*

L'ensemble des distributions de probabilité a posteriori déterminées lors de cette phase de calibrage est présenté dans le Tableau 12. Il est important de noter que les distributions de probabilité *a posteriori* estimées sont jointes, il n'est pas possible de les considérer séparément. Plus précisément, les distributions de probabilité *a posteriori* sont issues d'une distribution commune multivariée et sont par conséquent corrélées. Cela signifie qu'une valeur d'un paramètre coïncide avec des valeurs spécifiques des autres paramètres. Par conséquent, les distributions de probabilité a posteriori doivent être appliquées conjointement lors de la propagation des sources d'incertitudes. Il faut également rappeler que les distributions de probabilité *a posteriori* estimées par l'algorithme peuvent ne pas être physiques. On peut par exemple obtenir une puissance de chauffage estimée supérieure à la documentation technique.

Tableau 12 : Distributions de probabilité *a posteriori* estimées

Paramètre	Loi <i>a posteriori</i>	Unité
$Q_{v,nom-1}$	Loi normale (147,7 ; 11,8)	[m ³ /h]
Pdi	Loi normale (212 ; 21)	[W]
Pch	Loi normale (1230 ; 29)	[W]
Cvl – Béton banché	Loi normale (2586 ; 191)	[kJ/(m ³ .K)]
Alb	Uniforme (0,28 ; 0,38)	[-]
Con – Polyst W	Loi normale (0,027 ; 0,004)	[W/(m.K)]

Suite à l'estimation des distributions de probabilité *a posteriori*, il est possible d'évaluer la performance du processus de calibrage grâce à une propagation des sources d'incertitudes.

4.5 Évaluation des résultats (étape 5)

La définition des distributions de probabilité *a priori* et *a posteriori* permet de caractériser les incertitudes liées aux facteurs d'entrée du modèle avant calibrage et après calibrage. Ces dernières sont ensuite propagées selon une méthode de Monte-Carlo consistant à réaliser un grand nombre de simulations avec un tirage aléatoire des paramètres selon leur distribution. Pour son efficacité reconnue, un tirage stratifié latin hypercube dit « LHS » (*Latin Hypercube Sampling*) a été utilisé (Munaretto 2014). Les sorties du modèle (ici la température de la zone) sont relevées à chaque simulation afin d'obtenir leur distribution et d'analyser les résultats. Pour obtenir une représentation graphique des résultats de la propagation des sources d'incertitudes, pour chaque de simulation i le profil de distribution des températures simulées $T_i^{sim}(k\Delta t)$ à un pas de temps fixé $k\Delta t$ ($k \in \mathbb{Z}$) est approché par une loi normale d'espérance $\mu_{i,k}$ et d'écart-type $\sigma_{i,k}$. La moyenne sur toutes les simulations des $\mu_{i,k}$ est une série temporelle représentée par la courbe C_μ . De la même manière, C_σ , construite à partir des $\sigma_{i,k}$, représente la courbe des écarts-types à la moyenne. La courbe C_μ est alors encadrée par les courbes $C_{\mu+2\sigma}$ et $C_{\mu-2\sigma}$ valant respectivement C_μ plus ou moins deux fois C_σ (Recht et al. 2014).

Les résultats de la propagation des sources d'incertitudes sur le modèle avant calibrage et après calibrage sont représentés respectivement sur la Figure 45 et la Figure 47. Pour rappel, dans le but d'effectuer une comparaison entre l'outil de simulation COMFIE et l'expérimentation, une bande d'incertitudes de $\pm 1^\circ C$ a été considérée sur la mesure.

Pour le modèle avant calibrage (Figure 45 et Figure 46), on constate que sur le scénario n°1 la simulation a tendance à sous-estimer la température intérieure en fin de simulation. Sur les scénarios n°2 et 3, on observe une tendance du modèle à sous-estimer la température intérieure bien que les dynamiques soient similaires. Sur le scénario n°4, on constate que la température simulée sous-estime la température mesurée sur l'ensemble du scénario. Cependant en fin de période, les bandes d'incertitudes sont confondues. Sur le scénario n°5, correspondant à l'ouverture des volets, l'amplitude journalière de variation des températures augmente sensiblement. On peut remarquer que celle des températures simulées est plus réduite que celle des températures

Chapitre 3 : Calibrage de modèle

mesurées. Enfin, sur le dernier scénario, l'analyse est similaire : on observe des profils simulés et mesurés proches avec des amplitudes plus faibles concernant les résultats de simulation. Sur l'ensemble de ces résultats, on peut constater les bonnes performances du modèle non calibré qui permet de reproduire de manière satisfaisante l'évolution de la température au sein du bâtiment.

Pour le modèle après calibrage (Figure 47 et Figure 48), on constate que sur les scénarios utilisés pour le calibrage (scénarios n°1, 2, 3 et 5) les bandes d'incertitudes des profils simulés et mesurés sont proches voire quasiment confondues, en particulier pour les scénarios n°2 et 3. Sur les données de validation, correspondant aux scénarios n°4 et 6, le constat est cependant plus mitigé. Sur le scénario n°4, on peut observer que le calibrage n'apporte que des améliorations à la marge. On constate ainsi que les profils mesurés et simulés sont plus proches en début de scénario. Sur le scénario n°6 on remarque l'apport du calibrage qui permet de diminuer l'incertitude du profil simulé sur la fin du scénario.

Pour quantifier les résultats, une RMSE moyenne (correspondant à la moyenne des RMSE calculées sur chaque simulation) entre les températures simulées et les températures mesurées a été calculée sur les données de validation (scénarios n°4 et 6). Les résultats sont présentés dans la Figure 44. Comme précédemment, on peut constater que sur le scénario n°4 le calibrage n'apporte qu'une amélioration à la marge. Cependant, sur le scénario n°6 le calibrage permet d'obtenir une RMSE de 0,5°C après calibrage contre une RMSE de 0,6°C avant calibrage.




Figure 44 : Comparaison la RMSE moyenne avant et après calibrage

La faible diminution du RMSE suite à la phase de calibrage peut s'expliquer de plusieurs manières. Tout d'abord le modèle considéré dans cette étude est un modèle monozone dont la précision est inférieure à celle d'un modèle multizone. Ensuite, dans l'objectif de comparer les températures simulées avec les températures mesurées, ces dernières ont été agrégées au prorata des surfaces intérieures des pièces du bâtiment, amenant également à une diminution de la précision. Enfin, dans ce cas d'application, seules des lois normale ou uniforme ont été utilisées.

On peut envisager l'utilisation de lois normales tronquées qui permettrait d'une part d'obtenir des distributions de probabilité *a posteriori* plus fines et d'autre part de s'assurer d'obtenir des distributions de probabilité *a posteriori* plus réalistes en évitant des valeurs physiques aberrantes.

Chapitre 3 : Calibrage de modèle




Figure 45 : Propagation des sources d'incertitudes avant calibrage

Chapitre 3 : Calibrage de modèle

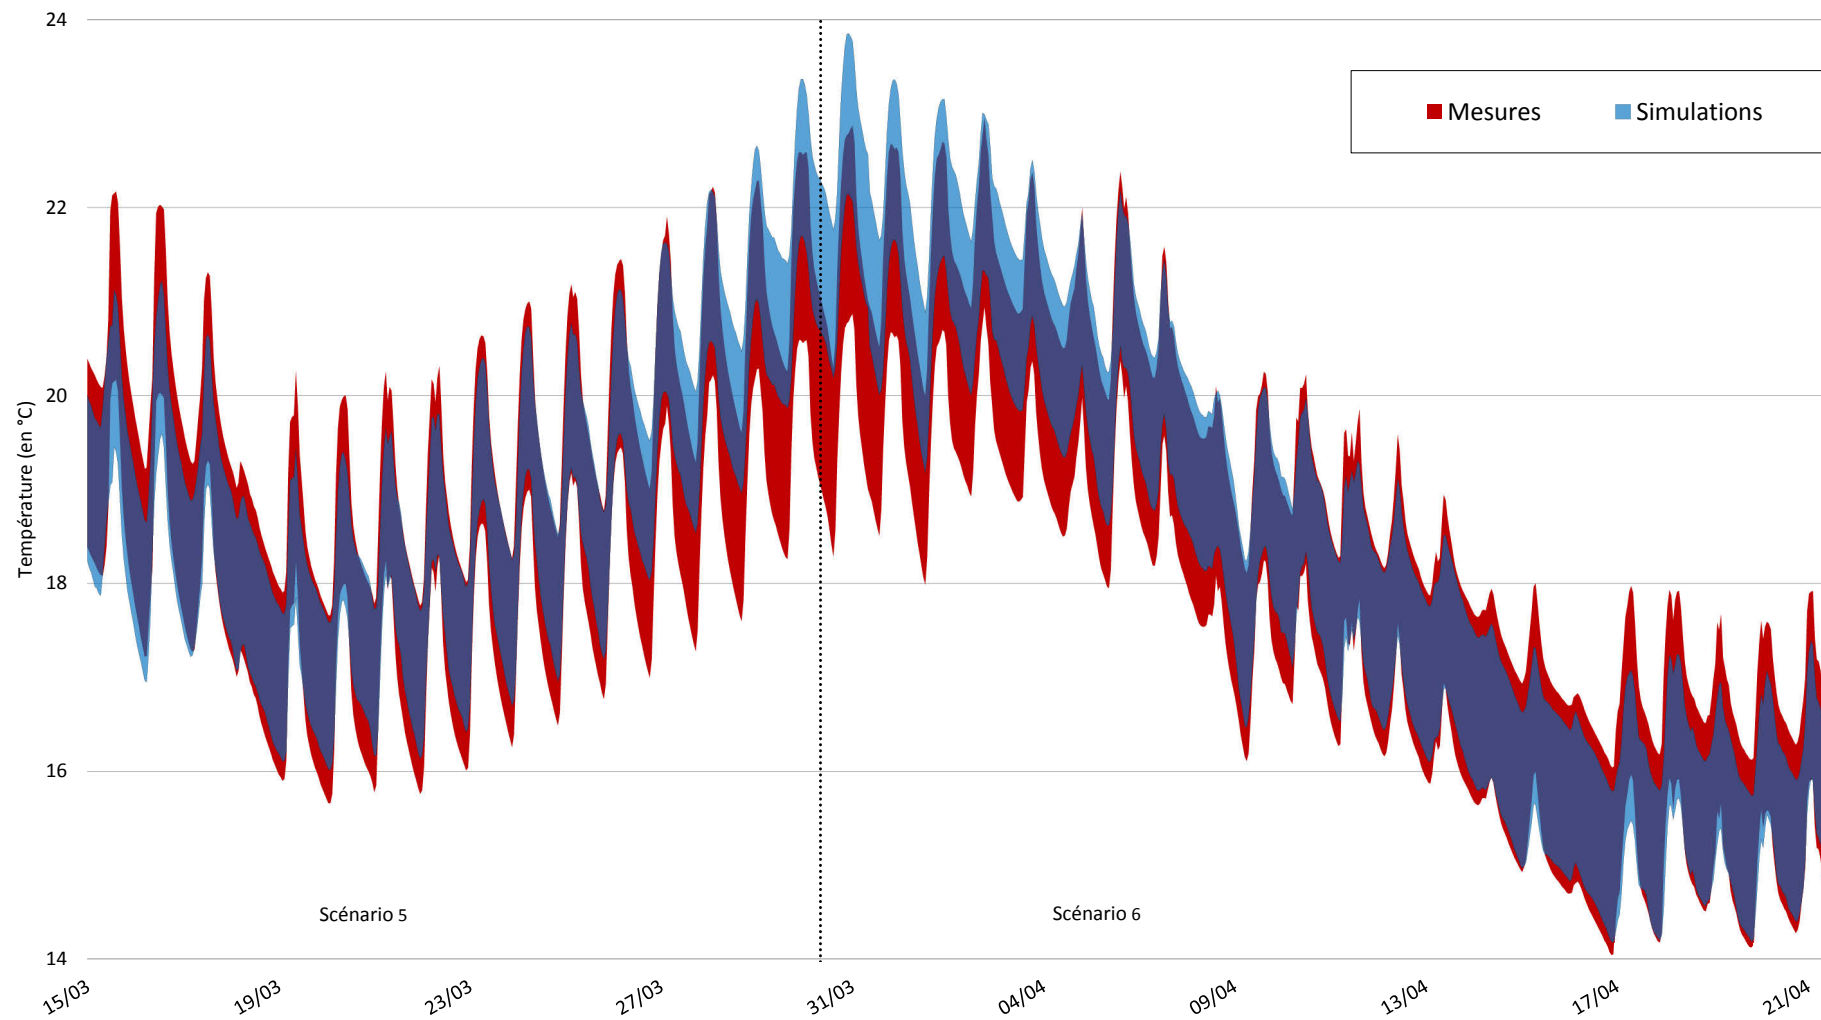


Figure 46 : Zoom sur les scénarios n°5 et n°6 (avant calibrage)

Chapitre 3 : Calibrage de modèle




Figure 47 : Propagation des sources d'incertitudes après calibrage

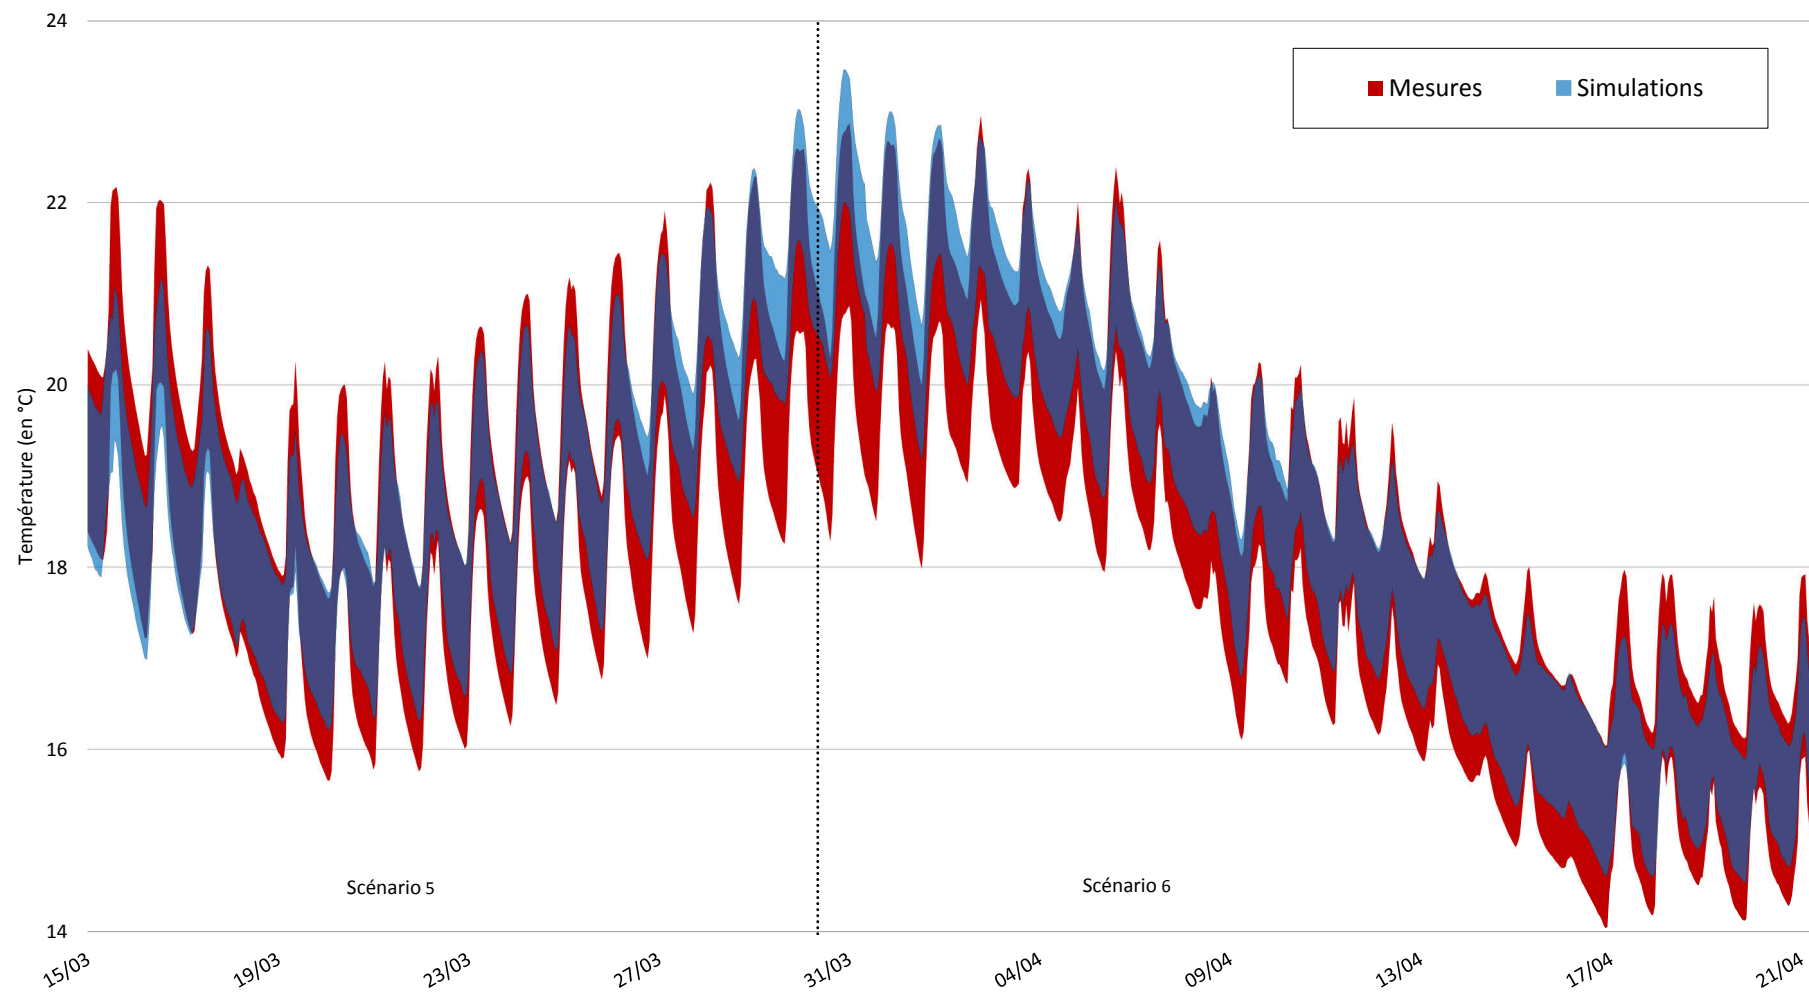


Figure 48 : Zoom sur les scénarios n°5 et n°6 (après calibrage)

5. CONCLUSION DU CHAPITRE

Dans ce chapitre, un rapide état de l'art a permis de présenter les principales méthodes de calibrage existantes, à savoir les méthodes heuristiques, les méthodes avancées et les méthodes bayésiennes. Nous nous sommes ensuite concentrés sur les méthodes bayésiennes car elles présentent l'avantage de considérer l'ensemble des sources d'incertitudes et d'erreurs pouvant expliquer les différences entre les données simulées et les données mesurées. Ces méthodes se placent dans le cadre de l'approche statistique du calibrage dont l'objectif est d'estimer des distributions de probabilité *a posteriori* des paramètres incertains. Les méthodes bayésiennes reposent sur le théorème de Bayes permettant d'estimer la distribution de probabilité *a posteriori* et se différencient selon la connaissance ou non de la fonction de vraisemblance. Dans l'objectif de définir une méthode de calibrage la plus générique possible (s'appliquant par exemple à des données simulées temporellement corrélées), notre choix s'est porté sur l'utilisation du calcul bayésien approché permettant d'éviter de connaître analytiquement la fonction de vraisemblance. Par la suite, une méthodologie a été présentée consistant à collecter l'ensemble des données nécessaires à la modélisation, à déterminer les paramètres les plus influents par une analyse de sensibilité, à estimer les distributions de probabilité *a posteriori* des paramètres influents grâce à l'algorithme ABC-PMC, et enfin à évaluer les résultats par le biais d'une propagation d'incertitudes.

Les résultats ont montré qu'il était possible d'estimer des distributions de probabilité *a posteriori* des paramètres influents, et d'améliorer le comportement du modèle après calibrage. Cependant, les améliorations sont faibles par rapport au modèle non calibré. Des études complémentaires seraient nécessaires pour évaluer les performances de la méthode développée. Cependant, plusieurs raisons peuvent expliquer ces faibles améliorations, telles que l'utilisation d'un modèle monozone du bâtiment et de données agrégées de la température intérieure.

Les avantages de la méthode de calibrage définie dans ce chapitre sont multiples. Tout d'abord, dans le cadre de la garantie de performance, cette méthode fournit d'une part des distributions de probabilité *a posteriori* des paramètres influents et non des valeurs uniques estimées par moindre carré. Ces distributions peuvent alors être utilisées pour propager les sources d'incertitudes et évaluer leur impact sur la grandeur d'intérêt considérée (consommation de chauffage, évolution de la température intérieure, etc.). D'autre part, elle permet de s'assurer de disposer d'un modèle fiable pour évaluer par exemple l'impact de rénovations énergétiques sur le comportement du bâtiment. De plus, cette méthode de calibrage peut également être utilisée pour calibrer un modèle de bâtiment utilisé dans le cadre de la régulation. Il suffit alors de considérer l'espérance mathématique de la distribution de probabilité *a posteriori* de chaque paramètre. Enfin, cette méthode de calibrage est générique et peut être utilisée sur n'importe quel modèle de bâtiment tout en utilisant des mesures diverses (puissance de chauffage, facture d'énergie, température intérieure, etc.). En perspectives, l'emploi de lois normales tronquées pour caractériser les distributions de probabilité *a priori* permettrait de s'assurer du respect des contraintes physiques des paramètres à calibrer. La

Chapitre 3 : Calibrage de modèle

méthode présentée dans ce chapitre permet d'envisager d'utiliser ce type de loi. De même, cette méthode pourrait être utilisée pour de la détection de défauts en orientant les campagnes de mesure à mener sur les paramètres dont la distribution de probabilité *a posteriori* ne semble pas correspondre avec la réalité.

Suite au calibrage du modèle thermique du bâtiment, nous nous intéresserons dans le chapitre 4 au développement de méthodes d'optimisation hors-ligne permettant d'approximer les résultats de la commande prédictive dans le but d'identifier les lois de commande simplifiées pouvant être embarquées dans les systèmes de régulation couramment utilisés par les professionnels du bâtiment.

Chapitre 4

Élaboration de lois de type heuristique

La commande prédictive est une méthode prometteuse pour améliorer la régulation énergétique des bâtiments performants. Cependant, son application par les professionnels du bâtiment reste encore limitée. Ce chapitre a pour objectif de développer des méthodes d'optimisation hors-ligne pour approximer les résultats de la commande prédictive et ainsi identifier des lois de commande simplifiées plus adaptées aux pratiques courantes. Dans un premier temps, nous présenterons les principes de l'optimisation hors-ligne. Par la suite, nous exposerons le cas d'application ainsi que la méthodologie développée. Enfin, le comportement des lois heuristiques identifiées sera analysé et leur robustesse testée.

PLAN DU CHAPITRE 4

1.	<u>L'OPTIMISATION HORS-LIGNE</u>	<u>145</u>
2.	<u>CADRE DE L'ÉTUDE</u>	<u>147</u>
2.1	BÂTIMENT ÉTUDIÉ	147
2.2	OBJECTIF DE L'OPTIMISATION	149
2.2.1	CONTRAINTES	150
2.2.2	TARIFS DE L'ÉLECTRICITÉ	150
3.	<u>MÉTHODOLOGIE</u>	<u>151</u>
3.1	ALGORITHME D'OPTIMISATION	151
3.1.1	LA PROGRAMMATION DYNAMIQUE	151
3.1.2	LES PARAMÈTRES DE LA PROGRAMMATION DYNAMIQUE	152
3.2	ÉLABORATION DES LOIS HEURISTIQUES	153
3.2.1	LES MÉTHODES DE RÉGRESSION	154
3.2.2	MÉTHODOLOGIE	155
3.2.3	VARIABLES EXPLICATIVES	159
3.2.4	MODÈLES DÉVELOPPÉS	159
3.2.5	CRITÈRES D'ÉVALUATION DES RÉSULTATS	160
4.	<u>RÉSULTATS</u>	<u>161</u>
4.1	DONNÉES MÉTÉOROLOGIQUES	161
4.2	INFLUENCE DES DONNÉES D'ENTRAÎNEMENT SUR LES RÉGRESSIONS BÊTA	162
4.3	UTILISATION D'UN CONTRÔLEUR	164
4.4	COMPARAISON À UNE LOI DE COMMANDE CLASSIQUE	166
5.	<u>INFLUENCE DE LA PRÉVISION MÉTÉOROLOGIQUE SUR LA LOI HEURISTIQUE IDENTIFIÉE</u>	<u>168</u>
5.1	MODÈLE DE PRÉVISION MÉTÉOROLOGIQUE	168
5.1.1	DONNÉES MÉTÉOROLOGIQUES UTILISÉES	168
5.1.2	DÉVELOPPEMENT DES MODÈLES	169

Chapitre 4 : Élaboration de lois de type heuristique

5.2	IMPACT SUR LES LOIS HEURISTIQUES	170
5.2.1	MISE EN PLACE DES DONNÉES MÉTÉOROLOGIQUES	170
5.2.2	COMPARAISONS DES RÉGULATIONS SELON LES DONNÉES CLIMATIQUES UTILISÉES.....	171
6.	<u>CONCLUSION DU CHAPITRE</u>	<u>173</u>

1. L'OPTIMISATION HORS-LIGNE

La commande prédictive est une technique prometteuse pour résoudre les problèmes d'optimisation rencontrés dans le domaine du bâtiment. Cependant, son utilisation par les professionnels reste encore limitée. En effet, les systèmes de régulation utilisés classiquement reposent sur des arbres de décision, c'est-à-dire sur l'emploi de lois de commande explicites. Or, dans le cadre de la commande prédictive, la loi de commande calculée est implicite. Seuls le modèle du bâtiment et l'algorithme d'optimisation doivent être définis alors que la loi de commande sous des sollicitations particulières n'est pas connue à l'avance. De plus, la mise en place de la commande prédictive nécessite l'utilisation de systèmes de contrôle-commande plus développés avec des solutions matérielles et logicielles spécifiques. Le gestionnaire doit alors être formé pour installer ces systèmes reposant sur l'optimisation numérique, les régler et réagir aux éventuels dysfonctionnements. Enfin, cette méthode nécessite l'utilisation de capteurs fiables, de moyens de calculs importants et d'algorithmes d'optimisation performants. En particulier, dans le cadre de la régulation en temps réel, ces algorithmes doivent faire face à des difficultés théoriques, telles que le respect des contraintes, le problème de convergence en un temps limité ou encore l'initialisation.

Une alternative consiste à utiliser des méthodes d'approximation hors-ligne des résultats de la commande prédictive (chapitre 1). La méthode hors-ligne consistant à approximer les résultats de l'optimisation en simulant le bâtiment sous des sollicitations extérieures et intérieures représentatives d'une année type va nous intéresser tout particulièrement dans ce chapitre. Son objectif est de développer des stratégies générales de gestion énergétique (ou loi de commande simplifiée). Des techniques statistiques peuvent alors être utilisées pour apprendre des résultats de la commande prédictive et identifier des lois heuristiques. Ces lois permettent ainsi de relier le choix d'une action à des variables explicatives.

Cette approche a par exemple été appliquée à la gestion en temps réel des inondations à l'aide d'un système de plusieurs réservoirs. L'objectif était d'identifier des lois de gestion des réservoirs (typiquement un arbre de décision) à partir des résultats de la commande prédictive (Wei et Hsu 2009).

La même démarche a été utilisée plus récemment dans le contexte du bâtiment. Par exemple, May-Ostendorp et al. (2013) ont utilisé plusieurs techniques d'exploration de données (le modèle linéaire généralisé, l'apprentissage par arbre de décision, l'algorithme Adaboost) pour identifier des lois heuristiques à partir des résultats de la commande prédictive. Le cas d'application concernait le rafraîchissement lors de la saison de climatisation d'un bâtiment de bureau de trois étages. L'objectif de l'optimisation était alors de minimiser la consommation d'énergie en commandant l'ouverture des fenêtres, sans contraintes sur le confort thermique. Une optimisation par essais particuliers a été employée sur un horizon de 24 heures. Les résultats de l'identification des lois heuristiques ont montré que les techniques statistiques utilisées présentent de bonnes performances, en particulier pour l'apprentissage par arbre de décision et l'algorithme Adaboost.

Chapitre 4 : Élaboration de lois de type heuristique

Plus récemment, Domahidi et al. (2014) ont utilisé différents algorithmes issus de l'apprentissage automatique tels que les machines à vecteurs de support (*Support Vector Machine, SVM*) ou encore l'algorithme Adaboost. L'objectif était de reproduire le comportement d'une commande prédictive pour déterminer les périodes de mise en fonctionnement des systèmes énergétiques. Une des principales limites de ces exemples est que ces techniques d'apprentissage ne sont employées que pour identifier des décisions binaires.

Enfin, Le et al. (2014) ont également utilisé les machines à vecteurs de support pour approcher les résultats de la commande prédictive. Le cas d'application concernait la gestion des occultations avec la résolution de la commande prédictive par une méthode de Séparation et Evaluation (*Branch & Bound*). Contrairement aux exemples précédents, l'originalité de leur travail repose sur l'apprentissage de décisions non binaires, en considérant plusieurs positions possibles pour les volets. Le fonctionnement de cette méthode est illustré dans la Figure 49. La structure de la commande prédictive est conservée mais elle est cette fois utilisée pour l'optimisation hors-ligne (*offline MPC*) dans le but d'identifier des lois heuristiques.

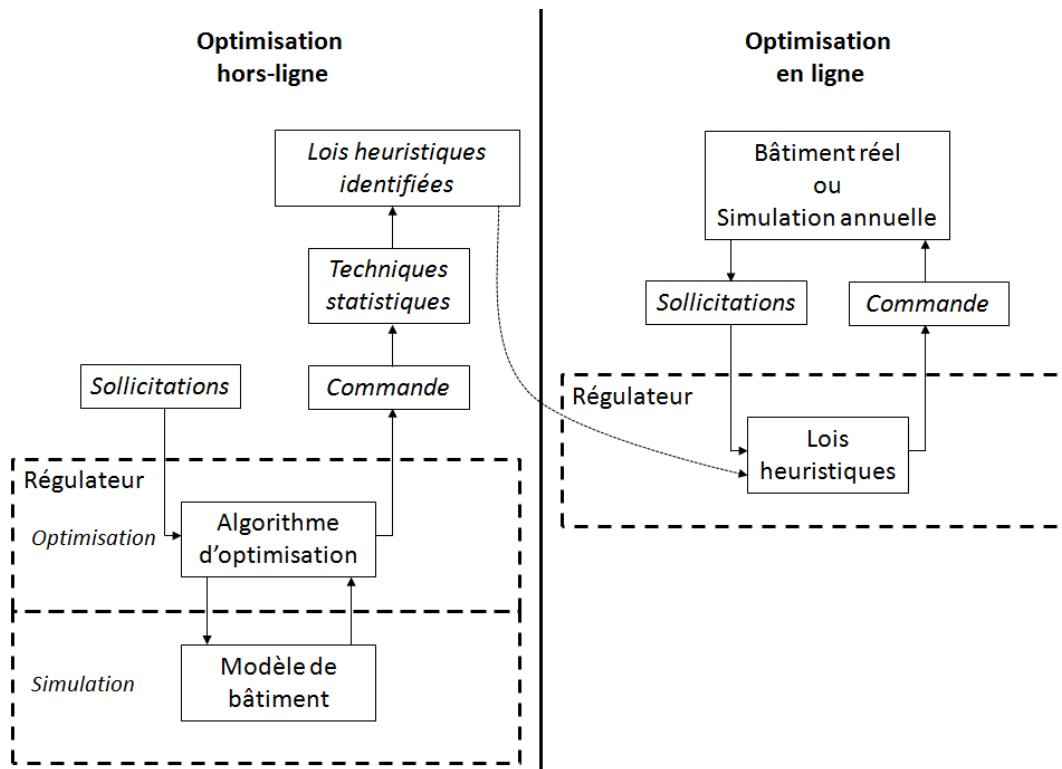


Figure 49 : Identification de lois heuristiques à partir de la commande prédictive

A notre connaissance, ces méthodes d'identification de lois heuristiques n'ont jamais été appliquées à la gestion du chauffage dans les bâtiments, et en particulier à l'identification de lois de commande continues. Le développement de la méthodologie est l'objet des paragraphes suivants.

2. CADRE DE L'ÉTUDE

2.1 Bâtiment étudié

Nous considérons le bâtiment présenté dans le Chapitre 3. Ce dernier dispose d'une ventilation mécanique de type double flux avec un récupérateur de chaleur d'une efficacité de 70 %. Le débit considéré pour le renouvellement d'air est de 0,6 vol/h (incluant 0,03 vol/h pour les infiltrations) quand le bâtiment est occupé et de 0,3 vol/h dans le cas contraire (toujours avec infiltrations). Le chauffage est assuré par une résistance électrique chauffant l'air insufflé dans le bâtiment.

Les apports internes émis par le métabolisme des occupants et les apports des systèmes électriques sont également pris en compte. Pour l'occupation du bâtiment, on considère une famille de quatre personnes : le bâtiment est occupé à 100 % de 18h à 8h, à 50 % de 17h à 18h. Le week-end, les quatre personnes sont continuellement présentes. Le même scénario est reproduit toutes les semaines et présenté dans le Tableau 13. Pour chaque occupant, une chaleur métabolique de 80 W est considérée. Les puissances dissipées par les systèmes électriques suivent également un scénario hebdomadaire, présenté dans le Tableau 14.

Le modèle thermique du bâtiment considéré dans cette étude est monozone dans le but de diminuer les temps de calculs de l'algorithme d'optimisation utilisé et de simplifier le développement des lois heuristiques. Selon les résultats de la simulation thermique dynamique effectuée avec le logiciel COMFIE (en considérant un modèle réduit par analyse modale à dix modes), les besoins de chauffage annuels sont de 14 kWh/m² correspondant au label « maison passive ».

Tableau 13 : Scénario hebdomadaire d'occupation

Hebdomadaire		% d'occupation					
Nombre d'occupants : 4							
Heure	Lun %	Mar %	Mer %	Jeu %	Ven %	Sam %	Dim %
0-1h	100	100	100	100	100	100	100
1-2h	100	100	100	100	100	100	100
2-3h	100	100	100	100	100	100	100
3-4h	100	100	100	100	100	100	100
4-5h	100	100	100	100	100	100	100
5-6h	100	100	100	100	100	100	100
6-7h	100	100	100	100	100	100	100
7-8h	100	100	100	100	100	100	100
8-9h	100	100	100	100	100	100	100
9-10h	0	0	0	0	0	100	100
10-11h	0	0	0	0	0	100	100
11-12h	0	0	0	0	0	100	100
12-13h	0	0	0	0	0	100	100
13-14h	0	0	0	0	0	100	100
14-15h	0	0	0	0	0	100	100
15-16h	0	0	0	0	0	100	100
16-17h	0	0	0	0	0	100	100
17-18h	50	50	50	50	50	100	100
18-19h	100	100	100	100	100	100	100
19-20h	100	100	100	100	100	100	100
20-21h	100	100	100	100	100	100	100
21-22h	100	100	100	100	100	100	100
22-23h	100	100	100	100	100	100	100
23-24h	100	100	100	100	100	100	100

Tableau 14 : Scénario hebdomadaire des puissances dissipées par les appareils électriques

Hebdomadaire		Puissance dissipée					
Heure	Lun Watts	Mar Watts	Mer Watts	Jeu Watts	Ven Watts	Sam Watts	Dim Watts
0-1h	10	10	10	10	10	10	10
1-2h	10	10	10	10	10	10	10
2-3h	10	10	10	10	10	10	10
3-4h	10	10	10	10	10	10	10
4-5h	10	10	10	10	10	10	10
5-6h	10	10	10	10	10	10	10
6-7h	10	10	10	10	10	10	10
7-8h	250	250	250	250	250	250	250
8-9h	200	200	200	200	200	200	200
9-10h	10	10	10	10	10	150	150
10-11h	10	10	10	10	10	150	150
11-12h	10	10	10	10	10	150	150
12-13h	10	10	10	10	10	250	250
13-14h	10	10	10	10	10	150	150
14-15h	10	10	10	10	10	150	150
15-16h	10	10	10	10	10	150	150
16-17h	10	10	10	10	10	150	150
17-18h	10	10	10	10	10	150	150
18-19h	200	200	200	200	200	200	200
19-20h	200	200	200	200	200	200	200
20-21h	320	320	320	320	320	320	320
21-22h	360	360	360	360	360	360	360
22-23h	250	250	250	250	250	250	250
23-24h	250	250	250	250	250	250	250

2.2 Objectif de l'optimisation

Dans cette étude, on se propose d'étudier la possibilité d'effacer la consommation électrique de chauffage du bâtiment pendant une période dite « de pointe » allant de 17 h à 21 h. L'objectif de l'optimisation est de déterminer la stratégie optimale qui minimise le coût de la consommation énergétique tout en respectant des contraintes de température de confort (contraintes d'état) et des contraintes de puissance maximale du système de chauffage (contraintes de commande). A noter qu'aucune contrainte n'est ajoutée sur la commande de chauffage pour réaliser l'effacement de la

Chapitre 4 : Élaboration de lois de type heuristique

consommation de pointe. L'effacement n'est obtenu que par un coût variable de l'électricité dans le temps. Le critère à minimiser est donc :

$$\min_P \int_0^{tf} C_{elec}(t)P(t)dt \quad (4.1)$$

où $C_{elec}(t)$ est le coût de l'électricité, $P(t)$ la puissance de chauffage à injecter dans le bâtiment et tf l'horizon d'optimisation.

2.2.1 Contraintes

Les contraintes d'état et de commande sont les suivantes :

- **Contraintes de commande** : la puissance de chauffage doit être comprise entre 0 W (P_{min}) et 5000 W (P_{max}).

$$P_{min} \leq P(t) \leq P_{max} \quad (4.2)$$

- **Contraintes d'état** : la température intérieure de la zone doit être comprise entre 19°C (T_{min}) et 24°C (T_{max}).

$$T_{min} \leq T_{zone}(t) \leq T_{max} \quad (4.3)$$

De plus, nous considérons une vitesse maximale de variation de la température de l'air définie par l'ASHRAE 55 - 1992. :

$$\frac{dT_{zone}}{dt} \leq 2,2^\circ\text{C} / \text{h} \quad (4.4)$$

2.2.2 Tarifs de l'électricité

Dans l'objectif d'effacer la consommation électrique pendant les heures de pointe, le prix du kilowattheure d'électricité considéré est ici multiplié par deux par rapport aux heures pleines. Deux tarifs différents étant déjà proposés en France en fonction de l'heure de la journée (heures creuses et heures pleines), la grille tarifaire utilisée dans cette étude considère par conséquent trois tarifs différents de l'électricité (Tableau 15).

Tableau 15 : Tarifs des heures creuses, pleines et de pointe

	Heures creuses	Heures pleines	Heures de pointe
Horaire	0h-9h	9h-17h 22h-0h	17h-22h
Prix du kWh en €	0,0864	0,1275	0,255

3. MÉTHODOLOGIE

3.1 Algorithme d'optimisation

3.1.1 La programmation dynamique

La programmation dynamique est une méthode d'optimisation développée par R. Bellman (1957). Il s'agit d'un algorithme d'optimisation séquentiel permettant d'obtenir l'optimum global en balayant l'ensemble des solutions possibles étant donnée une discrétisation.

Pour appliquer la programmation dynamique, une variable d'état décrivant le système est utilisée et discrétisée temporellement :

$$x(t) = x_t \in X_t, X_t \subset \mathbb{R}^{N_s} \quad (4.5)$$

avec X_t l'ensemble des états admissibles et N_s la dimension de X_t . Le vecteur commande u , également discrétisé temporellement, peut être choisi dans l'ensemble $U_t \subset \mathbb{R}^{N_c}$ (représentant l'ensemble des commandes admissibles), de dimension N_c :

$$u(t) = u_t \in U_t, U_t \subset \mathbb{R}^{N_c} \quad (4.6)$$

On peut alors agir sur l'état du système à travers la variable de commande u . L'équation d'état du système dynamique $f(\cdot)$ est ainsi :

$$x(t) = x_t, \quad x(t+1) = f(x(t), u(t)) \quad (4.7)$$

Une fonction coût v_t est également définie, représentant le coût du passage d'un état x à t à un autre état x à $t+1$:

$$v_t(x_t, x_{t+1}) \quad (4.8)$$

Sous ces hypothèses, le problème d'optimisation séquentielle à horizon fini prend la forme suivante :

$$V_0^t = \min \left[\sum_{j=0}^{t-1} v_j(x_j, x_{j+1}) \right] \quad (4.9)$$

sous les contraintes d'état et de commande (5) et (6) et l'équation d'état (7). V_0^t représente la politique optimale, ou plus précisément le vecteur commande correspondant, qui minimise la fonction coût tout en respectant les contraintes. Pour éviter de calculer le coût total de l'ensemble des politiques possibles, le principe d'optimalité de Bellman est alors utilisé pour diviser le problème de décision en des problèmes plus courts. Il stipule qu'« une politique optimale ne peut être formée que de sous-politiques optimales ». Ainsi l'équation (9) devient :

$$V_0^t = \min \left[v_0(x_0, x_1) + \min \left[\sum_{j=1}^{t-1} v_j(x_j, x_{j+1}) \right] \right] \quad (4.10)$$

Cela signifie qu'à un pas de temps donné, si plusieurs politiques arrivent au même état, il suffit alors de ne conserver que la politique optimale, les autres politiques pouvant être éliminées. Ainsi, de nombreuses politiques sont rejetées à chaque séquence et le nombre de calculs à effectuer est réduit. Ce fonctionnement est présenté dans la Figure 50.




Figure 50: Fonctionnement de la programmation dynamique

Dans la figure précédente, la variable d'état du système est divisée en cinq états et l'optimisation a pour but de minimiser la fonction coût. Dans cet exemple, par application du principe d'optimalité de Bellman, quatre solutions peuvent être éliminées, soit parce qu'elles ne respectent pas les contraintes, soit parce qu'elles atteignent un même état que des politiques dont le coût est plus faible.

3.1.2 Les paramètres de la programmation dynamique

Dans notre cas d'étude, on souhaite appliquer la programmation dynamique à la gestion énergétique d'un bâtiment et plus précisément déterminer la stratégie optimale qui minimise le coût de la consommation énergétique (1) tout en respectant les contraintes de commande (2) et les contraintes d'état (3)-(4). La variable d'état à utiliser doit alors représenter de manière synthétique l'état du bâtiment ainsi que son comportement, c'est-à-dire son évolution thermique caractérisée par des changements de température des mailles le modélisant. Ainsi, la variable d'état retenue est l'énergie

Chapitre 4 : Élaboration de lois de type heuristique

totale stockée dans le bâtiment, c'est-à-dire la somme des énergies de toutes les mailles (Favre et Peuportier 2014) :

$$E_t = \sum_{i=0}^{N_{mailles}} C_i (T_i - T_{ref}) \quad (4.11)$$

avec

- T_i la température de la maille i ;
- C_i la capacité thermique de la maille i ;
- T_{ref} la température de référence fixée à 0°C ;
- $N_{mailles}$ le nombre de mailles.

Dans notre cas d'application, une limite supérieure et inférieure de la plage de variation de la variable d'état a été définie selon sa valeur initiale. Le nombre de discrétisations de cette plage a été fixé à 800 suite à l'analyse de sensibilité réalisée par Favre (2013) permettant de réaliser un bon compromis entre précision de l'algorithme, durée de l'optimisation et besoin en mémoire vive.

L'utilisation de cette variable d'état amène une remarque. En effet, par l'application de la programmation dynamique, lorsque deux politiques atteignent la même valeur d'énergie totale stockée, seule la politique la moins coûteuse selon la fonction coût est conservée. Or, des valeurs d'énergies totales stockées égales n'impliquent pas forcément deux états identiques du bâtiment. En effet, les températures de maille peuvent être différentes même si la somme des énergies de toutes les mailles est identique. Cependant, dans notre cas d'application, à savoir un bâtiment avec une forte inertie, on peut supposer que les températures des mailles sont proches car elles varient lentement dans ce type de bâtiment (hormis dans la maille d'air) et donc varient peu entre deux pas de temps d'une heure. Par conséquent, en partant du même état initial, et en changeant uniquement la stratégie de chauffage, il est peu probable d'avoir deux situations ayant la même énergie stockée et des températures sensiblement différentes. Pour plus de détails sur l'application de la programmation dynamique à la gestion énergétique du bâtiment, il est conseillé au lecteur de se reporter à la thèse de Favre (2013).

3.2 Élaboration des lois heuristiques

L'objectif de l'élaboration des lois heuristiques est de déterminer des lois de commande simplifiées à partir des résultats de la programmation dynamique. Ces lois de commande permettront alors de calculer la puissance de chauffage (variable à prédire) à injecter selon différentes variables explicatives telles que la température intérieure de la zone ou encore la température extérieure. Différentes méthodes de régression peuvent être utilisées pour analyser la relation entre la variable à prédire et les variables explicatives.

3.2.1 Les méthodes de régression

L'objectif des méthodes de régression est d'expliquer les valeurs prises par une variable à prédire y à l'aide de p variables explicatives x_j ($j = 1, \dots, p$). Dans notre cas d'application, les observations y_i (de la variable à prédire y) correspondent à la puissance de chauffage calculée par la programmation dynamique, et les variables explicatives $x_{i,j}$ correspondent par exemple à la température de la zone, aux conditions météorologiques extérieures ou encore aux tarifs de l'électricité. Cependant, les observations y_i sont bornées entre P_{min} et P_{max} . Nous utilisons alors la transformation $\tilde{y}_i = (y_i - P_{min}) / (P_{max} - P_{min})$ pour normaliser les observations sur l'intervalle $[0,1]$.

3.2.1.1 La régression linéaire multiple

La régression linéaire multiple est une méthode de régression classiquement utilisée. Elle correspond à la généralisation multivariée de la régression linéaire simple. On peut ainsi écrire l'équation de régression suivante :

$$y_i = a_0 + a_1x_{i,1} + \dots + a_px_{i,p} + \varepsilon_i \quad (4.12)$$

avec :

- $i = 1, \dots, n$ le numéro des observations ;
- y_i la i -ème observation de la variable à prédire y ;
- $x_{i,j}$ la i -ème observation de la j -ème variable explicative ;
- a_j ($j = 0, \dots, p$), les $(p + 1)$ paramètres estimés par la méthode des moindres carrés ;
- ε_i l'erreur du modèle, résumant l'information qui n'est pas prise en compte dans la relation entre les valeurs prises par y et les p variables explicatives x_j .

La régression linéaire multiple repose sur plusieurs hypothèses, dont les principales sont que l'erreur a une espérance nulle, une variance constante (on parle alors d'homoscédasticité) et qu'elle est distribuée selon une loi normale. La régression linéaire multiple n'est cependant pas adaptée à notre cas d'application. Une des raisons principales est qu'elle pourrait prédire des valeurs en dehors de l'intervalle $[P_{min}, P_{max}]$.

3.2.1.2 La régression Bêta

Une alternative consiste alors à utiliser la régression Bêta. Cette méthode a été introduite par Ferrari et Cribari-Neto (2004) et permet de modéliser des variables continues qui admettent leurs valeurs dans l'intervalle $]0; 1[$. La régression Bêta est basée sur un paramétrage différent de la loi Bêta. Usuellement, la fonction de densité de probabilité de la loi Bêta (p,q) est donnée par :

$$\pi(y, p, q) = \frac{\Gamma(p + q)}{\Gamma(p) * \Gamma(q)} y^{p-1} (1 - y)^{q-1}, \quad 0 < y < 1 \quad (4.13)$$

Chapitre 4 : Élaboration de lois de type heuristique

avec $p > 0, q > 0$ et $\Gamma(\cdot)$ la fonction gamma d'Euler. L'espérance et la variance de y sont alors respectivement $E(y) = \frac{p}{p+q}$ et $\text{Var}(y) = \frac{pq}{(p+q)^2(p+q+1)}$.

Dans l'objectif de réaliser une régression par rapport à l'espérance de la réponse y , Ferrari et Cribari-Neto (2004) proposent alors de modifier cette loi en posant $\mu = \frac{p}{p+q}$ et $\phi = p + q$:

$$\pi(y, \mu, \phi) = \frac{\Gamma(\phi)}{\Gamma(\mu\phi) * \Gamma((1-\mu)\phi)} y^{\mu\phi-1} (1-y)^{(1-\mu)\phi-1}, 0 < y < 1 \quad (4.14)$$

où $E(y) = \mu$ et $\text{Var}(y) = \frac{\mu(1-\mu)}{1+\phi}$. Le paramètre ϕ peut alors être interprété comme un paramètre de précision.

Soient y_1, \dots, y_n des variables aléatoires indépendantes et distribuées suivant la fonction de densité donnée à l'équation (4.14), le modèle de régression Bêta est alors défini par :

$$g(\mu_i) = g(E(y_i)) = b_0 + b_1 x_{i,1} + \dots + b_p x_{i,p} \quad (4.15)$$

avec b_j ($j = 0, \dots, p$) les paramètres de régression estimés par maximum de vraisemblance, et $g(\cdot)$ une fonction de lien strictement monotone, deux fois dérivable, surjective, définie sur l'intervalle $]0; 1[$ et à valeurs dans \mathbb{R} . La variance de y est une fonction dépendante de μ , par conséquent le modèle prend en compte les éventuels défauts d'homoscédasticité. Plusieurs fonctions de lien existent telles que la fonction logit $g(\mu) = \ln\left(\frac{\mu}{1-\mu}\right)$ ou encore la fonction probit $g(\mu) = \Phi^{-1}(\mu)$, avec Φ la fonction de répartition de la loi normale centrée réduite. Dans notre cas d'application, nous utiliserons la fonction logit qui est la fonction la plus couramment utilisée.

La régression Bêta ne s'applique qu'à des observations comprises dans l'intervalle $]0; 1[$. Lorsque les observations comprennent les valeurs limites 0 et 1, une pratique classique est de remplacer les observations y_i par $(y_i(n-1) + 0,5)/n$, où n est le nombre d'observations (Smithson et Verkuilen 2006 ; Schmid et al. 2013).

Dans l'objectif de l'élaboration de lois heuristiques, la régression Bêta a été choisie car elle permet de modéliser des variables continues bornées et qu'elle présente une grande flexibilité (la loi bêta admet une grande variété de formes permettant de modéliser de nombreuses distributions).

3.2.2 Méthodologie

Une méthodologie a été développée pour déterminer des lois de commande simplifiées à partir des résultats de la programmation dynamique (Figure 51). On utilise la programmation dynamique d'une part pour générer des données d'entraînement pour identifier les paramètres de la régression Bêta, et d'autre part pour générer des données de validation pour évaluer la fiabilité des modèles de régression Bêta identifiés. Cette procédure se déroule en deux étapes.

Lors de la première étape, des données météorologiques typiques sont utilisées pour calculer, grâce à la programmation dynamique, la stratégie optimale de commande de la puissance de chauffage. Cette stratégie optimale, correspondant aux données d'entraînement, est ensuite utilisée pour identifier

Chapitre 4 : Élaboration de lois de type heuristique

les paramètres de la régression Bêta et ainsi déterminer des lois de commande simplifiées. Une année météorologique typique (TMY pour *Typical Meteorological Year*) correspond à une série temporelle synthétique de données météorologiques horaires et présente l'intérêt d'être représentative de la climatologie d'une région donnée. Elle consiste en une compilation de différentes périodes de données météorologiques provenant de plusieurs années de mesures. Plus précisément, elle est constituée d'une suite de jours réels assemblés de façon à s'assurer que les moyennes mensuelles des paramètres météorologiques (température, rayonnement...) correspondent aux moyennes réelles. Ainsi, les aspects dynamiques sont conservés. L'utilisation de ce type de données météorologiques permet d'identifier des lois de commandes simplifiées les plus générales possible et adaptées à la météorologie moyenne de la région du cas d'étude. Cette première étape correspond à l'étape d'identification des modèles heuristiques (optimisation hors-ligne).

Lors de la deuxième étape, la fiabilité des modèles heuristiques est évaluée sur des données météorologiques réelles. Ainsi, on se place dans un cas d'application réel. Les résultats obtenus par les lois de commande simplifiées (identifiées à la première étape) sont alors comparés à la stratégie optimale calculée par la programmation dynamique (données de validation). Cette deuxième étape correspond à l'étape d'évaluation de la fiabilité des modèles heuristiques (optimisation en ligne).

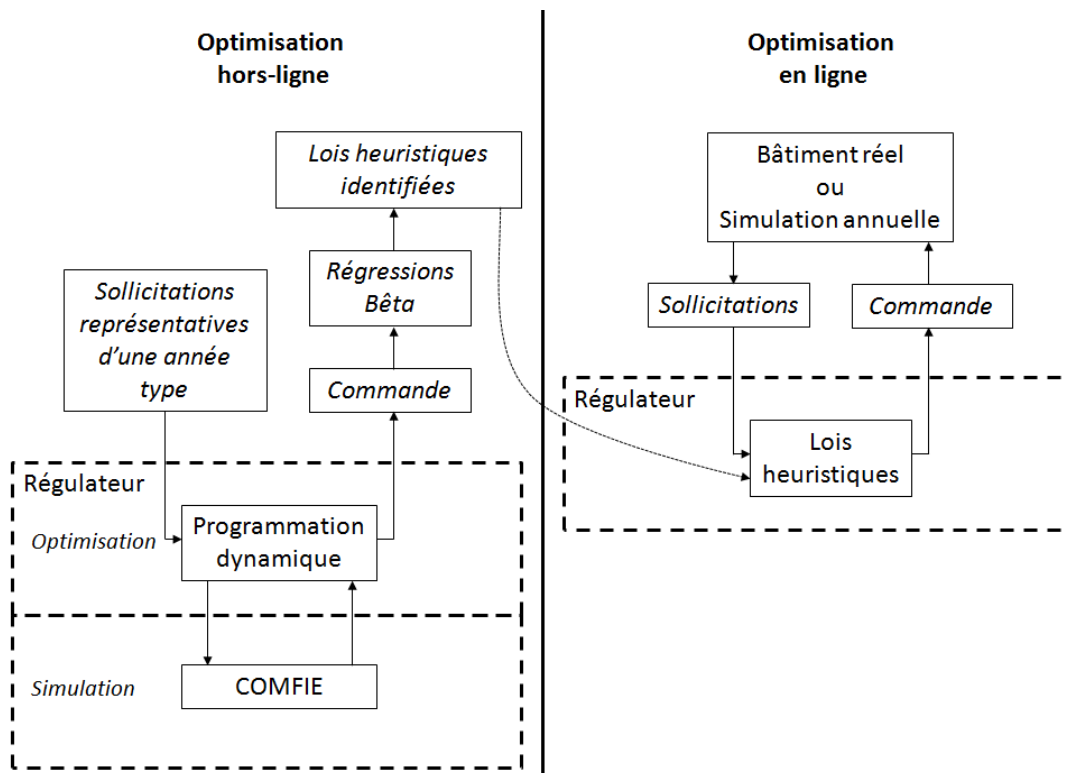


Figure 51 : Identification des lois heuristiques à partir de la programmation dynamique

3.2.2.1 Identification des modèles heuristiques

L'identification des modèles heuristiques se fait en quatre étapes (Figure 52) :

- Les données nécessaires au calcul de la stratégie optimale par la programmation dynamique sont collectées (données météorologiques de type TMY, tarifs de l'électricité, occupation du bâtiment).
- La stratégie optimale est calculée. Ces données correspondent aux données d'entraînement.
- Les paramètres du modèle de régression Bêta sont identifiés grâce aux données d'entraînement.
- Les lois de commande simplifiées alors identifiées sont implémentées dans la plateforme de simulation COMFIE.




Figure 52 : Identification des modèles heuristiques

3.2.2.2 Évaluation de la fiabilité des modèles heuristiques

L'évaluation de la fiabilité des modèles heuristiques se déroule en trois étapes (Figure 53) :

- Les données nécessaires au calcul de la puissance de chauffage soit par la programmation dynamique, soit par les lois de commande simplifiées sont collectées (données météorologiques réelles, tarifs de l'électricité, occupation du bâtiment).
- La stratégie optimale (calculée par la programmation dynamique) et les stratégies opérationnelles (calculées par les lois de commande simplifiées) sont déterminées.
- Les performances des stratégies opérationnelles par rapport à la stratégie optimale sont évaluées.

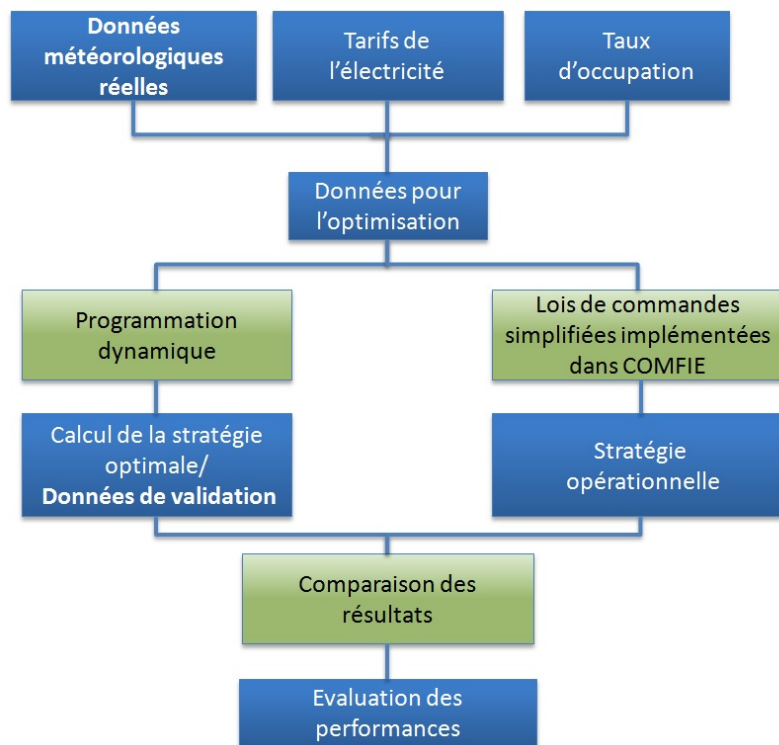


Figure 53 : Evaluation de la fiabilité des modèles heuristiques

3.2.3 Variables explicatives

L'objectif étant de développer un système de contrôle reposant sur des lois de commande simplifiées, seules des variables explicatives facilement mesurables dans le bâtiment sont utilisées par les modèles de régression Bêta. Ainsi pour déterminer la puissance de chauffage P au temps $t + \Delta t$ (Δt représentant le pas de temps, une heure dans notre cas d'application), nous considérons :

- la prévision de la température extérieure T_{ext} aux temps $t + \Delta t$, $t + 3\Delta t$ et $t + 6\Delta t$;
- la prévision du rayonnement solaire global horizontal G_h aux temps $t + \Delta t$, $t + 3\Delta t$ et $t + 6\Delta t$;
- le tarif de l'électricité C_{elec} aux temps $t + \Delta t$, $t + 3\Delta t$ et $t + 6\Delta t$;
- la température minimale acceptable dans les locaux à chauffer (zone thermique) T_{min} aux temps $t + \Delta t$, $t + 3\Delta t$ et $t + 6\Delta t$;
- la température de la zone T_{zone} aux temps t , $t - \Delta t$, $t - 3\Delta t$, $t - 6\Delta t$, $t - 12\Delta t$ et $t - 24\Delta t$;
- la puissance de chauffage utilisée aux temps t , $t - \Delta t$, $t - 3\Delta t$, $t - 6\Delta t$, $t - 12\Delta t$ et $t - 24\Delta t$.

L'utilisation des variables explicatives à différents pas de temps permet d'une part d'anticiper les évolutions météorologiques, les tarifs de l'électricité ainsi qu'un changement éventuel de la température minimale autorisée, et d'autre part de conserver en mémoire l'état du bâtiment et les puissances de chauffage précédemment calculées.

L'estimation des paramètres de la combinaison linéaire des variables explicatives est réalisée par maximum de vraisemblance. Cependant, certaines valeurs de ces paramètres ne diffèrent pas statistiquement de zéro de manière significative, amenant à ne pas considérer dans la régression la variable explicative associée. Ainsi, le modèle de régression Bêta finalement identifié peut conserver un nombre de variables explicatives inférieur au nombre initial (21 variables explicatives considérées au départ). Cette estimation des valeurs des paramètres se fait selon une procédure d'élimination progressive (« *Backward Elimination* ») consistant à éliminer de proche en proche (c'est-à-dire en ré-estimant la combinaison linéaire après chaque élimination) les variables explicatives non significatives statistiquement. Par exemple dans notre cas d'application, la température minimale T_{min} étant fixée à 19°C pendant toute la période de l'étude, les variables explicatives correspondantes ne sont pas utilisées.

3.2.4 Modèles développés

Cinq modèles de régression Bêta ont été développés, chacun utilisant tout ou partie des données d'entraînement (Tableau 16). Les données d'entraînement ont été divisées en trois groupes : les données d'entraînement « heures creuses » $DE_{heures\ creuses}$, les données d'entraînement « heures pleines » $DE_{heures\ pleines}$ et les données d'entraînement « heures de pointe » $DE_{heures\ pointe}$.

Chapitre 4 : Élaboration de lois de type heuristique

Par exemple, toutes les données d'entraînement ont été utilisées pour identifier le modèle de régression BETA_1, alors que seules les données d'entraînement correspondant aux heures creuses l'ont été pour le modèle de régression BETA_3.

Pour s'assurer de l'effacement de la puissance de chauffage au temps $t + \Delta t$ durant les heures de pointe ou les heures pleines, cette puissance a été fixée à 0 W dans les cas suivants :

- pendant les heures de pointe pour les modèles de régression BETA_2, BETA_3, BETA_4 et BETA_5,
- pendant les heures pleines pour les modèles de régression BETA_3 et BETA_5.

Tableau 16 : Données d'entraînement

	Heures creuses	Heures pleines	Heures de pointe
BETA_1	$DE_{heures\ creuses}$	$DE_{heures\ pleines}$	$DE_{heures\ pointe}$
BETA_2	$DE_{heures\ creuses}$	$DE_{heures\ pleines}$	$P = 0$
BETA_3	$DE_{heures\ creuses}$	$P = 0$	$P = 0$
BETA_4	$DE_{heures\ creuses}$	$DE_{heures\ pleines}$	$DE_{heures\ pointe},$ $P = 0$
BETA_5	$DE_{heures\ creuses}$	$DE_{heures\ pleines},$ $P = 0$	$DE_{heures\ pointe},$ $P = 0$

Ainsi, les modèles BETA_3 et BETA_5 sont différents car ils n'utilisent pas les mêmes données d'entraînement. En effet, le modèle BETA_3 est entraîné seulement sur les données d'entraînement correspondant aux heures creuses alors que le modèle BETA_5 utilise l'ensemble des données d'entraînement. Cependant, lors de l'implémentation, la puissance de chauffage au temps $t + \Delta t$ est fixée à 0 W lors des heures pleines et de pointe pour les deux modèles. La même logique peut être appliquée pour les modèles BETA_2 et BETA_4.

3.2.5 Critères d'évaluation des résultats

Des critères objectifs doivent être utilisés pour évaluer la qualité de prédiction des lois de commande simplifiées. Nous avons ainsi considéré les indicateurs suivants :

- la puissance moyenne calculée ;
- le coût cumulé ;
- le pourcentage d'heures de pointe effacées ;
- le pourcentage d'heures pleines effacées ;
- les taux d'inconfort :
 - TI_{min} : durée (en %) où $T_{zone}(t) \leq T_{min}$;

Chapitre 4 : Élaboration de lois de type heuristique

- TI_{max} : durée (en %) où $T_{zone}(t) \geq T_{max}$;
- le nombre de fois où la vitesse de variation entre deux pas de temps de la température de zone est supérieure à la vitesse maximale de variation autorisée (N_{var_max}).

Enfin, dans l'objectif d'évaluer la fiabilité des modèles heuristiques, le biais moyen MBE entre les puissances de chauffage calculées par la programmation dynamique et les lois de commandes simplifiées est également utilisé.

4. RÉSULTATS

4.1 Données météorologiques

Les données météorologiques utilisées pour l'identification des modèles heuristiques correspondent aux données de type TMY de la ville de Chambéry. Ainsi, les modèles de régression (et par conséquent les lois de commande simplifiées) sont identifiés sur des données climatiques représentant les conditions météorologiques typiques de la zone considérée. Concernant les données météorologiques utilisées pour évaluer la fiabilité des modèles heuristiques identifiés, elles correspondent à des données mesurées à l'aéroport du Bourget-du-Lac (ville voisine de Chambéry) situé à 300 mètres du bâtiment. Dans notre cas d'application, nous considérons un mois (31 jours) de données mesurées allant du 15 janvier 2012 au 14 février 2012 (l'horizon d'optimisation est alors également fixé à 31 jours pour la programmation dynamique). Grâce à ces données météorologiques mesurées, il est possible d'évaluer la performance des lois de commande simplifiées en conditions réelles. Les caractéristiques générales des données météorologiques sont résumées dans le Tableau 17.

Tableau 17 : Données météorologiques

	Données météorologiques d'entraînement	Données météorologiques de validation
Température minimale (°C)	-9,10	-14
Température moyenne (°C)	1,44	-0,22
Température maximale (°C)	11,50	11,33
Rayonnement global horizontal moyen (W/m ²)	58	60
Rayonnement global horizontal maximal (W/m ²)	486	569

4.2 Influence des données d'entraînement sur les régressions Bêta

Les cinq modèles de régression Bêta ont été identifiés et implémentés dans la plateforme de simulation COMFIE. L'Annexe D rassemble les résultats de l'identification de ces cinq modèles (à savoir les variables explicatives conservées ainsi que l'estimation des paramètres de la combinaison linéaire des variables explicatives). Les résultats obtenus par les modèles de régression Bêta sur les données de validation sont indiqués dans le Tableau 18. Les résultats de référence obtenus par la programmation dynamique (données de validation) sont présentés dans la colonne PD.

Tableau 18 : Résultats des modèles de régression Bêta

	BETA_1	BETA_2	BETA_3	BETA_4	BETA_5	PD
Puissance moyenne (W)	2719	1482	1027	2693	1869	980
Coût cumulé (€)	273	116	66	211	120	65
Heures de pointe effacées (%)	0	100	100	100	100	100
Heures pleines effacées (%)	0	0	100	0	100	88
TI_{min} (%)	0	0	13	0	0	0
TI_{max} (%)	99	47	0	98	85	0
T_{min}/T_{max}	21,8/40,3	21,4/27,6	18,6/23	21,5/40,1	19,6/32,6	19/23,4
N_{var_max}	1	19	23	26	62	0
MBE (%)	-178	-51	-5	-175	-91	-

Les résultats obtenus par les modèles BETA_1, BETA_2 et la programmation dynamique lors de la quatrième semaine sont présentés dans la Figure 54 . On peut clairement observer que les modèles BETA_1 et BETA_2 ne suivent pas le comportement de la programmation dynamique. Par exemple, on peut constater que le modèle BETA_1 présente un taux d'inconfort TI_{max} très élevé (99 %), et une température maximale T_{max} de 40,3°C. De plus son coût cumulé est quatre fois supérieur à celui de la programmation dynamique (273 € et 65 € respectivement). Les remarques sont les mêmes pour le modèle BETA_2. En effet, il présente un coût cumulé important (116 €) et un taux d'inconfort TI_{max} non négligeable avec une température maximale atteinte de 27,6°C. Par conséquent, les modèles BETA_1 et BETA_2 ne sont pas retenus comme candidats pour des systèmes de contrôle simplifiés.

La Figure 55 montre également que les résultats obtenus par les modèles BETA_4 et BETA_5 sont très différents de ceux de la programmation dynamique. Par exemple, les modèles BETA_4 et BETA_5

Chapitre 4 : Élaboration de lois de type heuristique

ont des coûts cumulés significatifs (211 € et 120 € respectivement) et une puissance de chauffage moyenne importante (2693 W et 1869 W respectivement). De plus, les taux d'inconfort TI_{max} compris entre 85 % et 98 % sont extrêmement élevés. En conséquence, les modèles BETA_4 et BETA_5 ne sont pas retenus comme candidats pour des lois de commandes simplifiées.

Finalement, on peut noter le comportement intéressant du modèle BETA_3 (Figure 56). Tout d'abord, de par sa construction, il permet d'effacer 100 % des heures de pointe et pleines. De plus, son coût cumulé et sa puissance moyenne sont proches de ceux de la programmation dynamique (66 € et 1027 W à comparer à 65 € et 980 W pour la programmation dynamique). Ensuite, il présente un biais moyen raisonnable de -5 %. L'ensemble des résultats des modèles de régression Bêta pour les autres semaines se trouve dans l'Annexe E. Enfin, ce modèle ne repose que sur l'utilisation de quatre variables explicatives, à savoir $T_{ext}(t + 6\Delta t)$, $G_h(t + 6\Delta t)$, $T_{zone}(t)$ et $P(t)$. Il est intéressant de noter que l'horizon de prévision de la température et du rayonnement est le même ($6\Delta t$).

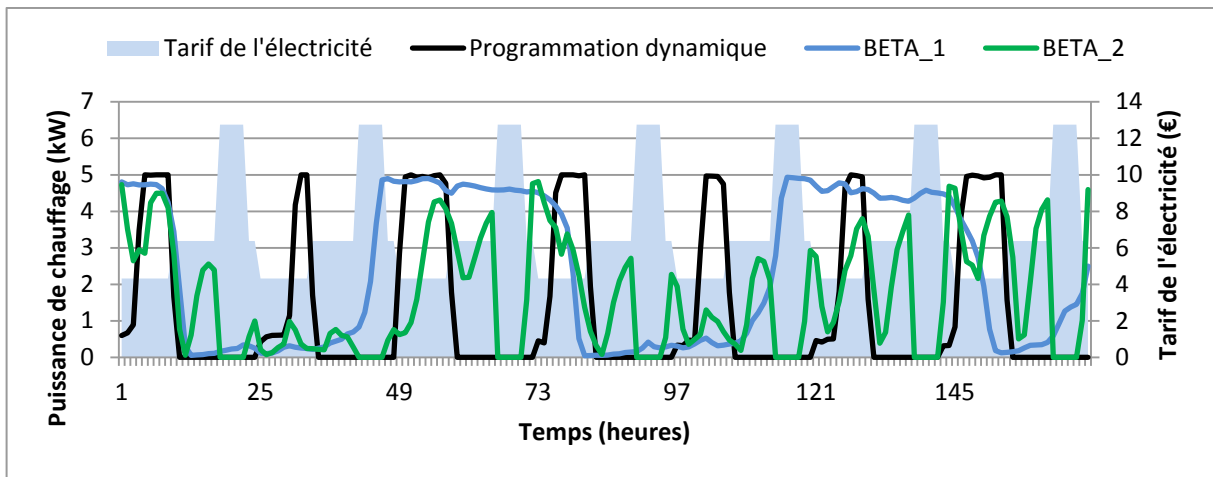


Figure 54 : Puissances de chauffage calculées par la programmation dynamique, BETA_1 et BETA_2 (quatrième semaine)




Figure 55 : Puissances de chauffage calculées par la programmation dynamique, BETA_4 et BETA_5 (quatrième semaine)

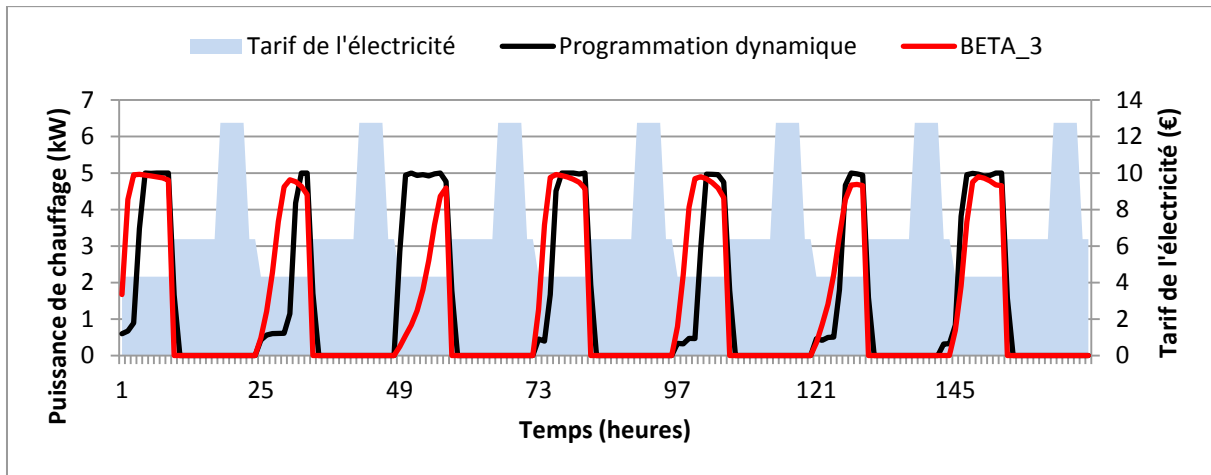


Figure 56 : Puissances de chauffage calculées par la programmation dynamique et BETA_3 (quatrième semaine)

Le modèle BETA_3 présente donc un comportement satisfaisant et semble être un bon candidat pour être utilisé comme un système de contrôle simplifié. Cependant, à plusieurs occasions, il ne respecte pas les contraintes de température. En effet, il présente un taux d'inconfort TI_{min} de 13 % avec un écart moyen de 0,1°C. Ainsi en moyenne, pendant 13 % du temps, le modèle chauffe à 18,9°C au lieu de 19°C (avec une température minimale atteinte T_{min} de 18,6°C). De plus, la vitesse maximale de variation de la température entre deux pas de temps n'est pas respectée à 23 occasions. Cependant, ce non respect apparaît à chaque fois lors de la transition entre les heures creuses et les heures pleines (9h), c'est-à-dire lorsque le bâtiment n'est pas occupé (sauf pendant le week-end). Il s'agit donc d'un non-respect acceptable de la contrainte de variation de température.

Pour améliorer le comportement du modèle BETA_3 et respecter la contrainte de température minimale de confort, un contrôleur qui est activé dès que la température de la zone ne respecte pas les contraintes de confort peut être mis en place.

4.3 Utilisation d'un contrôleur

Un contrôleur *on-off* idéal est considéré dans notre cas d'étude. Il est appliqué pendant les heures pleines et de pointe lorsque le modèle BETA_3 ne fonctionne pas. Sa loi de contrôle varie entre la puissance minimale de chauffage P_{min} (0 W) et la puissance maximale de chauffage P_{max} (5000 W). Plus précisément, le contrôleur *on-off* idéal est activé dès que la température intérieure est inférieure à $19^\circ\text{C} - \varepsilon$ et désactivé lorsque cette dernière est supérieure à $19^\circ\text{C} + \varepsilon$ (l'objectif étant de respecter la température de consigne de 19°C). Ainsi, en supposant que ε tend vers 0, la bande morte du contrôleur *on-off* ($\pm\varepsilon$) tend également vers 0. Ce contrôleur permet ainsi de calculer la puissance de chauffage exacte $P_{idéal}$ pour atteindre 19°C . En pratique, le modèle BETA_3 calcule la puissance de chauffage toutes les heures alors que le contrôleur agit sur des pas de temps beaucoup plus courts. L'utilisation de ce contrôleur *on-off* idéal en simulation numérique permet alors de s'affranchir de ces contraintes et d'évaluer les performances maximales (théoriques) atteintes par le modèle BETA_3 + contrôleur.

Chapitre 4 : Élaboration de lois de type heuristique

La loi de contrôle considérée est la suivante :

- pendant les heures creuses

$$P(t + \Delta t) = \begin{cases} \text{BETA_3} & T_{zone}(t) \leq T_{max} \\ 0 & T_{zone}(t) > T_{max} \end{cases} \quad (4.16)$$

- pendant les heures pleines et de pointe

$$P(t + \Delta t) = \begin{cases} P_{idéal} & \text{si } T_{zone}(t) < 19^\circ\text{C} - \varepsilon \\ 0 & \text{si } T_{zone}(t) \geq 19^\circ\text{C} + \varepsilon \end{cases} \quad \varepsilon \rightarrow 0 \quad (4.17)$$

Les résultats obtenus sont résumés dans le Tableau 19 où l'on peut remarquer le comportement intéressant du modèle BETA_3 + contrôleur. Tout d'abord, grâce au contrôleur on-off idéal, le modèle BETA_3 + contrôleur respecte les températures de contraintes (la température minimale atteinte étant 19°C). La mise en place du contrôleur n'engendre pas de changement concernant le non-respect de la vitesse maximale de variation de la température. Il entraîne une légère dégradation concernant l'effacement des heures pleines et de pointe. Par exemple, le modèle BETA_3 + contrôleur efface 84 % des heures de pointe à comparer aux 100 % du modèle BETA_3 et de la programmation dynamique. De même, 81 % des heures pleines sont effacées, à comparer aux 100 % pour le modèle BETA_3 et aux 88 % de la programmation dynamique. Cependant, cette dégradation est limitée. En effet, la puissance moyenne utilisée lors des heures de pointe non effacées par le modèle BETA_3 + contrôleur est de 134 W alors que celle utilisée lors des heures pleines non effacées est de 159 W. Enfin, le modèle BETA_3 + contrôleur présente un coût cumulé (67 €) et une puissance moyenne proche (1028 W) proches du modèle BETA_3 et des résultats de la programmation dynamique.

Tableau 19 : Résultats du modèle de régression BETA_3 + contrôleur

	BETA_3	BETA_3 + contrôleur	PD
Puissance moyenne (W)	1027	1028	980
Coût cumulé (€)	66	67	65
Heures de pointe effacées (%)	100	84	100
Heures pleines effacées (%)	100	81	88
TI_{min} (%)	13	0	0
TI_{max} (%)	0	0	0
T_{min}/T_{max}	18,6/23	19/23,1	19/23,4
N_{var_max}	23	23	0
MBE (%)	-5	-5	-

Chapitre 4 : Élaboration de lois de type heuristique

Par conséquent, l'utilisation d'un contrôleur *on-off* idéal permet d'améliorer le comportement du modèle BETA_3 et de respecter les contraintes de température. Le comportement du modèle BETA_3 avec ou sans contrôleur lors de la quatrième semaine est représenté dans la Figure 57. Leurs courbes sont quasiment confondues à l'exception de l'activation du contrôleur lors des heures pleines ou de pointe pour s'assurer du maintien de la température intérieure à 19°C. L'ensemble des résultats pour les autres semaines se trouvent dans l'Annexe E.

Le modèle BETA_3 + contrôleur présente donc un comportement satisfaisant pour être utilisé comme une loi de commande simplifiée. Pour valider son comportement, il peut être intéressant de comparer ses résultats à ceux d'une loi purement heuristique.




Figure 57 : Puissances de chauffage calculées par la programmation dynamique, BETA_3 et BETA_3 + contrôleur (quatrième semaine)

4.4 Comparaison à une loi de commande classique

Le développement du modèle BETA_3 a nécessité un effort de développement non négligeable. Pour valider son intérêt, une comparaison avec une loi heuristique pure est nécessaire.

Les résultats du §4.2 ont démontré que le modèle imposant une puissance de chauffage nulle pendant les heures pleines et de pointe obtenait les meilleurs résultats. Cependant, ce constat aurait pu être supposé de manière intuitive. Ainsi, il est intéressant de comparer les résultats du modèle BETA_3 avec ceux d'une loi de commande classique ne chauffant que pendant les heures creuses. L'avantage d'anticipation du modèle BETA_3 (c'est-à-dire savoir à quel moment surchauffer le bâtiment pour stocker l'énergie) peut alors être évalué par rapport à cette loi de commande classique.

Chapitre 4 : Élaboration de lois de type heuristique

La loi heuristique considérée est la suivante :

- pendant les heures creuses, on chauffe pour atteindre la température maximale T_{max} et stocker la chaleur (l'objectif étant de ne pas chauffer pendant les heures pleines et de pointe) ;
- pendant les heures pleines et de pointe, on chauffe si besoin pour maintenir la température minimale T_{min} .

Le Tableau 20 rassemble les résultats obtenus. On peut tout t'abord constater que la loi purement heuristique permet d'effacer toutes les heures pleines et de pointe (contrairement au modèle BETA_3 + contrôleur et à la programmation dynamique). Cependant, elle présente un coût cumulé bien supérieur à celui du modèle BETA_3 + contrôleur (84 € et 67 € respectivement). Le constat est le même pour la puissance moyenne de chauffage utilisée (1307 W et 1028 W respectivement). Enfin, le biais moyen de -33 % est important comparé à celui du modèle BETA_3 + contrôleur (-5 %).

Tableau 20 : Résultats du contrôleur heuristique

	BETA_3 + contrôleur	Heuristique	PD
Puissance moyenne (W)	1028	1307	980
Coût cumulé (€)	67	84	65
Heures de pointe effacées (%)	84	100	100
Heures pleines effacées (%)	81	100	88
TI_{min} (%)	0	0	0
TI_{max} (%)	0	0	0
T_{min}/T_{max}	19/23,1	19,6/24	19/23,4
N_{var_max}	23	31	0
MBE (%)	-5	-33	-

Les comportements de la loi purement heuristique, du modèle BETA_3 + contrôleur et de la programmation dynamique sont présentés dans la Figure 58. L'ensemble des résultats pour les autres semaines se trouvent dans l'Annexe E.

Par conséquent, le modèle BETA_3 + contrôleur utilisé comme loi de commande simplifiée présente de meilleures performances pour optimiser le coût de la consommation de chauffage (avec un tarif de l'électricité variable) que la loi purement heuristique.




Figure 58 : Puissances de chauffage calculées par la loi purement heuristique, la programmation dynamique, et BETA_3 + contrôleur (quatrième semaine)

5. INFLUENCE DE LA PRÉVISION MÉTÉOROLOGIQUE SUR LA LOI HEURISTIQUE IDENTIFIÉE

Il est intéressant d'évaluer l'influence des erreurs de prévision météorologique sur la régulation obtenue par la loi heuristique identifiée (modèle BETA_3 + contrôleur). En effet, cette étude est indispensable pour juger de la robustesse de la loi de commande.

5.1 Modèle de prévision météorologique

Le modèle de prévision météorologique utilisé est celui présenté dans le chapitre 2. Pour rappel, les prévisions de température sont réalisées par un modèle de type ARMA qui modélise l'écart de température entre une station où nous disposons des prévisions de Météo France et le lieu où est situé le bâtiment étudié où l'on souhaite prédire la température. Les prévisions du rayonnement sont quant à elles réalisées par la prévision régionale.

5.1.1 Données météorologiques utilisées

Ne disposant pas de données météorologiques réelles sur la même année pour deux stations voisines du lieu d'étude (Chambéry), nous avons choisi d'utiliser les résultats obtenus au chapitre 2 (et en particulier les erreurs de prévisions) où les stations météorologiques de Paris et d'Orly sur l'année 2013 ont été considérées. On peut supposer que l'utilisation de données météorologiques de la région parisienne (au lieu de la région de Chambéry) peut amener à une majoration de l'erreur en raison de la présence d'un îlot de chaleur.

5.1.2 Développement des modèles

Dans notre cas d'application, nous souhaitons évaluer l'impact des erreurs de prévision météorologique sur le modèle BETA_3 + contrôleur. Ce modèle repose sur l'utilisation de quatre variables explicatives :

- la température extérieure au temps $t + 6\Delta t$, $T_{ext}(t + 6\Delta t)$;
- le rayonnement solaire global horizontal au temps $t + 6\Delta t$, $G_h(t + 6\Delta t)$;
- la température de zone au temps t , $T_{zone}(t)$;
- la puissance de chauffage utilisée au temps t , $P(t)$.

Par conséquent, nous allons nous concentrer sur les erreurs de prévision faites à $t + 6\Delta t$ par le modèle de prévision météorologique aussi bien pour la température extérieure que pour le rayonnement solaire global horizontal sur la période du 15/01/2013 au 14/02/2013.

5.1.2.1 Modélisation de la température

La méthodologie définie au chapitre 2 a été appliquée et les résultats de la prévision à $t + 6\Delta t$ sont présentés dans le Tableau 21 . Ils correspondent à la moyenne de l'indicateur MBE (erreur entre la prévision et la mesure) ainsi qu'à son écart-type sur 720 prévisions réalisées (30 jours \times 24 heures). On peut constater que les prévisions réalisées à $t + 6\Delta t$ ne sont pas biaisées.

Tableau 21 : Résultats de la prévision de la température (période du 15/01/2013 au 14/02/2013)

Prévision de la température (°C)	MBE ($t + 6\Delta t$)
Moyenne	0,02
Écart-type	1,1

5.1.2.2 Modélisation du rayonnement

Les résultats de la prévision à $t + 6\Delta t$ du rayonnement sont présentés dans le Tableau 22. Il s'agit de la moyenne de l'indicateur MBE (erreur entre la prévision et la mesure) ainsi que de l'écart type sur 300 prévisions réalisées (30 jours \times 10 heures) sur les heures diurnes (de 8h à 17h).

Tableau 22 : Résultats de la prévision du rayonnement (période du 15/01/2013 au 14/02/2013)

Prévision rayonnement (W/m ²)	MBE ($t + 6\Delta t$)
Moyenne	-0,38
Écart-type	17,35

5.2 Impact sur les lois heuristiques

5.2.1 Mise en place des données météorologiques

Une approche simplifiée pour évaluer l'impact des erreurs de prévision sur la loi heuristique a été mise en place. Pour cela, nous utilisons la moyenne des erreurs de prévision faites par le modèle de prévision ainsi que l'écart-type des erreurs de prévision. Trois études de cas sont réalisées.

Tout d'abord, dans l'objectif d'évaluer l'impact moyen des erreurs de prévision, les variables climatiques à prévoir à $t + 6\Delta t$ sont modifiées en y ajoutant les erreurs moyennes de prévision faites par le modèle de prévision. Ainsi, la température extérieure et le rayonnement solaire global horizontal au temps $t + 6\Delta t$ sont modifiés comme suit :

$$T_{ext}(t + 6\Delta t) = T_{ext}(t + 6\Delta t)_{mesurée} + 0,02^{\circ}C \quad (4.18)$$

et

$$G_h(t + 6\Delta t) = \max(G_h(t + 6\Delta t)_{mesurée} - 0,38 W/m^2 ; 0) \quad (4.19)$$

Ensuite, dans le but de majorer l'impact des erreurs de prévision, les variables climatiques à prévoir à $t + 6\Delta t$ sont modifiées en y ajoutant deux fois l'écart-type des erreurs de prévision. Ainsi, lorsque le modèle de prévision a tendance à surestimer les variables climatiques au temps $t + 6\Delta t$, les prévisions sont modifiées comme suit :

$$T_{ext}(t + 6\Delta t) = T_{ext}(t + 6\Delta t)_{mesurée} + 2 \times 1.1^{\circ}C \quad (4.20)$$

et

$$G_h(t + 6\Delta t) = \max(G_h(t + 6\Delta t)_{mesurée} + 2 \times 17,35 W/m^2 ; 0) \quad (4.21)$$

Enfin, dans le cas d'une sous-estimation, où les variables climatiques sont modifiées en soustrayant deux fois l'écart-type des erreurs de prévisions, on aura :

$$T_{ext}(t + 6\Delta t) = T_{ext}(t + 6\Delta t)_{mesurée} - 2 \times 1.1^{\circ}C \quad (4.22)$$

et

$$G_h(t + 6\Delta t) = \max(G_h(t + 6\Delta t)_{mesurée} - 2 \times 17,35 W/m^2 ; 0) \quad (4.23)$$

Il s'agit d'une majoration importante permettant de se placer dans un cas défavorable concernant les erreurs de prévision.

L'utilisation de données météorologiques de la région parisienne (au lieu de la région de Chambéry) peut également amener à une majoration de l'erreur. En effet, contrairement à la région de Chambéry, la région parisienne présente un îlot de chaleur important et potentiellement plus difficile à modéliser.

5.2.2 Comparaisons des régulations selon les données climatiques utilisées

Suite à la mise en place des données météorologiques, trois optimisations ont été réalisées : une première en considérant une erreur moyenne sur les prévisions météorologiques, une deuxième en ajoutant deux fois l'écart-type des erreurs de prévision et une troisième en soustrayant deux fois l'écart-type des erreurs de prévision. Les résultats obtenus sont résumés dans le Tableau 23. Les erreurs moyennes de prévision du modèle de prévision météorologique pour la température et le rayonnement étant très faibles (+0,02°C et -0,38 W/m² respectivement), leur impact est négligeable sur la régulation calculée par la loi heuristique comme le montrent les résultats.

Tableau 23 : Influence de la prévision de la météorologie sur la loi heuristique identifiée

	BETA_3 + contrôleur	BETA_3 + contrôleur / erreur (moyenne)	BETA_3 + contrôleur / erreur (+2σ)	BETA_3 + contrôleur / erreur (-2σ)
Puissance moyenne (W)	1028	1028	1020	1036
Coût cumulé (€)	67,05	67,05	67,15	67,14
Heures de pointe effacées (%)	84	84	79	92
Heures pleines effacées (%)	81	81	74	86
TI_{min} (%)	0	0	0	0
TI_{max} (%)	0	0	0	0
T_{min}/T_{max}	19/23,1	19/23,1	19/23	19/23,1
N_{var_max}	23	23	22	23
MBE (%)	-5	-5	-4	-6

On peut également constater la robustesse de la loi heuristique lorsque la variable climatique à prédire à $t + 6\Delta t$ est modifiée en y ajoutant (ou soustrayant) deux fois l'écart-type des erreurs de prévision. Par exemple, dans le cas où le modèle de prévision a tendance à surestimer les variables climatiques (ajout de deux fois l'écart-type), on remarque une diminution de la puissance moyenne utilisée (1020 W), donc une réduction des apports de chaleur dans le bâtiment, entraînant une diminution des heures pleines et de pointe effacées (74 % et 79 % respectivement). On peut faire le constat inverse dans le cas où le modèle de prévision sous-estime les variables climatiques (soustraction de deux fois l'écart-type). On note ainsi une augmentation de la puissance moyenne utilisée entraînant une augmentation des heures pleines et de pointe effacées. En effet, l'augmentation de la puissance

Chapitre 4 : Élaboration de lois de type heuristique

moyenne amène à une augmentation des apports de chaleurs et donc à une utilisation moindre du contrôleur pour assurer le respect des contraintes. Dans les deux cas, on peut remarquer une augmentation du coût très faible. Ces variations sont cependant minimes par rapport à la régulation calculée avec les prévisions météorologiques parfaites montrant ainsi la robustesse de la loi heuristique BETA_3 + contrôleur.

Le comportement du modèle BETA_3 + contrôleur par rapport aux erreurs de prévision météorologique est présenté dans la Figure 59. L'ensemble des résultats pour les autres semaines se trouvent dans l'Annexe E. On peut ainsi noter que les puissances calculées sont assez similaires.




Figure 59 : Puissances de chauffage calculées par BETA_3 + contrôleur, BETA_3 + contrôleur (-2 sigma) et BETA_3 + contrôleur (+2 sigma) (première semaine)

Les évolutions de la température de zone sont présentées dans la Figure 60. L'ensemble des résultats pour les autres semaines se trouvent dans l'Annexe E. Comme attendu, la température de zone aura tendance d'une part à être légèrement supérieure lorsque le modèle de prévision sous-estime les variables climatiques (la loi heuristique calcule alors une puissance de chauffage plus importante) et d'autre part légèrement inférieure lorsque le modèle de prévision surestime les variables climatiques (la loi heuristique calcule alors une puissance de chauffage plus faible). Cependant, les différences sont très faibles.




Figure 60 : Températures de zone correspondant aux régulations calculées par les modèles BETA_3 + contrôleur, BETA_3 + contrôleur (-2 sigma) et BETA_3 + contrôleur (+2 sigma) (première semaine)

La robustesse de la loi heuristique BETA_3 + contrôleur peut s'expliquer de plusieurs manières. D'un point de vue mathématique, on peut analyser la construction de la loi heuristique. On constate tout d'abord qu'elle présente une constante impliquant que la loi heuristique aura toujours tendance à chauffer pendant les heures creuses. La puissance de chauffage associée est alors pondérée selon les valeurs des variables explicatives. En analysant les valeurs des paramètres de la régression linéaire des variables explicatives, on peut constater que la variable explicative influençant le plus la puissance de chauffage au temps $t + \Delta t$ est la température de zone au temps t avec un paramètre associé qui est 10^2 (respectivement 10^4) fois plus grand que celui de la température extérieure au temps $t + 6\Delta t$ (respectivement le rayonnement solaire global horizontal au temps $t + 6\Delta t$). La puissance de chauffage au temps $t + \Delta t$ est donc d'une part majoritairement commandée par la température intérieure au temps t et d'autre part moins sensible à une erreur de prévision sur les variables explicatives météorologiques. D'un point de vue physique, la régulation calculée par la loi heuristique pour réaliser l'effacement s'applique à un bâtiment très bien isolé, donc moins sensible à la température extérieure. La forte inertie du bâtiment a alors tendance à lisser la courbe d'évolution de la température intérieure (correspondant à la variable explicative la plus influente) et donc limite l'impact des erreurs de prévision météorologique. Il n'en serait pas de même pour un bâtiment moins isolé nécessitant sûrement des prévisions météorologiques plus précises. Enfin, l'utilisation d'un chauffage électrique est un atout car il permet d'être très réactif en cas d'erreur importante sur les prévisions.

6. CONCLUSION DU CHAPITRE

L'objectif de ce chapitre était de développer des approches basées sur l'optimisation destinées à être « embarquées » dans des solutions et des outils de gestion de flux énergétiques classiques. Plus précisément, nous nous sommes intéressés à l'élaboration de lois de type heuristique à partir de la stratégie optimale calculée par la programmation dynamique.

Chapitre 4 : Élaboration de lois de type heuristique

La programmation dynamique a été utilisée pour étudier l'effacement de la consommation électrique de pointe dans les bâtiments performants énergétiquement. Étant donné ses temps de calculs importants et la difficulté de l'intégrer dans des outils de gestion énergétique, une méthode d'approximation a été mise en œuvre (optimisation hors-ligne). Une technique statistique (la régression Bêta) a été introduite permettant l'élaboration de lois heuristiques (lois de commande simplifiées) à partir des résultats de la programmation dynamique. Cette méthode permet de modéliser la relation existant entre des variables explicatives et une variable de réponse.

Les résultats ont montré que les modèles de régression Bêta sont capables d'imiter le comportement général des stratégies issues de la programmation dynamique, avec un temps de calcul très faible et un dépassement des contraintes de température limité. Pour améliorer le comportement de ces modèles de régression, un contrôleur *on-off* idéal a été utilisé, qui s'active dès que la température de la zone ne respecte pas les contraintes. Les résultats ont montré que le modèle de régression Bêta associé à un contrôleur *on-off* idéal permet de respecter les contraintes de température tout en conservant la majorité de l'effacement en heures pleines et de pointe. Une vérification a posteriori a également été réalisée concernant le respect de la contrainte de vitesse maximale de variation de la température. Cette dernière n'est pas respectée à tous les pas de temps. Cependant, ce non-respect a lieu majoritairement lorsque le bâtiment n'est pas occupé, limitant son impact. Une comparaison avec une loi purement heuristique a permis ensuite d'établir l'intérêt de la méthode. Enfin, une étude de l'influence des erreurs de prévision météorologique sur la loi heuristique développée a démontré la robustesse de cette dernière.

En conclusion, l'utilisation de lois heuristiques, identifiées à partir des résultats d'une optimisation exacte, s'avère pertinente d'autant plus que la formulation mathématique simple du modèle de régression Bêta permet d'envisager de l'implémenter dans des systèmes de commande de bâtiment en temps réel. De plus, son coût en temps de calcul (sur un ordinateur de bureau) est 150 fois inférieur à celui de la programmation dynamique pour calculer la loi de commande de chauffage sur un mois. Enfin, elles peuvent être embarquées dans des systèmes de régulation classique. En perspective, cette méthode peut être étendue au cas des bâtiments multizones en considérant des variables explicatives spécifiques aux différentes zones.

Cependant, l'utilisation des lois heuristiques (et en général de l'optimisation hors-ligne) présente quelques limitations. Tout d'abord ces lois ne sont pas souples, c'est-à-dire qu'un changement dans le problème d'optimisation à résoudre nécessite une nouvelle identification des lois heuristiques. De plus, elles sont sous-optimales et présentent un coût supérieur à celui de l'optimisation exacte. Enfin, l'évaluation de leur robustesse (en terme de coût, d'anticipation et de respect des contraintes) nécessiterait une étude plus approfondie.

Le développement et la démocratisation en cours des technologies nécessaires à l'implémentation des méthodes d'optimisation en ligne laissent envisager leur utilisation par les professionnels du bâtiment dans un futur proche. Ces méthodes ont l'avantage d'éviter les limites des lois heuristiques (sous-optimalité, robustesse incertaine, etc.) mais présentent généralement des coûts de calculs plus

Chapitre 4 : Élaboration de lois de type heuristique

importants. Par conséquent, nous nous intéresserons dans le prochain chapitre à l'optimisation en ligne avec la mise en place d'une commande prédictive adaptée au temps réel. L'objectif sera de développer des méthodes pouvant être utilisées par les systèmes de contrôle-commande les plus récents.

Chapitre 5

Application de la commande prédictive

La démocratisation de l'utilisation de la commande prédictive par les professionnels du bâtiment est envisageable dans un futur proche grâce au développement des technologies nécessaires à son implémentation. Les systèmes de contrôle-commande basés sur la commande prédictive ont en effet l'avantage d'être plus précis et plus robustes dans leur gestion des aléas. Cependant, ils nécessitent l'utilisation d'algorithmes d'automatique performants devant faire face à de nombreuses difficultés théoriques (initialisation de l'algorithme, respect des contraintes, convergence en un temps limité, gestion des aléas, etc.). Ce chapitre a pour objectif le développement d'un tel algorithme. Dans un premier temps, la taille du modèle de bâtiment sera réduite à l'aide d'une méthode de réduction. Par la suite, l'algorithme d'optimisation permettant de résoudre le problème de commande optimale sous contraintes d'état et de commande sera présenté. Dans l'objectif de réduire ses temps de calcul, une analyse de sensibilité sera menée. L'utilisation de l'algorithme nécessitant de connaître l'état du bâtiment, un observateur asymptotique sera également développé. Enfin, la gestion des aléas lors de l'application de la commande prédictive sera réalisée par le développement d'un régulateur permettant d'assurer le suivi de trajectoire.

PLAN DU CHAPITRE 5

1.	<u>INTRODUCTION.....</u>	181
2.	<u>RÉDUCTION DU MODÈLE THERMIQUE.....</u>	182
2.1	PROPRIÉTÉS DES SYSTÈMES D'ÉTAT	182
2.1.1	COMMANDABILITÉ	182
2.1.2	OBSERVABILITÉ	183
2.2	LA RÉALISATION ÉQUILBRÉE	183
2.3	LA RÉDUCTION ÉQUILBRÉE	184
2.4	APPLICATION AU CAS D'ÉTUDE	184
3.	<u>COMMANDE OPTIMALE</u>	189
3.1	PRINCIPE DES MÉTHODES DE PÉNALISATION.....	189
3.2	ALGORITHME D'OPTIMISATION.....	191
3.3	APPLICATION AU CAS D'ÉTUDE	192
3.3.1	PARAMÈTRES DE L'OPTIMISATION	192
3.3.2	RÉSOLUTION DU PROBLÈME DE COMMANDE OPTIMALE	193
3.3.3	RÉSULTATS.....	195
3.4	ANALYSE DE SENSIBILITÉ	196
3.4.1	HORIZON D'OPTIMISATION	196
3.4.2	ÉCHANTILLONNAGE DES SOLlicitATIONS	198
4.	<u>OBSERVATEUR ASYMPTOTIQUE.....</u>	201
4.1	STRUCTURE DE L'OBSERVATEUR.....	202
4.2	APPLICATION.....	203
5.	<u>COMMANDE PRÉDICTIVE</u>	205
5.1	COMMANDE PRÉDICTIVE SANS CONTRÔLEUR	205
5.1.1	FONCTIONNEMENT DE LA COMMANDE PRÉDICTIVE	205
5.1.2	RÉSULTATS.....	208

Chapitre 5 : Application de la commande prédictive

5.2	COMMANDE PRÉDICTIVE AVEC RÉGULATEUR.....	211
5.2.1	DÉFINITION DU RÉGULATEUR.....	212
5.2.2	RÉSULTATS.....	213
6.	<u>CONCLUSION DU CHAPITRE</u>	<u>216</u>

1. INTRODUCTION

L'utilisation de la commande prédictive par les professionnels du bâtiment reste à ce jour encore limitée dans la pratique. Néanmoins, la disponibilité de moyens de calculs toujours plus importants, la présence de capteurs fiables et à bas coût ainsi que le développement des moyens de télécommunication laissent envisager une démocratisation des systèmes de contrôle-commande à court terme. La mise en place de tels systèmes nécessite le développement d'algorithmes d'automatique performants permettant l'exploitation en temps réel des bâtiments. Cependant, ces derniers doivent faire face à de nombreuses difficultés théoriques telles que le respect des contraintes (par exemple contraintes sur le confort ou la puissance de chauffage), l'initialisation ou encore la convergence de l'algorithme d'optimisation en un temps limité. Le développement d'un tel algorithme est l'objet de ce chapitre.

La commande prédictive consiste en une résolution répétée à chaque période d'échantillonnage d'un problème de commande optimale. Cette technique repose sur l'utilisation d'un modèle dynamique du système à réguler (ici le bâtiment) permettant d'anticiper son comportement futur. La mise en place d'une telle méthode soulève plusieurs difficultés.

La première difficulté consiste à réduire la taille du modèle de bâtiment. En effet, la dimension de ce dernier est souvent trop élevée pour permettre une convergence rapide de l'algorithme d'optimisation. La mise en œuvre de méthodes de réduction de modèle est alors indispensable (§2). La deuxième difficulté concerne la résolution d'un problème de commande optimale visant à déterminer la commande d'un système (chauffage, ventilation, etc.) qui minimise (ou maximise) un critère de performance donné (par exemple la consommation énergétique) tout en respectant des contraintes fixées. On parle alors de planification de trajectoire. La résolution d'un tel problème requiert l'emploi d'un algorithme rapide et robuste (§3). Dans l'objectif de l'utilisation de cet algorithme à chaque période d'échantillonnage, la connaissance de l'état du bâtiment (correspondant aux conditions initiales de l'algorithme) est indispensable. Cependant, l'état du bâtiment n'est pas directement mesurable et la simple mesure de la température intérieure du bâtiment n'est pas suffisante pour le caractériser. En effet, pour une même température intérieure, un bâtiment peut être dans des états thermiques différents. Il est alors nécessaire d'estimer l'état du bâtiment par l'intermédiaire d'un observateur (§4). Enfin, la dernière difficulté réside dans la gestion des perturbations par un régulateur en temps réel. En effet, la résolution du problème de commande optimale permet de calculer une commande en boucle ouverte et de donner une trajectoire de référence à suivre. Cependant, lors de l'application de cette commande au système réel, des écarts peuvent être constatés entre la trajectoire de référence et la trajectoire réelle (causés par des perturbations ou des erreurs de modélisation du bâtiment). Il convient alors de corriger la commande dans l'optique de faire converger cet écart vers zéro, c'est-à-dire d'assurer le suivi de trajectoire (§5).

2. RÉDUCTION DU MODÈLE THERMIQUE

La modélisation thermique dynamique du bâtiment amène au développement d'un système de grande dimension. Cependant, résoudre un problème de commande optimale avec le système complet n'est pas envisageable car sa dimension est trop grande et peut induire des problèmes de convergence des algorithmes d'optimisation. Il est alors préférable de réduire l'ordre du modèle tout en conservant au maximum son comportement original. Différentes méthodes de réduction peuvent être utilisées pour réduire les modèles thermiques, telles que la réduction modale (Lefebvre 2007), la décomposition orthogonale aux valeurs propres (Sempey et al. 2009) ou encore les techniques basées sur la décomposition en valeurs singulières (Yahia et Palomo Del Barrio 1999). La réalisation équilibrée (Moore 1981) est une méthode efficace et couramment utilisée pour la réduction de modèle dans le cadre du contrôle-commande. Elle permet d'obtenir un modèle réduit adapté au contrôle et présentant une bonne précision (Palomo Del Barrio et al. 2000). Elle sera donc utilisée dans la suite du chapitre. Cette méthode repose sur les propriétés de commandabilité et d'observabilité des systèmes d'état définies ci-dessous.

2.1 Propriétés des systèmes d'état

Soit le système linéaire continu et invariant d'ordre n suivant :

$$\begin{cases} \dot{x}(t) = Ax(t) + Bu(t) & x(0) = x_0 \\ y(t) = Cx(t) \end{cases} \quad (5.1)$$

où $x \in \mathbb{R}^n$ est l'état, $u \in \mathbb{R}^m$ est la commande, $y \in \mathbb{R}^p$ est la sortie, A est une matrice $n \times n$, B une matrice $n \times m$ et C une matrice $p \times n$.

2.1.1 Commandabilité

Le système décrit par (5.1) est dit commandable s'il existe une commande permettant de le faire passer en un temps fini d'un état initial donné à un état final donné. Plus généralement, un système est dit entièrement commandable si par action sur la commande, il est possible d'atteindre en un temps fini n'importe quel point de l'espace d'état. Pour déterminer la commandabilité d'un système, on définit la matrice de commandabilité C_o :

$$C_o = (B, AB, \dots, A^{n-1}B) \quad (5.2)$$

Chapitre 5 : Application de la commande prédictive

Le système est commandable si et seulement si la matrice de commandabilité C_o est de rang $n = \dim(x)$ (critère de commandabilité de Kalman). On dira alors que (A, B) est commandable. La commandabilité peut être calculée de manière équivalente en calculant le grammien de commandabilité défini par (on suppose que les valeurs propres de la matrice A sont à partie réelle strictement négative) :

$$W_C = \int_0^{\infty} e^{tA} B B^T e^{tA^T} dt \quad (5.3)$$

Le système est alors contrôlable si et seulement si le grammien de commandabilité est défini positif.

2.1.2 Observabilité

Le système (5.1) est dit observable (ou (A, C) est observable), si pour tout instant t_1 , l'état initial $x(0) = x_0$ peut être déterminé à partir de la commande u et de la sortie y (observation) dans l'intervalle $[0, t_1]$. Pour déterminer l'observabilité d'un système on définit la matrice d'observabilité O_b :

$$O_b = \begin{bmatrix} C \\ CA \\ \vdots \\ CA^{n-1} \end{bmatrix} \quad (5.4)$$

Le système est alors observable si et seulement si la matrice d'observabilité O_b est de rang $n = \dim(x)$ (critère d'observabilité de Kalman). L'observabilité peut être également calculée par le grammien d'observabilité défini par :

$$W_o = \int_0^{\infty} e^{tA^T} C^T C e^{tA} dt \quad (5.5)$$

Le système est alors observable si et seulement si le grammien d'observabilité est défini positif.

2.2 La réalisation équilibrée

La réalisation équilibrée est un compromis optimal du point de vue de la commandabilité et de l'observabilité des variables d'état (Moore 1981). En effet, dans l'objectif de réduire l'ordre d'un modèle, une solution possible est l'élimination des états présentant un faible degré de commandabilité ou un faible degré d'observabilité. Cependant, des conflits peuvent exister pour des variables d'état avec un faible degré d'observabilité et fort degré de commandabilité (et inversement). Pour éviter cette difficulté, l'objectif de la réalisation équilibrée est alors de réaliser une transformation du système (5.1) dans le but d'équilibrer les degrés d'observabilité et de commandabilité. Plus précisément, l'objectif est de trouver une transformation d'état P :

$$x(t) = P \tilde{x}(t) \quad (5.6)$$

telle que les grammien de commandabilité et d'observabilité de $\tilde{x}(t)$ vérifient :

$$\tilde{W}_C = \tilde{W}_O = \Sigma \quad (5.7)$$

où Σ est une matrice diagonale incluant les valeurs singulières de Hankel du système :

$$\Sigma = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_n); \quad \sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_n > 0 \quad (5.8)$$

On obtient alors la représentation d'état équilibrée suivante :

$$\tilde{A} = P^{-1}AP, \quad \tilde{B} = P^{-1}B, \quad \tilde{C} = CP \quad (5.9)$$

La matrice P peut être calculée par (Laub et al. 1987) : $P = R^{-1}U\Sigma^{1/2}$ où R est une matrice triangulaire provenant de la factorisation de Cholesky du grammien d'observabilité $W_o = R^tR$, et où U et Σ sont définis par $RW_cR^t = U\Sigma^2U^t$.

2.3 La réduction équilibrée

Dès que le système (5.1) est mis dans sa forme équilibrée, on peut alors réduire facilement l'ordre du modèle en éliminant les états associés aux petites valeurs singulières de Hankel σ_i (représentant des faibles degrés d'observabilité et de commandabilité). On décompose ainsi la matrice Σ obtenue :

$$\Sigma = \begin{pmatrix} \sigma_1 & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & \sigma_n \end{pmatrix} = \begin{pmatrix} \Sigma_1 & 0 \\ 0 & \Sigma_2 \end{pmatrix}, \quad \Sigma_2 \ll \Sigma_1 \quad (5.10)$$

avec $\Sigma_1 \in \mathbb{R}^{k \times k}$ et $\Sigma_2 \in \mathbb{R}^{(n-k) \times (n-k)}$, k étant l'ordre souhaité pour le modèle réduit. La matrice Σ_2 contient ainsi les plus petites valeurs singulières de Hankel du système.

Le système équilibré avant troncature :

$$\begin{cases} \dot{x}(t) = \begin{bmatrix} \tilde{A}_{11} & \tilde{A}_{12} \\ \tilde{A}_{21} & \tilde{A}_{22} \end{bmatrix} x(t) + \begin{bmatrix} \tilde{B}_1 \\ \tilde{B}_2 \end{bmatrix} u(t) \\ y(t) = [\tilde{C}_1 \quad \tilde{C}_2]x(t) \end{cases} \quad (5.11)$$

conduit alors au modèle réduit après troncature :

$$\begin{aligned} \dot{x}_1(t) &= \tilde{A}_{11}x_1(t) + \tilde{B}_1u(t) \\ y(t) &= \tilde{C}_1x_1(t) \end{aligned} \quad (5.12)$$

avec $\tilde{A}_{11} \in \mathbb{R}^{k \times k}$, $\tilde{B}_1 \in \mathbb{R}^{k \times m}$ et $\tilde{C}_1 \in \mathbb{R}^{p \times k}$.

Le choix de l'ordre k peut être fait a priori ou par exemple par le choix d'une borne supérieure pour la différence entre deux valeurs singulières de Hankel successives.

2.4 Application au cas d'étude

Dans ce chapitre, nous nous intéressons à la maison I-BB (Béton banché) de la plateforme « INCAS » (présentée dans le §4.1.1 du chapitre 3). Cette dernière a été modélisée à l'aide du logiciel de simulation thermique dynamique Pléiades+COMFIE en considérant une seule zone thermique. Le modèle non réduit obtenu est un système d'état d'ordre 28. Ce dernier a été transformé sous sa forme équilibrée et les valeurs singulières de Hankel du système sont présentées dans la Figure 61. On peut remarquer que l'état n°1 se détache des autres modes avec une valeur singulière significativement plus élevée que les autres. Dans une moindre mesure, les états numérotés de 2 à 4 se détachent également des autres

Chapitre 5 : Application de la commande prédictive

états. Pour déterminer l'ordre de réduction du modèle, il est tout d'abord nécessaire de déterminer les modèles réduits entièrement commandables et observables. Pour cela, le rang des matrices de commandabilité et d'observabilité a été calculé pour les différents modèles réduits. Seuls les modèles réduits à un ordre inférieur ou égal à quatre respectent les critères de commandabilité et d'observabilité de Kalman (ces modèles réduits sont donc entièrement commandables et observables). Les constantes de temps des quatre modèles sont reportées dans le Tableau 24. On peut noter que les modèles réduits à l'ordre 2, 3 et 4 ont des constantes de temps bien séparées.




Figure 61 : Valeurs singulières de Hankel du système considéré

Tableau 24 : Constantes de temps des quatre modèles réduits

Ordre de réduction	1	2	3	4
Constantes de temps	16 jours	17 jours 13 minutes	17 jours 1 heure 8 minutes	17 jours 20 heures 44 minutes 6 minutes

Une analyse de la réponse fréquentielle des modèles réduits (de l'ordre 1 à l'ordre 4) aux différentes sollicitations est indispensable pour déterminer l'ordre de réduction du modèle permettant de faire un compromis entre précision et taille du modèle (qui va impacter les temps de calcul). Les sollicitations considérées dans cette analyse correspondent à la puissance de chauffage (variable de commande), à la température extérieure et au rayonnement solaire traversant les vitres (nommé ci-après flux vitré).

Dans l'objectif de déterminer la commande optimale de la puissance de chauffage, il est indispensable d'utiliser un modèle réduit présentant des performances proches de celles du modèle non réduit par rapport à la puissance de chauffage. La Figure 62 présente les réponses fréquentielles des modèles réduits à l'ordre 1 et 2 par rapport au modèle de référence. On peut constater que le modèle réduit à l'ordre 1 présente un comportement très différent par rapport au modèle non réduit aussi bien

Chapitre 5 : Application de la commande prédictive

en phase qu'en gain. Par exemple, il présente un retard important sur les temps compris entre une minute et plusieurs jours. Le modèle réduit à l'ordre 1 ne disposant que d'une seule constante de temps (qu'on peut faire correspondre d'un point de vue physique à la capacité thermique du bâtiment divisée par son coefficient de pertes), ce dernier est incapable de représenter correctement les variations de la température intérieure sur quelques heures. Le modèle réduit à l'ordre 2 présente quant à lui un retard de phase par rapport au modèle complet pour les temps compris entre une et plusieurs minutes et une avance de phase pour des temps correspondant à plusieurs heures. Ainsi, ce modèle a tendance à sous-estimer la variation de la température intérieure pour des variations de puissance à l'échelle de quelques minutes et à surestimer la variation de la température intérieure sur plusieurs heures. Par conséquent, les modèles réduits à l'ordre 1 et l'ordre 2 ne sont pas retenus dans la suite de l'étude du fait de leur comportements trop disparates par rapport au modèle non réduit.

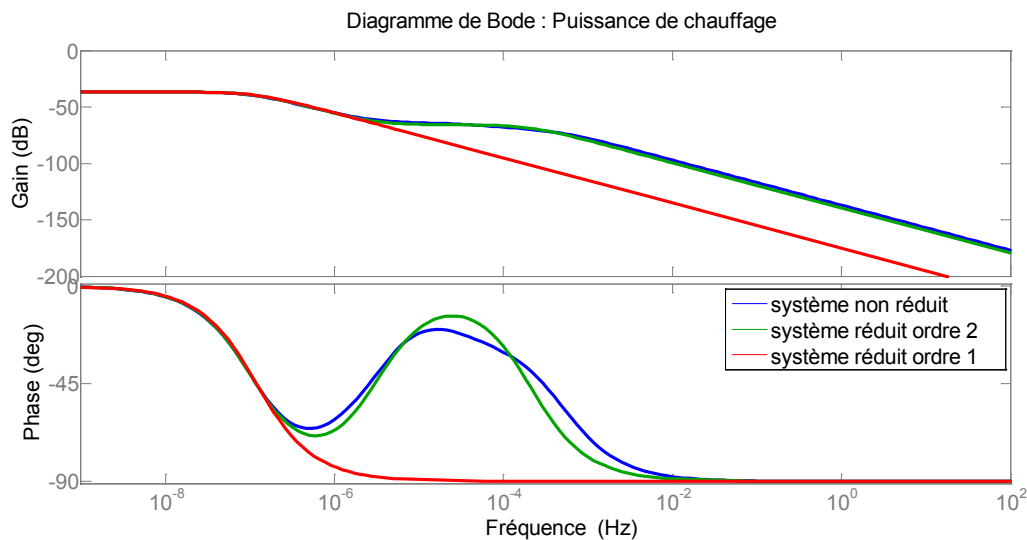


Figure 62 : Réponses fréquentielles des systèmes (non réduit, réduit à l'ordre 1 et réduit à l'ordre 2) à la puissance de chauffage

La Figure 63 présente les réponses fréquentielles des modèles réduits à l'ordre 3 et 4 par rapport au modèle non réduit. On peut constater qu'il n'y a que très peu de différences aussi bien en phase qu'en gain. Seuls de légers retards ou avances de phases peuvent être notés pour les modèles réduits à l'ordre 3 et 4 selon les échelles de temps.

Concernant les réponses fréquentielles à la température extérieure des modèles réduits à l'ordre 3 et 4 (Figure 64), on peut noter également leurs comportements très proches du modèle de référence aussi bien en phase qu'en gain.




Figure 63 : Réponses fréquentielles des systèmes (non réduit, réduit à l'ordre 3 et réduit à l'ordre 4) à la puissance de chauffage

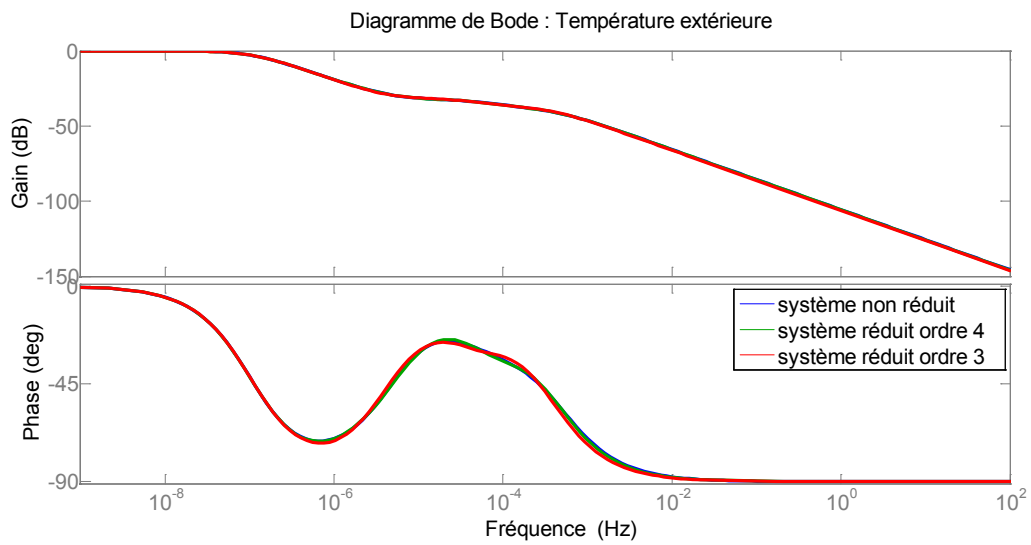


Figure 64 : Réponse fréquentielle des systèmes (non réduit, réduit à l'ordre 3 et réduit à l'ordre 4) à la température extérieure

Chapitre 5 : Application de la commande prédictive

Enfin, des différences sont à noter lorsque l'on considère les réponses fréquentielles des modèles au flux vitré (Figure 65). Ainsi, on peut constater que les modèles réduits à l'ordre 3 et 4 sont en avance de phase par rapport au modèle non réduit pour des temps compris entre 1 seconde et quelques heures. Cette différence peut s'expliquer d'un point de vue physique par l'incapacité des modèles réduits à représenter fidèlement l'impact du rayonnement solaire passant à travers les vitres. En effet, dans le modèle non réduit, le flux vitré est tout d'abord absorbé par les parois internes du bâtiment avant d'être réémis sous forme de rayonnement quelques minutes plus tard. Les modèles réduits à l'ordre 3 et 4 se montrent incapables de reproduire correctement ce comportement.

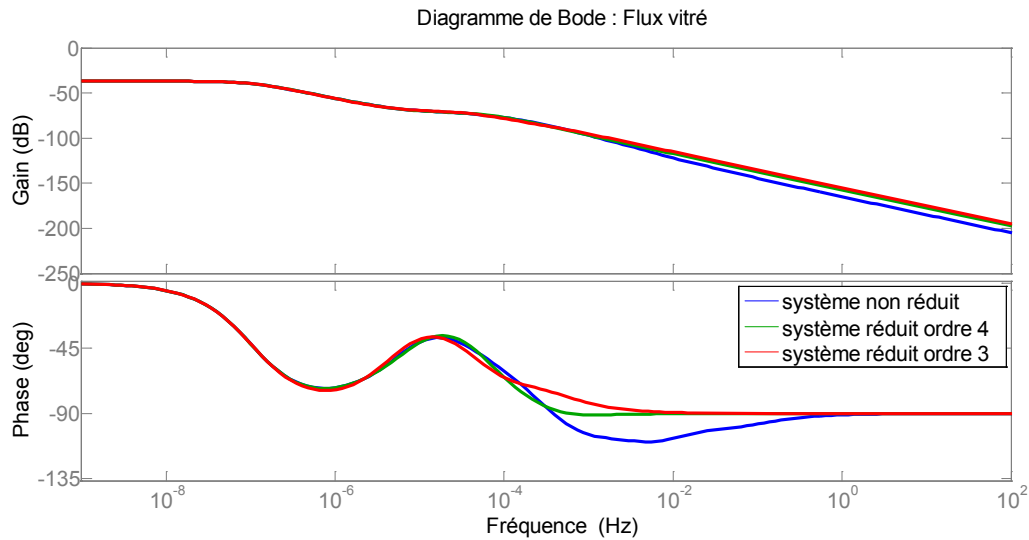


Figure 65 : Réponse fréquentielle des systèmes (non réduit, réduit à l'ordre 3 et réduit à l'ordre 4) au flux vitré

L'étude des réponses fréquentielles des modèles réduits aux différentes sollicitations a permis d'éliminer les modèles réduits à l'ordre 1 et 2 des modèles à utiliser pour le calcul de la commande optimale. En effet, le comportement de ces modèles, trop éloigné du modèle de référence, ne permet pas de s'assurer de la fiabilité de la commande optimale calculée. Les modèles réduits à l'ordre 3 et 4 présentent quant à eux un comportement satisfaisant. Cependant, l'étude des réponses fréquentielles ne permet pas de choisir entre la réduction à l'ordre 3 et la réduction à l'ordre 4. En effet, les réponses fréquentielles des deux modèles réduits sont très proches, même en ce qui concerne le flux vitré où ils sont incapables de représenter fidèlement le comportement du modèle complet. Le choix de l'ordre de réduction se fera alors en comparant le temps de calculs et la commande optimale calculée en considérant un modèle réduit à l'ordre 3 ou à l'ordre 4 (§ 3.3.3).

On s'intéresse dans la suite à la présentation de l'algorithme d'optimisation permettant de résoudre le problème de commande optimale.

3. COMMANDE OPTIMALE

On s'intéresse au problème de commande optimale suivant :

$$\min_{u \in U} \left[J(u) = \int_0^{t_f} L(x^u(t), u(t)) dt \right] \quad (5.13)$$

sous la contrainte de dynamique suivante :

$$\dot{x}^u(t) = f(x^u(t), u(t)) \quad ; \quad x(0) = x_0 \quad (5.14)$$

où x^u représente la trajectoire engendrée par la commande u et où l'on considère des contraintes portant sur l'état et la commande.

Dans le but de déterminer la loi de commande de chauffage qui minimise le coût de la consommation de chauffage, le problème de commande optimale (5.13)-(5.14) doit être soumis à différentes contraintes portant sur la température (contraintes d'état) et la puissance de chauffage (contraintes de commande). Cependant, le principe du minimum de Pontryagin (présenté dans le §3.1.1 du chapitre 1) prend en compte des contraintes sur le contrôle mais ne prend pas en compte d'éventuelles contraintes sur l'état. Une alternative consiste à utiliser des méthodes de pénalisation.

3.1 Principe des méthodes de pénalisation

Le principe des méthodes de pénalisation est de résoudre un problème de commande optimale modifié où l'on pondère la contrainte sur l'état de manière à forcer la solution à la respecter. On suppose par exemple que l'on souhaite imposer à l'état d'appartenir à un sous-ensemble $\mathcal{C} \subset \mathbb{R}^n$. L'objectif des méthodes de pénalisation est de définir une fonction de pénalisation γ de telle sorte que le problème de commande optimal sous contraintes et le problème de commande optimale modifié soient équivalents, c'est-à-dire qu'ils aient les mêmes solutions. On parle alors de pénalisation exacte. On peut par exemple choisir :

$$\gamma(s) = \begin{cases} 0 & \text{si } s \in \mathcal{C} \\ +\infty & \text{si } s \notin \mathcal{C} \end{cases} \quad (5.15)$$

Cependant cette fonction sommaire ne présente pas de bonnes propriétés mathématiques. On a alors généralement recours à des méthodes de pénalisation inexacte, c'est-à-dire telles que l'ensemble des solutions du problème de commande optimale modifié ne couvre pas totalement l'ensemble des solutions du problème de commande optimale sous contraintes. Le principe général de ces méthodes est le suivant (Trélat 2005). On définit une fonction γ sur \mathbb{R}^n de sorte qu'elle soit nulle sur \mathcal{C} et strictement positive ailleurs. On ajoute ensuite au coût $J(u)$ le scalaire $\varepsilon \int_0^{t_f} \gamma(x(t)) dt$ où $\varepsilon > 0$ est un poids pouvant être choisi assez grand. On peut alors espérer que la résolution du problème de commande optimale modifié force la trajectoire à rester dans l'ensemble \mathcal{C} . En effet, si $x(t)$ n'est pas dans l'ensemble \mathcal{C} , et si ε est grand, le coût correspondant sera alors grand et donc la trajectoire ne sera probablement pas optimale. Il s'agit du principe des méthodes de pénalisation extérieure. Cependant,

Chapitre 5 : Application de la commande prédictive

ces méthodes présentent l'inconvénient de pouvoir calculer des solutions ne respectant pas les contraintes.

Une alternative consiste alors à considérer des méthodes de pénalisation intérieure pouvant être utilisées pour résoudre le problème de commande optimale sous contraintes d'état (de la forme $g(x(t)) \leq 0$). Il s'agit de méthodes d'optimisation consistant à pénaliser la fonction coût par une fonction barrière faisant exploser le coût dès que la solution s'approche de la contrainte d'état permettant de s'assurer de son respect. Ainsi, le problème (5.13)-(5.14) devient :

$$\min_{u \in U} \left[J(u) = \int_0^{t_f} L(x^u(t), u(t)) dt + \varepsilon \int_0^{t_f} \gamma(g(x(t))) dt \right] \quad (5.16)$$

sous la contrainte de dynamique suivante :

$$\dot{x}^u(t) = f(x^u(t), u(t)) \quad ; \quad x(0) = x_0 \quad (5.17)$$

où le paramètre ε décroît vers 0, et où γ est la fonction barrière. L'objectif est alors d'approcher la solution du problème avec contraintes (5.13)-(5.14) par la résolution d'une suite de problèmes sans contraintes (5.16)-(5.17) et de faire décroître ε progressivement. L'avantage des méthodes de point intérieur est de pouvoir calculer des solutions admissibles. Cependant ces solutions sont sous-optimales d'où la nécessité de faire tendre ε vers 0 pour s'approcher de la solution optimale. La Figure 66 illustre le fonctionnement de la méthode des points intérieurs où l'objectif de l'optimisation est de minimiser la température tout en respectant la contrainte. On peut y constater que lorsque ε diminue ($\varepsilon_1 > \varepsilon_2 > \varepsilon_3$), la température s'approche de la contrainte sans l'enfreindre.




Figure 66 : Illustration du fonctionnement de la méthode des points intérieurs

3.2 Algorithme d'optimisation

L'algorithme utilisé dans le cadre de cette thèse repose sur celui développé par Malisani et al. (2014). Ce dernier permet de résoudre un problème de commande optimale (5.13)-(5.14) sous contraintes et plus précisément correspond à l'extension des méthodes des points intérieurs aux contraintes d'état de la forme $g(x(t)) \leq 0$ et aux contraintes de commande de la forme $u(t) \in C$ où C est un convexe fermé borné.

Cette méthode porte sur la définition des fonctions de pénalité γ_g et γ_u ainsi que d'une fonction de saturation généralisée ϕ ($u = \phi(v)$ correspondant à un changement de variable de la commande u permettant de supprimer la contrainte de commande de la formulation du problème) pour formuler le problème suivant :

$$\min_{v \in L^\infty([0, t_f], \mathbb{R}^m)} \int_0^{t_f} L(x^{\phi(v)}, \phi(v)) dt + \varepsilon \int_0^{t_f} \gamma_g(x^{\phi(v)}) + \gamma_u(v) dt \quad (5.18)$$

où γ_g et γ_u sont les fonctions de pénalité portant sur la contrainte d'état et la contrainte de commande respectivement. Il est alors démontré que ce problème (5.18) génère, lorsque ε tend vers 0, une séquence de solutions convergeant vers la solution du problème de commande optimale sous contraintes (5.13)-(5.14). Chaque solution de la séquence est facile à résoudre sachant que le problème (5.18) n'est pas contraint. La définition générale des fonctions de pénalité γ_g et γ_u sont définies dans l'article de Malisani et al. (2014).

Pour résoudre le problème de commande optimale, on définit l'Hamiltonien du problème pénalisé (5.18) :

$$H_\varepsilon(x^{\phi(v)}, v, p) = L(x^{\phi(v)}, \phi(v)) + \varepsilon[\gamma_g(x^{\phi(v)}) + \gamma_u(v)] + p^t f(x^{\phi(v)}, \phi(v)) \quad (5.19)$$

où $p \in \mathbb{R}^n$ est l'état adjoint.

L'algorithme de résolution se déroule de la manière suivante :

Étape 1 : Initialiser les fonctions $x^{\phi(v)}(t)$ et $p(t)$ telles que les valeurs initiales satisfassent $\forall t \in [0, t_f], g(x^{\phi(v)}(t)) < 0$. Définir une série décroissante $\varepsilon_i > 0, i = 0, \dots, N$ et initialiser à $\varepsilon = \varepsilon_0$.

Étape 2 : Soit l'Hamiltonien $H_\varepsilon(x^{\phi(v)}, v, p)$. Calculer v_ε^* solution de l'équation $\frac{\partial H_\varepsilon}{\partial v} = 0$.

Étape 3 : Résoudre les 2 n équations différentielles :

$$\begin{aligned} \frac{dx}{dt} &= f(x, \phi(v_\varepsilon^*)), & x(0) &= x_0 \\ \frac{dp}{dt} &= -\frac{\partial H_\varepsilon}{\partial x}(x, \phi(v_\varepsilon^*), p), & p(t_f) &= 0 \end{aligned}$$

La résolution de ce problème aux deux bouts peut être faite à l'aide des routines `bvp5c` ou `bvp4c` du logiciel Matlab (Shampine et al. 2000).

Étape 4 : Si $i = N$, fin. Sinon décroître ε , initialiser $x^{\phi^{(v)}}(t)$ et $p(t)$ avec les solutions trouvées à l'étape 2 et retourner à l'étape 2.

3.3 Application au cas d'étude

On se propose d'appliquer cet algorithme à notre cas d'étude, à savoir l'effacement de la consommation électrique de pointe sur un horizon d'une semaine. Pour rappel, l'objectif de l'optimisation est de déterminer la stratégie optimale qui minimise le coût de la consommation énergétique tout en respectant des contraintes de température de confort (contraintes d'état) et des contraintes de puissance maximale du système de chauffage (contraintes de commande).

3.3.1 Paramètres de l'optimisation

3.3.1.1 Notations du modèle

Nous utilisons le modèle réduit à l'ordre 3 ou 4 suivant (correspondant à un modèle monozone) :

$$\begin{cases} \dot{x}(t) = Ax(t) + BP(t) + d(t) \\ T(t) = Cx(t) \end{cases} \quad (5.20)$$

avec

- x l'état du modèle ;
- T la température intérieure de la zone ;
- P la puissance de chauffage (variable de commande) ;
- d l'influence du climat, des occupants et des équipements (apports solaires et internes).

3.3.1.2 Contraintes

Pour rappel, les contraintes portant sur l'état et la commande sont les suivantes :

- **Contraintes d'état** : la température intérieure de la zone doit être comprise entre 19°C (T_{min}) et 24°C (T_{max}).

$$T_{min} \leq T_{zone}(t) \leq T_{max} \quad (5.21)$$

- **Contraintes de commande** : la puissance de chauffage doit être comprise entre 0 W (P_{min}) et 5000 W (P_{max}).

$$P_{min} \leq P(t) \leq P_{max} \quad (5.22)$$

3.3.1.3 Climat

Les conditions météorologiques utilisées pour la résolution du problème de commande optimale sur une semaine sont représentatives d'une période froide d'un mois de janvier de la zone H1C (zone

Chapitre 5 : Application de la commande prédictive

thermique de la réglementation thermique) (Figure 67). La température moyenne sur la semaine considérée est de -2,5°C avec un minimum à -7°C.




Figure 67 : Conditions météorologiques (semaine froide d'hiver)

3.3.1.4 Scénarios d'utilisation

Les scénarios d'occupation, de ventilation et de puissance dissipée correspondent à ceux définis dans le §2.1 du chapitre 4. Pour rappel, en ce qui concerne la ventilation externe, une valeur moyenne est considérée pour les débits de ventilation dans le système linéaire (§2 du chapitre 2).

3.3.1.5 Tarifs de l'électricité

Les tarifs de l'électricité correspondent à ceux définis au chapitre 4 et sont rappelés dans le Tableau 25.

Tableau 25 : Tarifs des heures creuses, pleines et de pointe

	Heures creuses	Heures pleines	Heures de pointe
Horaire	0h-9h	9h-17h 22h-0h	17h-22h
Prix du kWh en €	0,0864	0,1275	0,255

3.3.2 Résolution du problème de commande optimale

Le but de l'optimisation est de déterminer la stratégie optimale qui minimise la consommation énergétique connaissant les tarifs de l'électricité. Le critère à minimiser est donc le suivant :

$$\min_P \int_0^{t_f} C_{elec}(t)P(t)dt \quad (5.23)$$

où $C_{elec}(t)$ est le coût de l'électricité et $P(t)$ est la puissance de chauffage à injecter dans le bâtiment.

Le problème de commande optimale revient à minimiser le critère (5.23) sous la dynamique (5.20) tout en respectant les contraintes d'état (5.21) et de commande (5.22). Pour résoudre ce problème, la méthode présentée au §3.2 est utilisée.

Chapitre 5 : Application de la commande prédictive

On utilise le changement de variable suivant ($P = \phi(v)$) pour la puissance de chauffage (Malisani 2012) :

$$P = \phi(v) = P_{max} \left(\frac{e^{kv}}{1 + e^{kv}} \right), k > 0 \quad (5.24)$$

L'hamiltonien du problème pénalisé de commande optimale est alors :

$$H(x, v, p) = C_{elec}\phi(v) + p^t(Ax + B\phi(v) + d) + \varepsilon[\gamma_g(Cx - T_{min}) + \gamma_g(T_{max} - Cx) + \gamma_u \circ \phi(v)] \quad (5.25)$$

Le vecteur adjoint doit alors satisfaire l'équation différentielle suivante :

$$\frac{dp}{dt}(t) = -A^t p(t) - \varepsilon C^t [\gamma'_g(Cx(t) - T_{min}) - \gamma'_g(T_{max} - Cx(t))] \quad (5.26)$$

où γ'_g est la dérivée de la fonction γ_g définie de la manière suivante :

$$\gamma_g(s) = \begin{cases} s^{-1.1} & \forall s > 0 \\ 0 & \text{sinon} \end{cases} \quad (5.27)$$

Il est à noter qu'il n'est pas nécessaire de définir explicitement la fonction γ_u . En effet, dans la résolution du problème aux deux bouts, seule la définition de γ'_u est requise (Malisani et al. 2014). L'algorithme utilisé pour résoudre le problème pénalisé de commande optimale est alors le suivant :

Étape 1 : Initialiser les fonctions $x(t)$ et $p(t)$ telle que $Cx(t) \in (T_{min}, T_{max})$ pour tout $t \in [0, t_f]$ (p peut être choisi égal à 0). Fixer $\varepsilon = \varepsilon_0$.

Étape 2 : Calculer $v_\varepsilon^* = \sinh^{-1} \left(-\frac{C_{elec}(t) + p^t(t)B}{\varepsilon} \right)$, solution⁷ de $\frac{\partial H_\varepsilon}{\partial v} = 0$ où nous avons choisi $\gamma'_u \circ \phi(v) = \sinh(v)$.

La solution optimale $P_\varepsilon^*(t) = \phi(v_\varepsilon^*(t))$ est alors donnée en utilisant l'équation (24).

Étape 3 : Résoudre le problème aux deux bouts suivants :

$$\begin{cases} \frac{dx(t)}{dt} = Ax(t) + BP_\varepsilon^*(t) + d(t) \\ P_\varepsilon^*(t) = \phi \left(\sinh^{-1} \left(-\frac{C_{elec}(t) + p^t(t)B}{\varepsilon} \right) \right) \\ \frac{dp(t)}{dt} = -A^t p(t) - \varepsilon C^t [\gamma'_g(Cx(t) - T_{min}) - \gamma'_g(T_{max} - Cx(t))] \end{cases}$$

avec comme conditions aux limites $x(0) = x_0$ et $p(t_f) = 0$.

Étape 4 : Diminuer ε . Initialiser $x(t)$ et $p(t)$ avec les solutions trouvées à l'étape 3 et retourner à l'étape 2.

La suite (ε_n) a été choisie, dans notre cas d'étude, telle que $\varepsilon_n = 10^{-\frac{n}{10}}$ avec $n = -90 \dots +70$, de telle sorte que ε varie de 10^9 à 10^{-7} .

⁷ $\frac{\partial H_\varepsilon}{\partial v} = 0$ donne $C_{elec}(t) + p^t(t)B + \varepsilon \gamma'_u \circ \phi(v) = 0$

3.3.3 Résultats

La Figure 68 présente les résultats obtenus par l'algorithme d'optimisation en considérant soit un modèle réduit à l'ordre 3 soit un modèle réduit à l'ordre 4. Pour éviter les effets de bords, l'horizon d'optimisation considéré a été fixé à huit jours mais seuls les sept premiers jours de l'optimisation ont été comparés. On peut constater que les stratégies de commande de la puissance de chauffage sont très proches l'une de l'autre. Par exemple, grâce à l'inertie thermique du bâtiment, ces stratégies ne chauffent que pendant les heures creuses. Plus précisément, elles augmentent progressivement la puissance de chauffage utilisée (jusqu'à la puissance maximale) de manière à atteindre une température intérieure suffisante en fin de période d'heures creuses permettant d'assurer, lors de l'effacement de la puissance de chauffage, une température supérieure à la température minimale (19°C) à la fin de période de pointe (Figure 69). On peut également remarquer une pointe de la puissance de chauffage en début de chaque période d'heures creuses pouvant s'expliquer par la discontinuité du coût de l'électricité et la non convexité du critère à minimiser. Enfin, les stratégies calculées par les modèles réduits à l'ordre 3 et 4 présentent un coût cumulé très proche avec 14,31 € et 14,33 € respectivement. Cependant, les temps de calculs de l'optimisation en considérant un modèle réduit soit à l'ordre 3 soit à l'ordre 4 sont respectivement de deux heures et de quatre heures (sur un ordinateur de bureau comprenant 16 Go de mémoire vive et un processeur cadencé à 2,8 GHz). Par conséquent, l'ordre de réduction du modèle a été fixé à trois permettant un bon compromis entre précision du modèle réduit et temps de calculs.

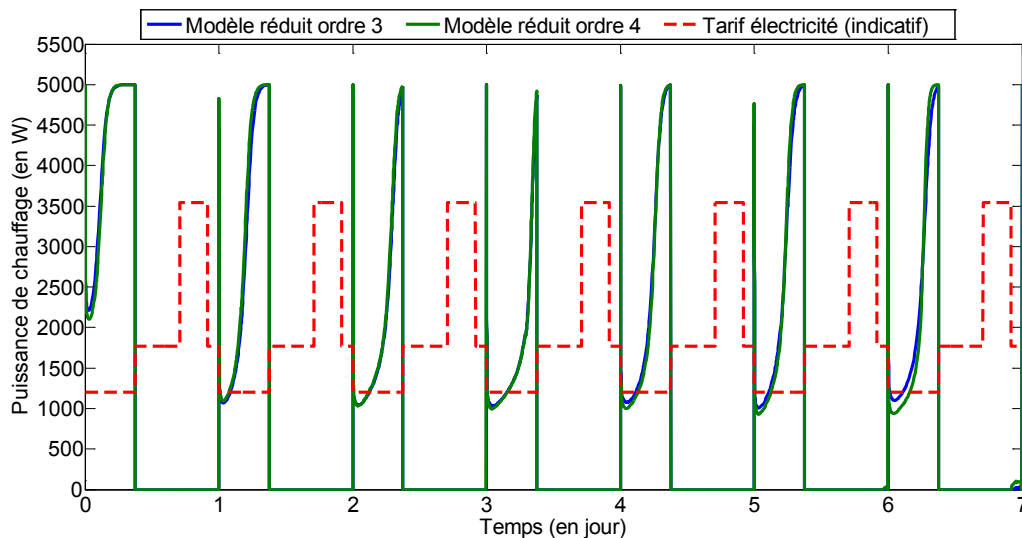


Figure 68 : Stratégies optimales de la puissance de chauffage calculées en considérant un modèle réduit à l'ordre 3 ou à l'ordre 4

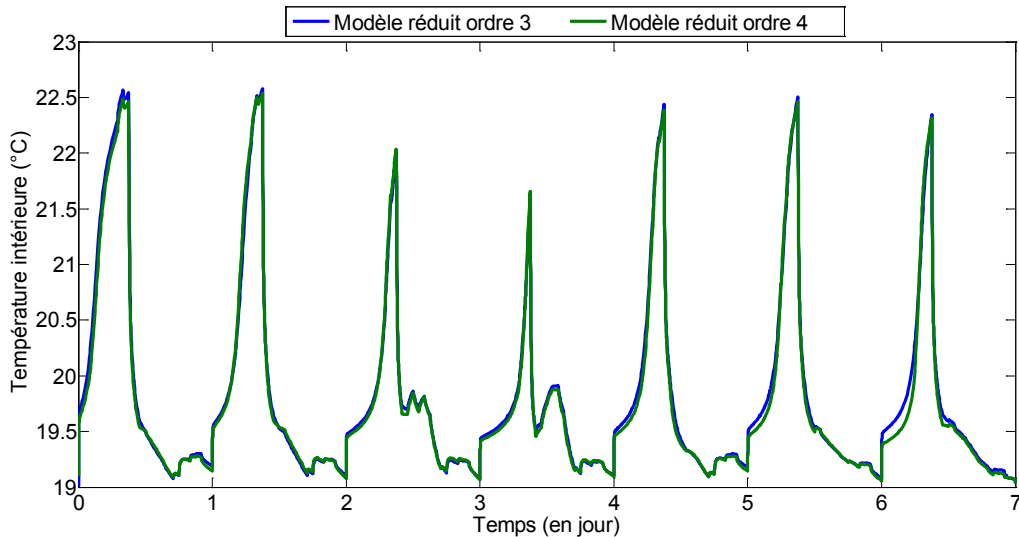


Figure 69 : Évolution de la température intérieure en considérant un modèle réduit à l'ordre 3 ou à l'ordre 4

3.4 Analyse de sensibilité

La mise place d'une commande prédictive nécessite tout d'abord de fixer la période à laquelle la commande optimale est recalculée (période d'échantillonnage). Dans le cas d'application de la gestion énergétique des bâtiments, cette période d'échantillonnage peut dépendre de la mise à jour des prévisions météorologiques (prévisions pouvant être mises à jour d'une à plusieurs fois par jour selon les fournisseurs), de l'estimation de l'état du bâtiment ou encore d'un changement de scénario des sollicitations. Dans l'objectif de développer un algorithme le plus général possible, la période d'échantillonnage a été fixée à 24 heures. Ensuite, il est nécessaire de fixer l'horizon d'optimisation de la commande optimale. Ce choix correspond à un compromis entre temps de calculs et précision de la commande calculée (§ 3.4.1). Enfin, l'évaluation de la robustesse de la commande calculée par rapport aux sollicitations (prévisions météorologiques, occupation) est indispensable dans l'objectif de déterminer la précision des prévisions des sollicitations nécessaire au calcul de la commande optimale (§ 3.4.2).

3.4.1 Horizon d'optimisation

La période d'échantillonnage de la commande prédictive a été fixée à 24 heures. Par conséquent, une analyse de sensibilité peut être menée consistant à comparer, par rapport à une référence, la commande calculée sur les 24 premières heures suivant un horizon testé. Dans cette analyse, la référence correspond aux 24 premières heures de la commande calculée selon un horizon de trois semaines (horizon supérieur à la plus grande constante de temps du modèle réduit d'ordre 3). On peut ainsi évaluer l'impact de l'horizon sur la commande calculée.

Chapitre 5 : Application de la commande prédictive

Deux indicateurs sont utilisés pour comparer les commandes calculées :

- l'écart moyen absolu (en Watt) correspondant à la moyenne des écarts absolus à chaque seconde entre la commande calculée avec un horizon testé et la référence ;
- la variation du coût (en pourcentage) de la commande calculée avec un horizon testé.

Le choix de l'horizon d'optimisation a suivi un processus itératif consistant à incrémenter d'un jour l'horizon d'optimisation si les performances de la commande calculée sur les 24 premières heures s'éloignaient trop de la référence. Les données météorologiques considérées dans cette étude correspondent à celles présentées au § 3.3.1.3 car elles ont l'avantage d'inclure une vague de froid sur trois jours commençant au 2^{ème} jour. Les résultats de cette étude sont présentés dans le Tableau 26 et la Figure 70. Le coût et la puissance moyenne de référence sur 24 heures est de 3,22 € et 1600 W respectivement. Le temps de calcul la commande de référence calculée selon un horizon de trois semaines est d'une dizaine d'heures.

Tableau 26 : Résultats de l'analyse de sensibilité portant sur l'horizon

	Horizon = 1 jour	Horizon = 2 jours	Horizon = 3 jours	Horizon = 4 jours
MAE (W)	850	17	1	0,3
Variation coût (%)	-22	-1	-0,05	-0,01
Temps de calcul (minutes)	12	17	25	49

On peut tout d'abord constater qu'un horizon d'un jour d'optimisation n'est pas suffisant. En effet, les écarts sont importants aussi bien sur la commande calculée (MAE de 850 W) que sur le coût (-22 %). Ceci s'explique par le fait qu'avec un horizon d'un jour, l'algorithme d'optimisation n'anticipe pas la vague de froid commençant au deuxième jour. Par conséquent, il ne surchauffe pas le bâtiment pour anticiper la baisse de température au deuxième jour expliquant ainsi le coût plus faible sur les 24 premières heures. Toutefois, il sera obligé par la suite de chauffer plus pendant la vague de froid conduisant au total à un coût plus élevé. Ensuite, en considérant un horizon de deux jours d'optimisation, on peut remarquer que les performances sont proches entre la commande calculée et la référence, avec un MAE de 17 W et une variation du coût de -1 %. Le coût de la commande calculée est plus faible que la référence car l'algorithme d'optimisation ne voit pas toute la vague de froid qui se termine au troisième jour. Enfin, les résultats de l'optimisation en considérant un horizon de trois jours sont pratiquement équivalents à la référence, avec un MAE de 1 W et une variation du coût de -0,05 %. L'ajout d'un jour dans l'horizon d'optimisation n'améliore qu'à la marge les résultats avec un MAE de 0,3 W et une variation du coût de -0,01 % tout en augmentant significativement les temps de calcul (49 minutes). On peut également noter que, sur la Figure 70, les courbes correspondant à un horizon de trois et quatre jours sont confondues avec la référence.

Suite à cette rapide analyse de sensibilité, il est possible de déterminer l'horizon d'optimisation à considérer. Ce choix correspond à un compromis entre temps de calcul et précision de la commande calculée par rapport à la référence. Un horizon d'optimisation de trois jours a ainsi été considéré dans la suite de l'étude. En effet, bien qu'un horizon de deux jours aurait pu être suffisant, un horizon de trois

jours permet de prendre une sécurité quant à l'anticipation des phénomènes climatiques tout en présentant des temps calculs acceptables. Cependant, ce choix de l'horizon d'optimisation dépend du cas d'étude considéré et en particulier des conditions météorologiques. Une étude de sensibilité plus approfondie serait ainsi nécessaire pour évaluer l'impact de l'horizon d'optimisation en considérant d'autres conditions météorologiques (vague de froid plus longue, conditions intersaisonniers). De plus, le choix de l'horizon d'optimisation se heurte à des considérations pratiques telles que la fiabilité des prévisions météorologiques




Figure 70 : Commandes calculées selon l'horizon d'optimisation

3.4.2 Échantillonnage des sollicitations

Dans les études précédentes, la prévision des sollicitations (conditions météorologiques, occupation) était considérée comme parfaite. Cette analyse de sensibilité a donc pour objectif d'évaluer la robustesse de la commande calculée par rapport à ces prévisions. Plus précisément, il s'agit de déterminer l'impact de la précision des prévisions des sollicitations sur le calcul de la commande.

Cette analyse peut être réalisée en considérant des sollicitations moyennées. Le principe est ici de ne plus considérer des prévisions des sollicitations heure par heure sur une journée, mais de diviser la journée en un nombre fixe de périodes et de prendre la moyenne des sollicitations sur ces périodes. Par exemple, on considérant une seule période, les sollicitations moyennées correspondront à la moyenne sur une journée des conditions météorologiques et des effets de l'occupation.

Cette méthode présente plusieurs intérêts. Elle permet tout d'abord de déterminer la précision à respecter concernant la prévision des sollicitations. De plus, elle diminue les temps de calculs en simplifiant la résolution du problème. Enfin, elle montre, sur un cas empirique, si l'on peut se satisfaire d'une commande calculée à partir de données météorologiques et d'occupation moyennées. Plus précisément, il s'agit de montrer si la commande obtenue en résolvant un problème de commande optimale similaire au problème réel, mais où la dynamique des sollicitations est remplacée par des moyennes, donnera lieu, une fois utilisée dans le problème réel, à un coût proche du coût minimal.

Chapitre 5 : Application de la commande prédictive

Cette méthode découle des travaux théoriques réalisés par Bernard (2014). Ces travaux ont montré qu'il était possible de réaliser une majoration de la différence des coûts correspondant l'un à la commande optimale réelle et l'autre à la commande obtenue par échantillonnage.

Dans cette analyse, la référence est la même que celle utilisée dans le § 3.4.1, à savoir une optimisation sur un horizon de trois semaines en considérant des sollicitations parfaitement connues. Les mêmes indicateurs sont également utilisés. Plusieurs échantillonnages ont été testés, à savoir des échantillonnages sur une période, sur deux périodes, sur trois périodes et sur quatre périodes, en considérant à chaque fois un horizon d'optimisation de trois jours. Les résultats obtenus sont présentés dans le Tableau 27 et la Figure 71.

Tableau 27 : Résultats de l'analyse de sensibilité portant sur les sollicitations

	1 période	2 périodes	3 périodes	4 périodes
MAE (W)	34	33	37	2,5
Variation coût (%)	2,1	2,1	-2,4	-0,2
Temps de calcul (minutes)	9	12	13	14

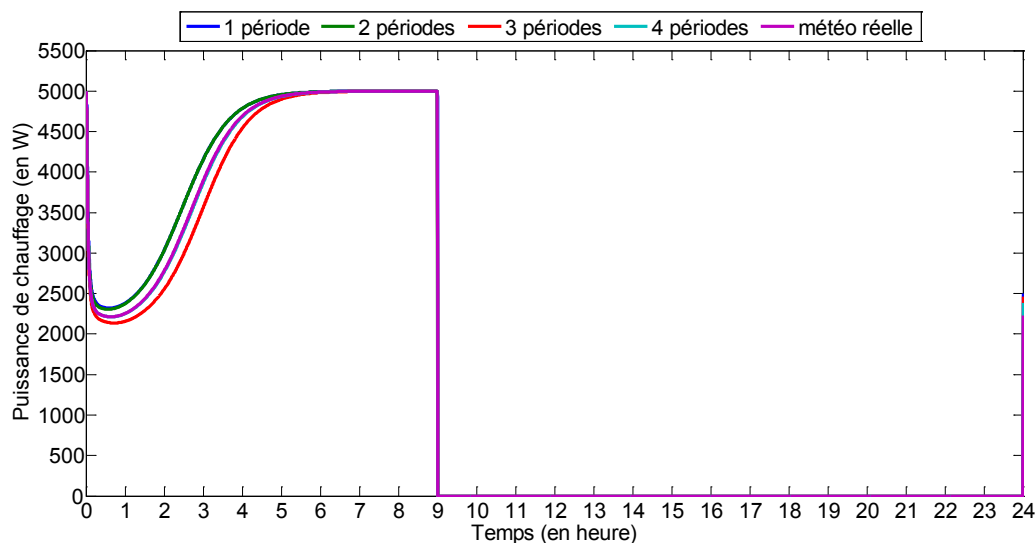


Figure 71 : Commandes calculées selon l'échantillonnage des sollicitations

On peut noter que lorsque l'on moyenne les sollicitations sur une période la commande calculée par le problème moyenné a tendance à être supérieure à la commande de référence (MAE de 34 W), entraînant une augmentation du coût. Les résultats sont équivalents lorsque l'on considère deux périodes (avec un MAE de 33 W et une variation du coût de 2,1 %). Le constat est inverse lorsque l'on considère un échantillonnage sur trois périodes (MAE de 37 W et variation du coût de -2,4 %). Bien que minimes, ces différences peuvent entraîner un risque de violation des contraintes de confort lors de l'application de la commande calculée par le problème moyenné au modèle réel (correspondant aux sollicitations parfaitement connues). On peut cependant remarquer les très bonnes performances de l'échantillonnage sur quatre périodes, avec un MAE de 2,5 W et une variation du coût de -0,2 %. Par

Chapitre 5 : Application de la commande prédictive

conséquent cela signifie qu'il est nécessaire de connaître en moyenne les sollicitations, et en particulier les conditions météorologiques, sur quatre périodes (correspondant d'un point de vue physique à la nuit, le matin, l'après-midi et le soir) pour obtenir un coût proche du coût optimal. Les sollicitations moyennées sont présentées de la Figure 72 à la Figure 74 et les quatre périodes sont définies comme suit :

- 1^{ère} période : 0 h - 8 h ;
- 2^{ème} période : 8 h - 13 h ;
- 3^{ème} période : 13 h - 18 h ;
- 4^{ème} période : 18 h - 0 h ;

En conclusion de cette analyse de sensibilité, un horizon d'optimisation de trois jours et un échantillonnage des sollicitations sur quatre périodes seront considérés dans la suite lors de la mise en place de la commande prédictive.




Figure 72 : Température extérieures (données réelles et données moyennées)




Figure 73 : Flux solaire passant à travers les vitres (données réelles et données moyennées)

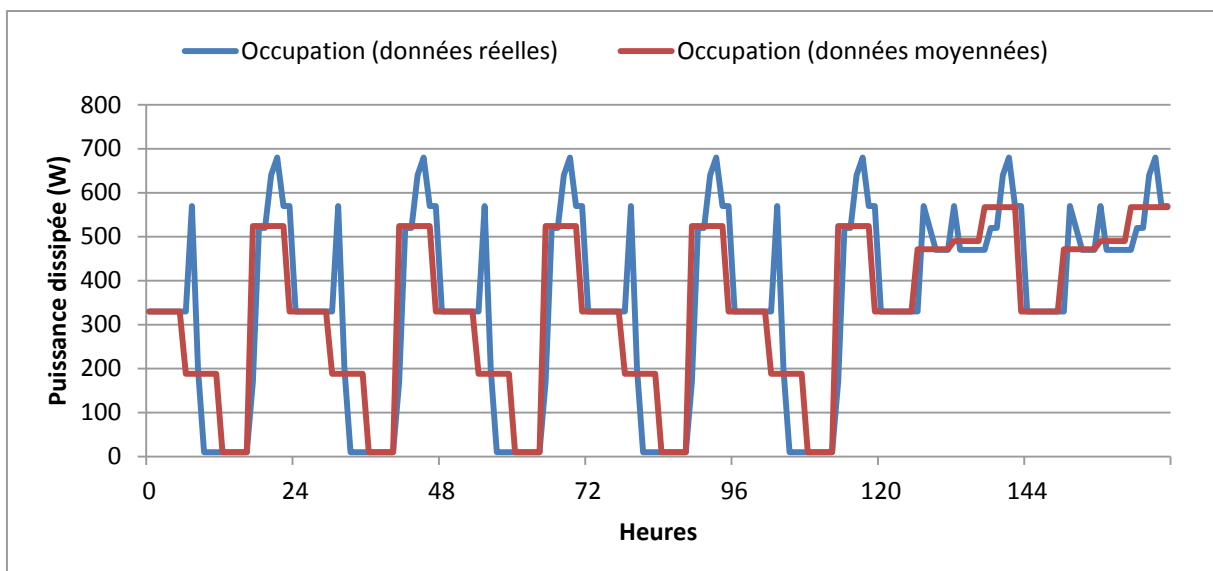


Figure 74 : Puissance dissipée due à l'occupation et aux équipements (données réelles et données moyennées)

4. OBSERVATEUR ASYMPTOTIQUE

L'utilisation de l'algorithme d'optimisation, présenté au paragraphe précédent, nécessite de connaître les conditions initiales portant sur l'état ($x(0) = x_0$), c'est-à-dire l'état du bâtiment. Cependant, celui-ci n'est pas directement mesurable : la simple mesure de sa température intérieure n'est pas suffisante pour le caractériser. Il est indispensable de pouvoir estimer cet état à partir d'un observateur. Ce dernier a pour vocation de reconstruire l'état du bâtiment en se basant sur un modèle dynamique. L'objectif de cette partie est de construire un tel observateur.

4.1 Structure de l'observateur

Soit un système à réguler modélisé par la représentation d'état suivante avec m entrées notées u , n états notés x et p sorties notées y :

$$\begin{cases} \dot{x}(t) = Ax(t) + Bu(t) \\ y(t) = Cx(t) \end{cases} \quad (5.28)$$

où A est une matrice $n \times n$, B une matrice $n \times m$ et C une matrice $p \times n$, avec $p < n$. En général, l'état du système n'est pas complètement accessible ou mesurable. La dimension du vecteur d'état est en effet supérieure à celle de la sortie. Cela signifie que pour tout instant t , le vecteur $x(t)$ ne peut être complètement mesuré ou déduit des sorties. Cependant, ce dernier peut être reconstruit à l'aide d'un observateur dimensionné judicieusement dans l'objectif de réaliser une estimation précise et rapide de la valeur des composantes du vecteur d'état $x(t)$. On notera dans la suite par $\hat{x}(t)$ et $\hat{y}(t)$ les estimations des quantités $x(t)$ et $y(t)$ respectivement. Le principe général (Figure 75) est qu'à partir des entrées u et des sorties mesurées y l'observateur puisse estimer l'état du système à réguler ($\hat{x}(t)$).

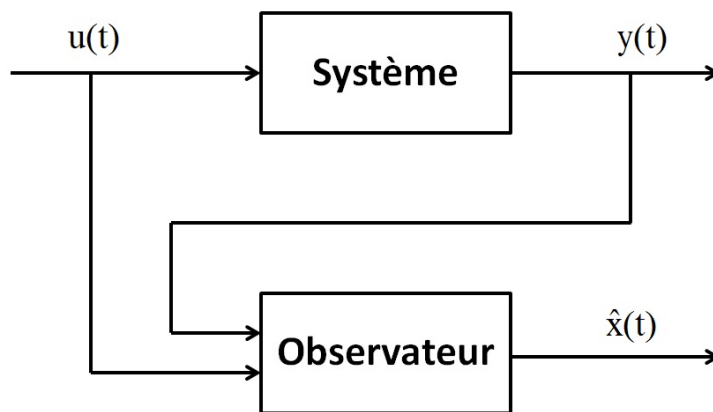


Figure 75 : Diagramme d'un observateur

L'idée générale de l'observateur asymptotique est de reprendre la dynamique de l'état et de la modifier par un terme correspondant à l'erreur d'observation. La structure de l'observateur peut alors être exprimée sous la forme suivante :

$$\begin{cases} \dot{\hat{x}}(t) = A\hat{x}(t) + Bu(t) + L(y(t) - \hat{y}(t)) \\ \hat{y}(t) = C\hat{x}(t) \end{cases} \quad (5.29)$$

Le problème consiste alors à choisir la matrice L de façon à ce que la solution \hat{x} du système (5.28) converge vers x . Plus précisément, considérons la dynamique de l'erreur d'estimation $e_x = \hat{x} - x$ définie par :

$$\frac{d}{dt}e_x = (A - LC)e_x \quad (5.30)$$

L'objectif est de s'assurer que l'erreur d'estimation converge asymptotiquement vers 0, c'est-à-dire d'imposer, par un choix judicieux de L , que toutes les valeurs propres de $A - LC$ soient à partie réelle

strictement négative. La construction d'un tel observateur asymptotique est possible si et seulement si (A, C) est observable. Dans l'objectif d'assurer une dynamique de l'erreur d'estimation plus rapide que celle du système en boucle ouverte, les valeurs propres de $A - LC$ doivent être choisies judicieusement. Cependant, en pratique on est limité au niveau de la grandeur de cette dynamique et il n'est pas possible de prendre des dynamiques très grandes. En effet, d'une part on ne peut choisir que des gains réalisables, et d'autre part plus le gain sera élevé plus les bruits influenceront sur la reconstruction de l'état.

4.2 Application

La construction d'un tel observateur a été appliquée à notre cas d'étude. Le modèle du bâtiment utilisé dans l'algorithme d'optimisation est un modèle réduit d'ordre trois ($\dim x = 3$) et nous ne disposons en sortie que de la température intérieure ($\dim y = 1$). Le dimensionnement de la matrice L (réalisé sous Matlab) a été fait de manière à assurer une convergence plus rapide de l'observateur (la réponse de l'observateur à un échelon de puissance de chauffage est de quelques secondes) par rapport à la dynamique du modèle réduit d'ordre 3 tout en assurant un gain pas trop élevé.

Pour valider le fonctionnement de cet observateur, une comparaison sur un cas d'étude entre l'état estimé et l'état réel est nécessaire. Pour cela, on se place dans le cas d'étude défini au § 3.3.3. Connaissant parfaitement les sollicitations et en utilisant le profil optimal de puissance calculé, il est possible de simuler l'évolution de l'état du système d'ordre 3 et d'obtenir les températures simulées. Suite au dimensionnement de la matrice L , on peut alors simuler l'évolution de l'état estimé et le comparer à l'état réel. Les résultats sont présentés de la Figure 76 à la Figure 78 où l'on a considéré un état estimé initial nul. Il s'agit d'une configuration très défavorable où l'erreur entre l'état réel et l'état estimé est importante. Dans la pratique, cette erreur sera beaucoup plus faible. On peut constater que la convergence de l'erreur entre l'état estimé et l'état réel est d'environ quatre jours. Après cette période, l'évolution des courbes de l'état réel et de l'état estimé sont confondues. Ainsi, lors de l'estimation de l'état du bâtiment, il est suffisant de disposer des mesures des sollicitations (conditions météorologiques, occupation et puissance de chauffage) et de la température du bâtiment sur quatre jours pour s'assurer de la convergence de l'observateur asymptotique.

Chapitre 5 : Application de la commande prédictive




Figure 76 : Comparaison entre l'état réel 1 et l'état estimé 1

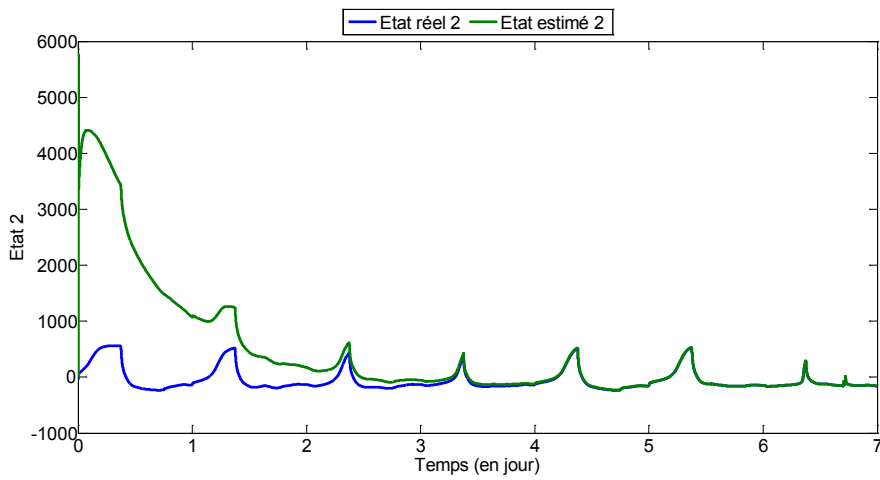


Figure 77 : Comparaison entre l'état réel 2 et l'état estimé 2




Figure 78 : Comparaison entre l'état réel 3 et l'état estimé 3

5. COMMANDE PRÉDICTIVE

Suite à la définition de l'algorithme d'optimisation (§ 3) et de l'observateur asymptotique (§ 4) permettant d'une part de calculer la commande optimale en boucle ouverte et d'autre part d'initialiser l'algorithme d'optimisation, il est désormais possible de mettre en place la commande prédictive. Cette commande prédictive a pour objectif de réguler un bâtiment en temps réel avec une mise à jour de la commande optimale toutes les 24 heures (période d'échantillonnage).

Ne disposant pas d'un bâtiment réel pour étudier le comportement de la commande prédictive, cette dernière sera étudiée en simulation numérique. Le modèle de bâtiment considéré correspond au modèle complet (de dimension 28) modélisé par COMFIE auquel on a rajouté les corrections concernant les échanges par ventilation. Pour rappel (§ 2 du chapitre 2), une valeur moyenne est considérée pour les débits de ventilation externe dans le système complet. Les corrections concernant les échanges par ventilation consistent à prendre en compte les écarts par rapport à la moyenne. Le comportement de la commande prédictive sera étudié sur deux cas d'application correspondant à la mise en place ou non d'un suivi de trajectoire par un régulateur.

5.1 Commande prédictive sans contrôleur

5.1.1 *Fonctionnement de la commande prédictive*

Le fonctionnement de la commande prédictive se déroule en cinq étapes.

La première étape (Figure 79) correspond à l'initialisation. Lors de cette étape, une consigne de chauffage constante (par exemple 19°C) peut être appliquée au bâtiment. L'objectif de cette étape est double. Le premier est de modéliser le bâtiment à réguler grâce au logiciel de simulation thermique dynamique Pléiades+COMFIE. Le modèle du bâtiment ainsi obtenu est ensuite réduit à l'ordre 3 (par la réalisation équilibrée § 2) dans le but de l'utiliser pour le calcul de la commande optimale (étape n°3). Le second objectif est de collecter les données nécessaires pour estimer l'état du bâtiment (étape n°2). La convergence de l'observateur asymptotique étant de quatre jours environ (§ 4), il est nécessaire de disposer d'au moins quatre jours de données concernant la température intérieure du bâtiment, la puissance de chauffage injectée ainsi que les sollicitations (conditions météorologiques, occupation).




Figure 79 : Schéma de l'étape n°1

Suite à l'initialisation, il est possible lors de l'étape n°2 d'estimer l'état initial du bâtiment (Figure 80). Grâce aux mesures collectées à l'étape n°1 et au développement d'un modèle réduit d'ordre 3 du bâtiment, il est possible d'estimer l'état du bâtiment à partir d'un observateur asymptotique basé sur la dynamique du modèle réduit (§ 4). Cette étape est indispensable pour déterminer les conditions initiales nécessaires à la résolution du problème de commande optimale (étape n°3).




Figure 80 : Schéma de l'étape n°2

L'état du bâtiment étant connu, il est alors possible de résoudre le problème de commande optimale et de calculer la commande de chauffage grâce à l'algorithme présenté au § 3 (Figure 81). Dans le but de diminuer les temps de calculs et suite à l'analyse de sensibilité, seule la connaissance de la tendance des prévisions des sollicitations à trois jours (sollicitations moyennées sur quatre périodes) est nécessaire pour calculer une commande proche de la commande optimale. Cette étape permet alors de définir la commande de chauffage à appliquer au bâtiment (profil de puissance de référence) ainsi que l'évolution supposée de la température à l'intérieur du bâtiment (trajectoire de température de référence).

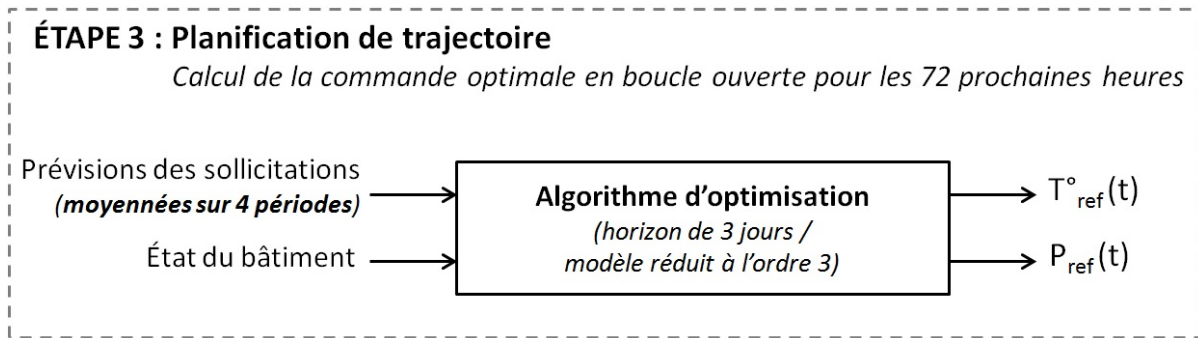


Figure 81 : Schéma de l'étape n°3

Dans le cas de la commande prédictive sans contrôleur, l'étape n°4 (Figure 82) correspond simplement à l'application sur les 24 premières heures du profil de puissance de référence (calculée pour les 72 prochaines heures) au bâtiment à réguler. Lors de cette étape la température réelle à l'intérieure du bâtiment est mesurée.

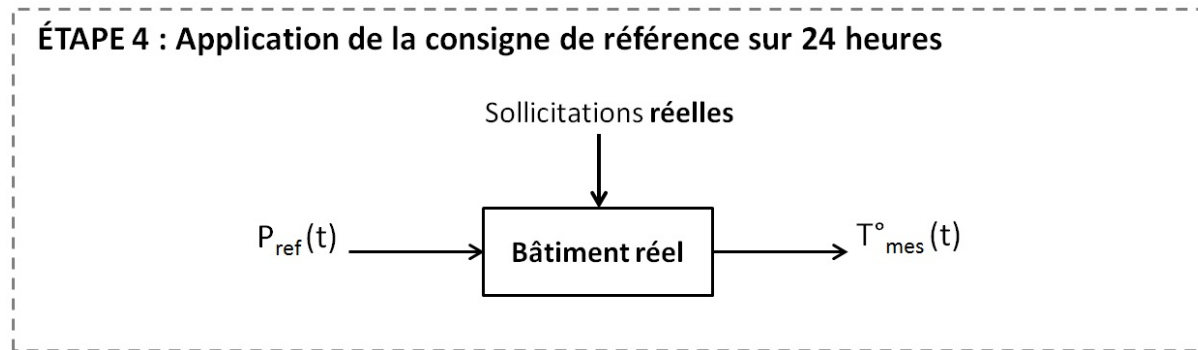


Figure 82 : Schéma de l'étape n°4 (sans régulateur)

Enfin, lors de l'étape n°5 (Figure 83), l'état courant du bâtiment est estimé suite à l'application du profil de puissance de référence sur 24 heures et à la mesure des sollicitations et de la température intérieure. Cet état estimé permettra alors de fermer la boucle et de retourner à l'étape n°3 pour calculer la commande de référence pour les 72 prochaines heures.

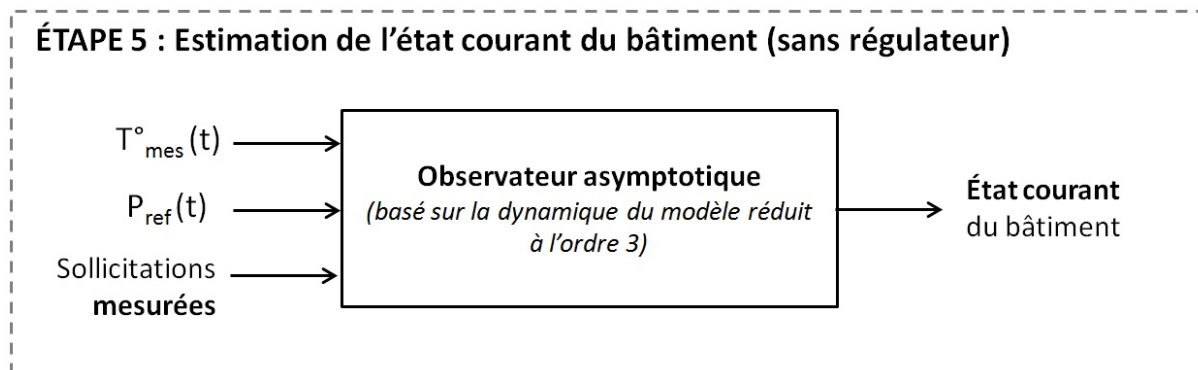


Figure 83 : Schéma de l'étape n°5

5.1.2 Résultats

La commande prédictive sans régulateur a été appliquée sur le cas d'étude défini au § 3.3.1 où la commande de la puissance de chauffage est mise à jour tous les jours à minuit. Les résultats sont présentés dans la Figure 84 et la Figure 85. Le coût de la commande de chauffage sur une semaine est de 13,37 €. On peut remarquer que le profil de la puissance de chauffage est très proche de celui calculé par la commande optimale sur un horizon d'une semaine avec les sollicitations parfaitement connues (§ 3.3.3). On constate par exemple que l'ensemble des heures pleines et de pointe sont effacées. En ce qui concerne les profils de température (Figure 85), plusieurs remarques peuvent être faites. Pour rappel, la température de référence (en bleu) correspond à la trajectoire calculée par la commande optimale avec un modèle réduit d'ordre 3 (sans correction sur la ventilation) et des sollicitations moyennées sur quatre périodes. La température mesurée (en vert) correspond quant à elle à la température simulée lorsqu'on applique le profil de puissance de référence au modèle complet (avec correction sur la ventilation) sous les sollicitations réelles. On constate que lors de la surchauffe du bâtiment pendant les heures creuses, la température mesurée et la température de référence sont proches. Cependant, lors des heures pleines, on peut remarquer une différence avec une température mesurée supérieure à la température de référence. Ce phénomène est particulièrement remarquable au troisième et quatrième jour. L'origine de ces différences est double. D'une part elles s'expliquent par le fait que la commande optimale (à partir de laquelle est calculée la trajectoire de référence) utilise des données de sollicitations moyennées. Ainsi, la valeur moyenne des sollicitations lors de cette période est inférieure à la valeur réelle des sollicitations (en particulier pour le rayonnement) expliquant la remontée de la température mesurée. Ce phénomène est mis en évidence sur la Figure 86 où l'on compare les températures de référence calculées avec des sollicitations réelles et moyennées. D'autre part, ces écarts peuvent également s'expliquer par une différence dans la dynamique de l'évolution de la température. En effet, la trajectoire de température de référence est calculée en considérant le modèle réduit à l'ordre 3 (sans correction sur la ventilation) alors que la température mesurée est calculée en considérant le modèle complet (avec correction sur la ventilation). Ce phénomène est mis en évidence sur la Figure 87 où l'on compare les températures de référence et mesurée en considérant dans les deux cas des sollicitations réelles. On constate alors que le modèle réduit à l'ordre 3 a tendance à surestimer la chute de température pendant les heures pleines et de pointe.

Chapitre 5 : Application de la commande prédictive




Figure 84 : Puissance de référence calculée par la commande prédictive sans régulateur

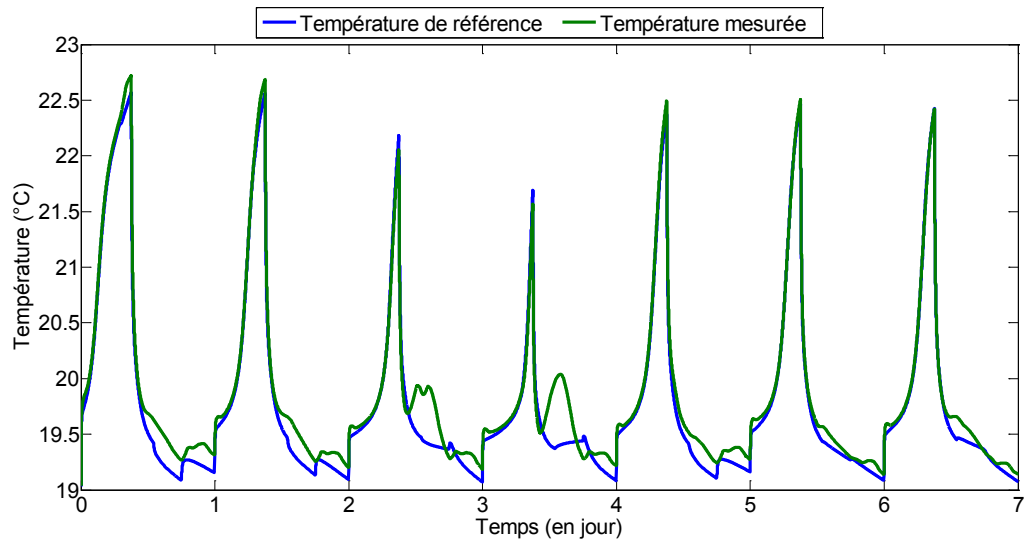


Figure 85 : Comparaison entre la température de référence et la température mesurée




Figure 86 : Comparaison entre les températures de référence calculées avec des sollicitations réelles ou moyennées




Figure 87 : Comparaison entre la température de référence (solicitations réelles) et la température mesurée

Enfin, il peut être intéressant de comparer les profils de puissance de référence obtenus avec des sollicitations réelles et moyennées (Figure 88). On constate que ces profils sont quasiment confondus et que les coûts calculés sont très proches avec respectivement 13,37 € et 13,32 €. Ces résultats valident l'intérêt de l'utilisation de sollicitations moyennées permettant d'obtenir une commande de la puissance de chauffage proche de la commande optimale tout en diminuant les temps de calcul.

En pratique, l'ajout d'un régulateur est nécessaire pour faire face à des événements imprévus (tels que des perturbations) et s'assurer de suivre la trajectoire de référence.

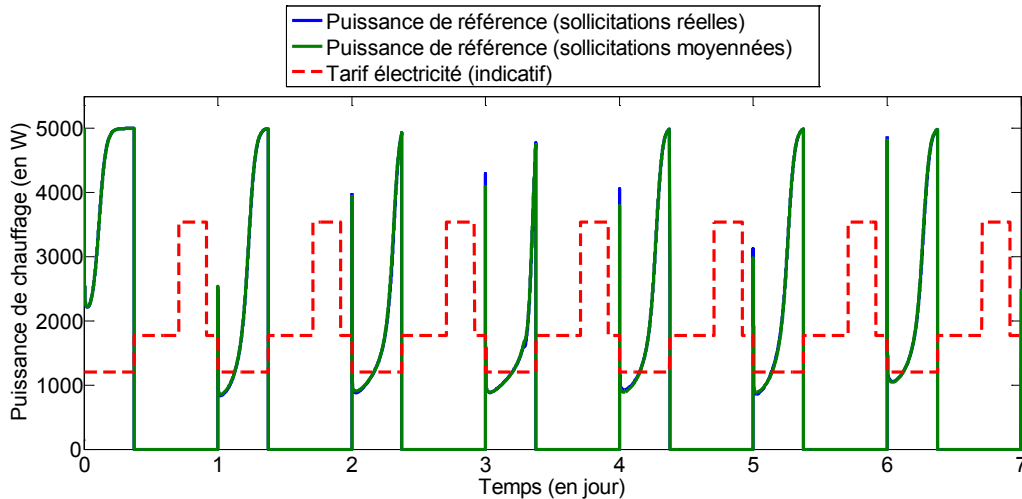


Figure 88 : Comparaison entre les puissances de référence calculées avec des sollicitations réelles ou moyennées

5.2 Commande prédictive avec régulateur

Lors de l'application de la commande de référence au bâtiment réel (étape n°4), des écarts peuvent être constatés entre l'évolution supposée de la température à l'intérieur du bâtiment (trajectoire de température de référence) et la température réellement mesurée. Ces écarts peuvent être la conséquence d'erreurs de modélisation (le modèle utilisé pour la planification de trajectoire est un modèle réduit d'ordre 3) ou d'erreurs dans l'échantillonnage des sollicitations et leurs prévisions (la trajectoire de référence est calculée à partir de la prévision des sollicitations moyennées sur quatre périodes). Une solution est de mettre en place un *feedback* qui assure le suivi asymptotique de la trajectoire de référence. Plus précisément, il s'agit de corriger la commande de chauffage calculée en boucle ouverte en fonction de l'erreur entre la température de référence et la température mesurée pour compenser les déviations entre la trajectoire réelle et la trajectoire de référence (Figure 89). Ce suivi de trajectoire peut être assuré par la mise en place d'un régulateur lors de l'étape n°4.




Figure 89 : Schéma de principe du suivi de trajectoire (adapté de Petit et Rouchon (2014))

5.2.1 Définition du régulateur

Le régulateur PI (proportionnel / intégral) est classiquement employé pour la régulation des bâtiments et peut être utilisé pour assurer le suivi de trajectoire. Le principe est alors de lui ajouter un terme d'anticipation, terme correspondant à la puissance de chauffage de référence calculée à l'étape n°3. Dans ce cadre, la puissance en sortie du régulateur peut être définie par :

$$\begin{cases} e(t) = T_{ref}^{\circ}(t) - T_{mes}^{\circ}(t) \\ P_{reg}(t) = S^{at} \left(P_{ref}(t) + K \left[e(t) + \frac{1}{T_i} \int_0^t e(t) dt \right] \right) \end{cases} \quad (5.31)$$

où S^{at} est la fonction de saturation permettant de respecter les contraintes, K est le gain proportionnel et T_i est le temps d'intégration. La fonction S^{at} est ici définie par :

$$\begin{cases} S^{at}(s) = P_{max} & \text{si } s > P_{max} \\ S^{at}(s) = s & \text{si } s \in [P_{min}, P_{max}] \\ S^{at}(s) = P_{min} & \text{si } s < P_{min} \end{cases} \quad (5.32)$$

L'intérêt de cette formulation est double. D'une part, l'ajout du terme d'anticipation permet de mieux gérer les variations de la trajectoire de référence (par exemple lors de la surchauffe du bâtiment pendant les heures creuses). D'autre part, la partie rétroaction permet quant à elle de compenser les erreurs du modèle du bâtiment ou encore les erreurs dans les prévisions des sollicitations.

En considérant le régulateur ainsi défini, un phénomène d'emballement peut apparaître. Ce phénomène se manifeste lorsque la commande calculée par le régulateur est différente de celle appliquée au système, c'est-à-dire lorsque la commande calculée par le régulateur dépasse les contraintes. Le régulateur continue alors d'intégrer l'erreur et à fournir une valeur de commande très supérieure (respectivement inférieure) à P_{max} (respectivement P_{min}). Un mécanisme d'anti-emballement (*anti-windup*) est alors classiquement ajouté au régulateur pour contrer ce phénomène. Une des solutions est de stopper l'intégration de l'erreur dès que la commande calculée sature (Astrom et Hagglund 1995). Les paramètres du régulateur ainsi défini ont été identifiés à l'aide du logiciel Matlab ($K = 2 \times 10^4 \text{ W/}^{\circ}\text{C}$ et $T_i = 30$ secondes).

L'étape n°4, définie au § 5.1.1, a été par conséquent modifiée par l'ajout de ce régulateur permettant de réaliser le suivi de trajectoire (Figure 90). Suite à cette étape, on dispose de la puissance en sortie du régulateur, ainsi que des mesures des sollicitations et de la température à l'intérieur du bâtiment. Ces données sont ensuite utilisées pour estimer l'état courant du bâtiment à l'étape n°5, où la puissance de référence (utilisée dans le cas de la commande prédictive sans régulateur) est remplacée par la puissance en sortie du régulateur (Figure 91). A la suite de cette étape, on retourne à l'étape n°3 pour calculer la commande de référence pour les 24 prochaines heures.

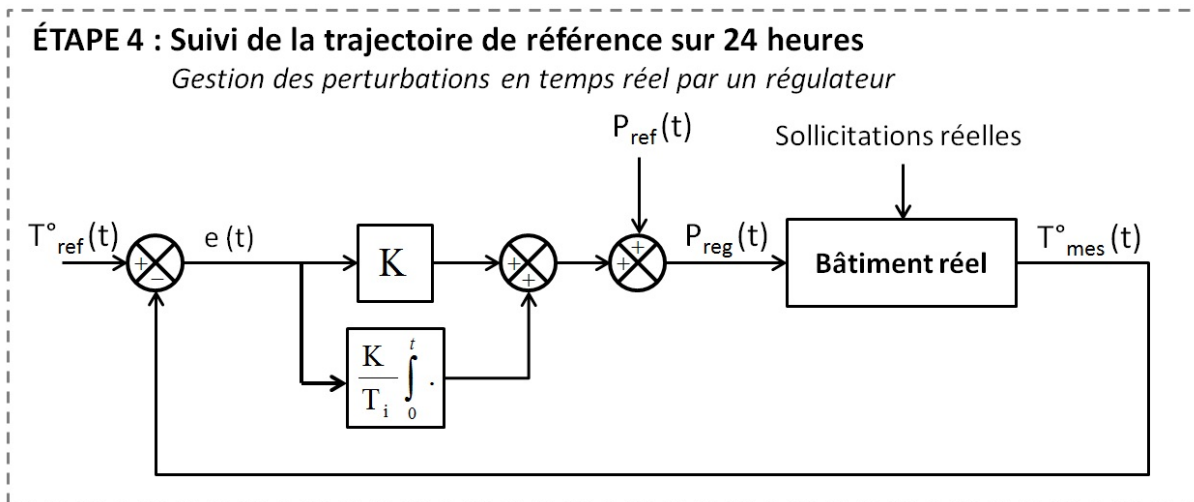


Figure 90 : Schéma de l'étape n°4 modifiée (avec régulateur)

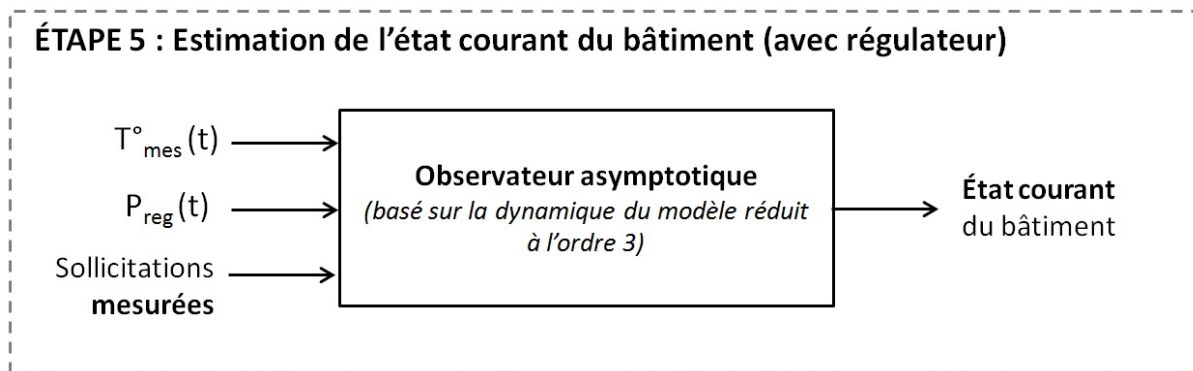


Figure 91 : Schéma de l'étape n°5 (avec régulateur)

5.2.2 Résultats

La commande prédictive avec régulateur a été appliquée sur le cas d'étude défini au § 3.3.1. Les résultats sont présentés dans la Figure 92 et la Figure 93. On peut constater qu'avec l'ajout du régulateur, le chauffage est utilisé lors des heures pleines et de pointe dans l'objectif de suivre au mieux la trajectoire de référence (Figure 92). Ceci entraîne une augmentation du coût de la commande de chauffage sur une semaine (13,49 €) par rapport à celui de la commande prédictive sans régulateur (13,37 €). On peut également noter que l'utilisation du régulateur permet de suivre plus précisément la trajectoire de référence en limitant les écarts à la température de référence (Figure 93). Enfin, comme dans le cas de la commande prédictive sans régulateur, on constate les mêmes écarts entre la température mesurée et la température de référence. Ces écarts s'expliquent par l'utilisation de sollicitations moyennées et du modèle réduit à l'ordre 3 lors du calcul de la commande optimale à partir de laquelle est calculée la trajectoire de référence.

Chapitre 5 : Application de la commande prédictive

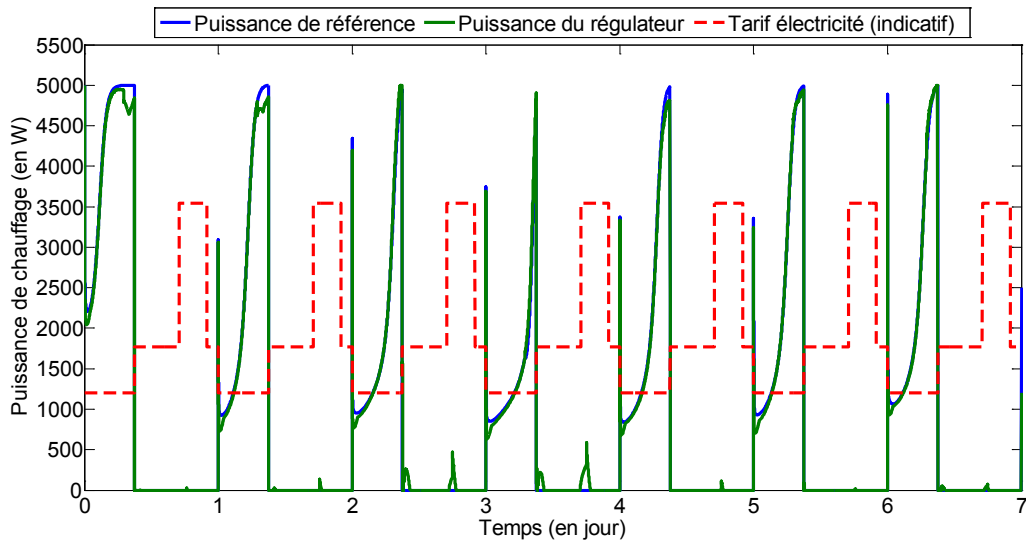


Figure 92 : Comparaison entre la puissance de référence et la puissance du régulateur




Figure 93 : Comparaison entre la température de référence et les températures mesurées (avec ou sans régulateur)

Ces résultats peuvent être comparés avec ceux obtenus par la commande prédictive avec régulateur en considérant les sollicitations parfaitement connues. Tout d'abord, les coûts calculés sont très proches avec respectivement 13,49 € et 13,31 € avec les sollicitations moyennées et les sollicitations réelles. De même sur la Figure 94 on peut remarquer qu'il existe très peu de différence entre la température mesurée engendrée par une commande calculée sous des sollicitations réelles (en bleu) et celle résultant de la commande calculée sous des sollicitations moyennées (en vert). Ceci valide l'intérêt de l'utilisation des sollicitations moyennées permettant d'obtenir une commande proche de la commande optimale tout en diminuant les temps de calculs (§ 3.4.2). Enfin, de manière logique, on constate que le régulateur a tendance à plus chauffer pendant les heures pleines ou de pointe lorsque la commande de référence a été calculée en considérant des sollicitations moyennées dans le but de

Chapitre 5 : Application de la commande prédictive

compenser les écarts (engendrés par les imprécisions sur les sollicitations) par rapport à la température de référence (Figure 95).




Figure 94 : Comparaison entre les températures mesurées (sollicitations réelles et moyennées)

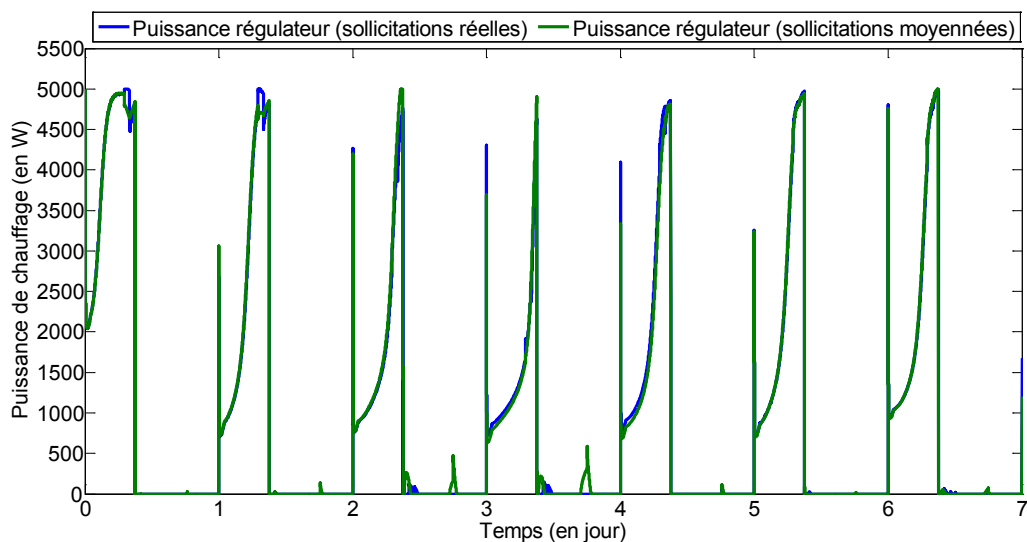


Figure 95 : Comparaison entre les puissances du régulateur calculées (sollicitations réelles et moyennées)

L'utilisation d'un régulateur est indispensable pour faire face à des événements imprévus en particulier lorsqu'une erreur importante est faite sur la prévision des sollicitations. Nous avons ainsi testé le régulateur sur le premier jour d'optimisation, en considérant que, contrairement aux prévisions, l'occupation réelle était nulle. Les résultats sont présentés dans la Figure 96 et la Figure 97. On constate que sans l'utilisation du régulateur, la température mesurée descend en dessous de la contrainte de température de 19°C. Au contraire, l'utilisation du régulateur permet de compenser les erreurs de prévisions (avec l'utilisation du chauffage de 18 h à 24 h), de suivre la trajectoire de référence et de respecter les contraintes de température. Ceci met en évidence l'intérêt du régulateur qui permet de

Chapitre 5 : Application de la commande prédictive

compenser les erreurs faites sur la modélisation et la prévision des sollicitations dans l'objectif de suivre la trajectoire de référence.




Figure 96 : Comparaison entre la température de référence et les températures mesurées (avec ou sans régulateur)

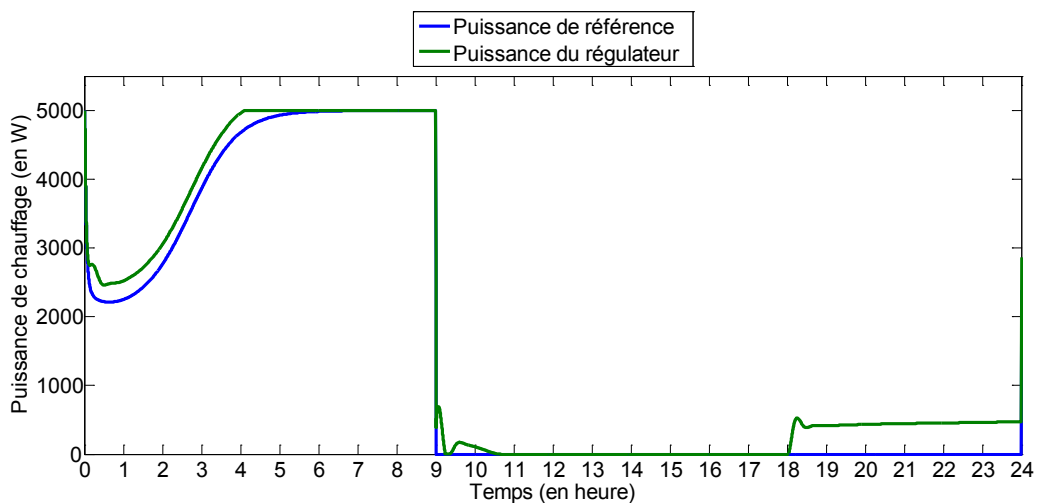


Figure 97 : Comparaison entre la puissance de référence et la puissance du régulateur

6. CONCLUSION DU CHAPITRE

Ce chapitre présente le développement d'une approche basée sur la commande prédictive, dont l'utilisation par les professionnels du bâtiment est destinée à se démocratiser dans un futur proche grâce au développement et à la diffusion des technologies nécessaires à son implémentation d'une part et à une demande accrue des acteurs économiques du bâtiment et de l'énergie pour le développement de solutions techniques dans le domaine de la gestion intelligente de l'énergie d'autre part. L'avantage

Chapitre 5 : Application de la commande prédictive

de la commande prédictive est de s'appuyer sur un modèle du bâtiment à réguler permettant d'anticiper son comportement et de calculer la commande qui minimise une fonction de coût donnée tout en respectant des contraintes imposées. La mise en place d'un tel système nécessitait cependant de répondre à de nombreuses difficultés théoriques à travers le développement d'un algorithme performant.

La première difficulté était de disposer d'un modèle réduit de bâtiment précis permettant une convergence rapide de l'algorithme d'optimisation. Dans le cadre de la régulation, l'utilisation de la réalisation équilibrée s'avère particulièrement efficace. Elle permet d'une part d'obtenir un modèle réduit complètement observable et commandable et d'autre part de réaliser un compromis entre précision et taille du modèle. Les résultats ont montré que, dans notre cas d'étude, un modèle réduit à l'ordre trois était nécessaire.

La deuxième difficulté était de disposer d'un algorithme d'optimisation rapide et robuste. Un algorithme d'optimisation basé sur la pénalisation intérieure a été présenté permettant de résoudre un problème de commande optimale sous contraintes d'état et de commande. Dans l'objectif de diminuer les temps de calcul, une analyse de sensibilité a été menée sur l'horizon d'optimisation de l'algorithme et sur la précision des sollicitations nécessaires.

La troisième difficulté était de connaître, à chaque période d'échantillonnage, l'état du bâtiment. Le développement d'un observateur asymptotique a été réalisé permettant d'estimer l'état du bâtiment à travers les mesures des sollicitations et de la température du bâtiment.

Enfin, la dernière difficulté était de pouvoir faire face, lors de l'application de la commande optimale, aux différentes perturbations faisant s'éloigner la trajectoire réelle de la température de la trajectoire de référence. Un régulateur PI utilisant un terme d'anticipation a été développé permettant d'assurer le suivi de trajectoire et de compenser les éventuelles erreurs de modélisation ou de prévision des sollicitations.

En conclusion, l'algorithme de commande prédictive développé présente de bonnes performances en terme de robustesse et de temps de calcul permettant d'envisager son utilisation dans des systèmes avancés de commande de bâtiment en temps réel. Plusieurs améliorations de l'algorithme peuvent être envisagées. Par exemple, l'utilisation de contraintes portant sur la variation de la température dans l'algorithme d'optimisation peut être intéressant dans l'objectif de prendre mieux en compte le confort de l'occupant, de même que l'extension de l'algorithme d'optimisation à un bâtiment multizone. Enfin, les mesures utilisées pour estimer l'état du bâtiment pouvant être incomplètes ou entachées d'incertitudes, le développement d'un filtre de Kalman à la place d'un observateur asymptotique peut être considéré.

Conclusion générale

BILAN DU TRAVAIL EFFECTUÉ

Conformément aux objectifs initiaux énoncés, cette thèse s'est intéressée au développement de méthodes et stratégies visant à une gestion optimisée en temps réel des flux énergétiques dans les bâtiments performants.

Le travail initial a consisté à réaliser un état de l'art sur la régulation énergétique des bâtiments, à en déterminer les principaux objectifs ainsi que les commandes associées. Il a permis également de présenter la problématique de gestion du réseau électrique dans laquelle s'inscrit cette thèse, le besoin de solutions innovantes pour la gestion de la demande en énergie et de voir dans quelle mesure la régulation énergétique des bâtiments peut répondre à cet enjeu.

Dans l'objectif d'anticiper l'état futur du bâtiment et de s'adapter aux usages et conditions environnementales changeantes, les stratégies de régulation doivent reposer sur des modèles qu'il est indispensable de définir. En premier lieu, un modèle thermique dynamique du bâtiment alliant précision et vitesse de calcul suffisante doit être utilisé. Le modèle thermique dynamique aux volumes finis COMFIE, réduit par analyse modale, a été choisi dans cette optique. L'occupation a quant à elle été définie par des scénarios représentatifs (qui peuvent être affinés à partir de mesures sur le terrain) plus adaptés au cadre de la régulation. Enfin, un modèle original de prévision météorologique locale a été développé. Ce dernier repose sur l'utilisation d'un modèle de type ARMA pour modéliser l'écart de température (ou de rayonnement) entre une station où nous disposons des prévisions de Météo France (prévision régionale) et le lieu où est situé le bâtiment considéré où l'on souhaite prévoir la température (ou le rayonnement). L'avantage de cette méthode est de s'appuyer sur la précision des prévisions météorologiques fournies par les modèles physiques. Les résultats ont montré leur intérêt pour la prévision de la température. Pour le rayonnement et dans l'étude de cas réalisée (écart entre Paris et Orly), les résultats sont plus mitigés et la méthode n'apporte pas d'amélioration par rapport à la prévision régionale.

Dans l'objectif de développer et calculer des stratégies de régulation les plus performantes possibles, il est nécessaire de prendre en compte les incertitudes et le manque de connaissance liés aux paramètres et variables du modèle. Il est alors utile de mettre en œuvre des méthodes de calibrage de modèle pour diminuer les écarts entre le comportement prévu par la simulation et le comportement réel. Une méthodologie basée sur le calcul bayésien approché a été développée, permettant de considérer l'ensemble des sources d'incertitudes et d'erreurs pouvant expliquer les différences entre les résultats de simulation et les données observées. Cette méthodologie présente l'avantage de pouvoir être utilisée aussi bien dans le cadre de la garantie de performance que dans le cadre de la régulation.

Elle est également générique et peut être utilisée sur n'importe quel modèle de bâtiment tout en utilisant des mesures diverses. Les résultats ont montré qu'il était possible d'estimer des distributions de probabilité *a posteriori* des paramètres influents du modèle et d'améliorer le comportement global de celui-ci. Cependant, dans le cas d'application considéré, les améliorations sont faibles par rapport au modèle non calibré. La validation de la méthodologie nécessiterait ainsi des études complémentaires pour évaluer ses performances sur différents cas d'étude.

Enfin, dans l'objectif de développer des stratégies de régulation adaptées au temps réel, deux approches ont été étudiées dans le cadre de l'effacement de la consommation électrique de pointe dans les bâtiments performants énergétiquement.

La première approche repose sur des méthodes d'optimisation hors-ligne dont l'objectif est d'élaborer des lois de type heuristique à partir de la stratégie optimale calculée par une méthode d'optimisation. Ces lois de commande simplifiées ont ainsi l'avantage de pouvoir être embarquées dans les systèmes de régulation couramment utilisés par les professionnels du bâtiment. Une méthode d'approximation, basée sur la régression Bêta, a été mise en œuvre permettant l'élaboration de lois heuristiques à partir des résultats de la programmation dynamique. Les résultats ont montré que les modèles de régression Bêta, associés à un contrôleur, étaient capables de reproduire le comportement général des stratégies issues de la programmation dynamique tout en présentant un temps de calcul très faible (150 fois inférieur à celui de la programmation dynamique). Une comparaison avec une loi purement heuristique a permis de valider l'intérêt de cette méthode. De même, une étude de l'influence des erreurs de prévision météorologique sur la loi heuristique a permis de démontrer sa robustesse.

La deuxième approche s'est portée sur la mise en place d'une commande prédictive adaptée au temps réel et le développement d'algorithmes performants nécessaires à sa mise en œuvre. En effet, d'une part la demande accrue des acteurs économiques du bâtiment et de l'énergie pour le développement de solutions techniques nouvelles dans le domaine de la gestion dynamique de la demande en énergie et de son pilotage, et d'autre part le développement récent des technologies nécessaires à l'implémentation de la commande prédictive laisse envisager son utilisation dans un futur proche par les professionnels. La mise en place d'un tel algorithme a nécessité de lever plusieurs verrous techniques. Tout d'abord, dans l'objectif de disposer d'un modèle réduit précis, rapide à calculer et présentant de bonnes propriétés pour le contrôle-commande, la réalisation équilibrée a été considérée dans cette étude. Ensuite, un algorithme d'optimisation rapide et robuste, basé sur la pénalisation intérieure a été adapté. Dans l'objectif de réduire ses temps de calcul, une analyse de sensibilité a par la suite été menée sur l'horizon d'optimisation et la précision des sollicitations. L'utilisation de cet algorithme nécessitant de connaître l'état du bâtiment à chaque période d'échantillonnage, un observateur asymptotique a également été réalisé. Enfin, un régulateur PI utilisant un terme d'anticipation a été étudié dans le but de suivre la trajectoire de référence calculée par l'algorithme d'optimisation et ainsi de compenser les erreurs de modélisation ou de prévision des sollicitations.

PERSPECTIVES

Les perspectives de ce travail sont nombreuses. Tout d'abord, il serait intéressant de disposer de données de mesure et de prévision de la température et du rayonnement de deux stations de Météo-France plus proches pour pouvoir valider le fonctionnement du modèle de prévision météorologique locale (et en particulier le principe de la modélisation de l'écart entre deux stations) sur un cas réel.

Ensuite, concernant le calibrage de modèle, la validation de la méthodologie présentée sur d'autres cas d'étude est indispensable. En particulier, l'utilisation d'une variable d'intérêt différente (telle que la consommation de chauffage, ou encore une facture d'électricité) ou l'application de la méthodologie sur un bâtiment ancien dont les caractéristiques sont mal connues (impliquant de considérer des plages d'incertitudes plus larges sur les distributions de probabilité *a priori* des paramètres influents) sont des cas d'étude intéressants à mener. Dans le cadre de la garantie de performance énergétique des bâtiments, la méthodologie de calibrage développée dans cette thèse est une première étape dans le développement d'un protocole de mesure et de vérification de cette performance. Cependant, de nombreuses questions théoriques restent à résoudre telles que la prise en compte dans le processus de calibrage des incertitudes liées à l'occupation. En effet, au delà du choix de la température de consigne, le comportement des occupants intègre divers aspects liés à la gestion de la ventilation et des protections solaires, à la consommation d'eau chaude et d'électricité (électroménager, bureautique, etc.) qu'il est important de prendre en compte.

Enfin, les deux approches développées pour les stratégies de régulation adaptées au temps réel pourraient également donner lieu à un approfondissement sur plusieurs aspects. Pour l'élaboration des lois heuristiques, l'évaluation de la robustesse des lois identifiées nécessite de considérer d'autres cas d'application, tels que l'étude du comportement de ces lois en intersaison. De plus, l'extension de la méthodologie à des modèles de bâtiment multizone est indispensable. De la même manière, des développements théoriques supplémentaires seraient nécessaires pour étendre l'application de la commande prédictive à un modèle de bâtiment multizone et à des contraintes de vitesse de variation de la température intérieure. La comparaison des performances des deux approches peut également être une perspective intéressante. L'utilisation d'une chambre climatique où il est possible de contrôler l'ensemble des sollicitations peut ainsi être envisagée, permettant de se placer dans les mêmes conditions expérimentales et de s'affranchir des perturbations. L'extension de ces méthodes à une période estivale, avec le pilotage de la ventilation forcée, de la ventilation naturelle et / ou des stores, est également un point important à développer soulevant des questions théoriques avec la prise en compte des non linéarités dans le processus d'optimisation, en particulier en ce qui concerne la commande prédictive. De manière plus globale, de nombreuses perspectives existent quant à l'utilisation de stratégies de gestion énergétique à l'échelle d'un quartier. En effet, des leviers d'action supplémentaires existent à l'échelle d'un îlot par exemple, en particulier la mutualisation des productions et des consommations et le stockage d'énergie. L'utilisation d'un contrôle hiérarchisé peut alors être envisagé où l'on considère différentes échelles de temps d'optimisation. L'idée générale est qu'à l'échelle du quartier une stratégie globale de stockage de l'énergie sur une échelle de temps longue

peut être calculée à partir d'un modèle simplifié d'un îlot. A partir de cette stratégie globale, une stratégie plus précise sur une échelle de temps plus courte peut ensuite être mise en œuvre à l'échelle de chaque bâtiment. Cette stratégie est alors calculée à partir d'un modèle plus fin des bâtiments et d'une meilleure connaissance des sollicitations (en particulier l'occupation) auxquelles ces derniers sont soumis.

Bibliographie

- ADEME. 2013. « Les chiffres clé du bâtiment - Énergie Environnement ». Agence De l'Environnement et Maitrise de l'Énergie.
- Ahmad, M., et C. H. Culp. 2006. « Uncalibrated Building Energy Simulation Modeling Results ». *HVAC&R Research* 12 (4): 1141-55. doi:10.1080/10789669.2006.10391455.
- Andersen, I., et M. J. Brandemuehl. 1992. « Heat storage in building thermal mass: A parametric study ». *ASHRAE Trans.*, 98 (1992) 910-918.
- ASHRAE. 2002. « Guideline 14-2002: measurement of energy and demand savings ». American Society of Heating, Refrigerating and Air-Conditioning Engineers.
- . 2003. « Thermal Environmental Conditions for Human Occupancy ». *Third Public Review*. American Society of Heating, Refrigerating and Air-Conditioning Engineers
- . 2004. *Thermal Environmental Conditions for Human Occupancy*. Vol. 55. 2004. American Society of Heating, Refrigerating and Air-Conditioning Engineers.
- Astrom, K., et T. Hagglund. 1995. *PID Controllers: Theory, Design, and Tuning*. 2nd Ed. Instrument society of America.
- Bacot, P. 1984. « Analyse modale des systèmes thermiques ». Thèse de doctorat, École Nationale Supérieure des Mines de Paris, 177 p.
- Bauer, M. 1998. « Gestion biomimétique de l'énergie dans le bâtiment ». Thèse de doctorat, Ecole Polytechnique Fédérale de Lausanne, 202 p.
- Beaumont, M. A., J.-M. Cornuet, J.-M. Marin, et Christian P. Robert. 2009. « Adaptive Approximate Bayesian Computation ». *Biometrika*, octobre, asp052. doi:10.1093/biomet/asp052.
- Becker, R, et M Paciuk. 2002. « Inter-related effects of cooling strategies and building features on energy performance of office buildings ». *Energy and Buildings* 34 (1): 25-31. doi:10.1016/S0378-7788(01)00081-0.
- Bellman, R. 1957. *Dynamic Programming*, Princeton, Princeton University Press.
- Bemporad, A., M. Morari, V. Dua, et E. N. Pistikopoulos. 2002. « The explicit linear quadratic regulator for constrained systems ». *Automatica* 38 (1): 3-20. doi:10.1016/S0005-1098(01)00174-1.
- Bernard, S. 2014. « Moyennisation et traitement du signal en contrôle optimal ». MINES ParisTech. <https://hal-mines-paristech.archives-ouvertes.fr/hal-01113625/document>.
- Bertagnolio, S., F. Randaxhe, et V. Lemort. 2012. « Evidence-based calibration of a building energy simulation model: Application to an office building in Belgium ». Proceedings of the Twelfth International Conference for Enhanced Building Operations, Manchester, UK, October 23-26, 2012.
- Betts, J. T. 2010. *Practical methods for optimal control and estimation using nonlinear programming*. Vol. 19. Siam.
- Blanc Sommereux, I. 1991. « Etude du couplage dynamique de composants du bâtiment par synthèse modale ». Thèse de doctorat, École Nationale Supérieure des Mines de Paris, 210 p.

- Blanc Sommereux, I. et G. Lefebvre. 1989. « Simulation de bâtiments multizones par couplage de modèles modaux réduits ». *Chauffage Ventilation Conditionnement d'air*, 5, p31-37.
- Bou-Saada, T. E., et J. S. Haberl. 1995. « An improved procedure for developing calibrated hourly simulation models ». <http://repository.tamu.edu/handle/1969.1/94780>.
- Box, G. E. P., et G. M. Jenkins. 1976. *Time series analysis: forecasting and control*. Vol. 734. Holden-Day.
- Braun, J. E. 1990. « Reducing energy costs and peak electrical demand through optimal control of building thermal storage ». *ASHRAE transactions* 96 (2): 876-88.
- . 2003. « Load control using building thermal mass ». *Transactions - American Society of Mechanical Engineers - Journal of Solar Energy Engineering*: 125 (3): 292-301.
- Braun, J. E., K. W. Montgomery, et N. Chaturvedi. 2001. « Evaluating the Performance of Building Thermal Mass Control Strategies ». *HVAC&R Research* 7 (4): 403-28. doi:10.1080/10789669.2001.10391283.
- Campbell, K. 2006. « Statistical calibration of computer simulations ». *Reliability Engineering & System Safety*, Proceedings of the Fourth International Conference on Sensitivity Analysis of Model Output (SAMO 2004), 91 (10-11): 1358-63. Santa Fe, New Mexico, USA, March 8-11, 2004. doi:10.1016/j.res.2005.11.032.
- Campolongo, F., J. Cariboni, et A. Saltelli. 2007. « An effective screening design for sensitivity analysis of large models ». *Environmental Modelling & Software*, Modelling, computer-assisted simulations, and mapping of dangerous phenomena for hazard assessment, 22 (10): 1509-18. doi:10.1016/j.envsoft.2006.10.004.
- CGDD. 2015. « Chiffres clés de l'énergie - Edition 2014 ». Commissariat Général au Développement Durable, Repères, Février 2015
- Chahwane, L. 2011. « Valorisation de l'inertie thermique pour la performance énergétique des bâtiments ». Thèse de doctorat, Université de Grenoble, 223 p.
- Chaplais, F., et N. Petit. 2008. « Inversion in indirect optimal control of multivariable systems ». *ESAIM : Control, Optimisation and Calculus of Variations*. Vol. 14, pp. 294-317.
- Chen, T. Y. 2002. « Application of adaptive predictive control to a floor heating system with a large thermal lag ». *Energy and Buildings* 34 (1): 45-51. doi:10.1016/S0378-7788(01)00076-7.
- Coakley, D., P. Raftery, et M. Keane. 2014. « A review of methods to match building energy simulation models to measured data ». *Renewable and Sustainable Energy Reviews* 37 (septembre): 123-41. doi:10.1016/j.rser.2014.05.007.
- Coakley, D., P. Raftery, et P. Molloy. 2012. « Calibration of whole building energy simulation models: detailed case study of a naturally ventilated building using hourly measured data ». *Building Simulation and Optimization*, 57-64.
- Coakley, D., P. Raftery, P. Molloy, et G. White. 2011. « Calibration of a detailed BES model to measured data using an evidence-based analytical optimisation approach ». *Proceedings of BS2011: 12th Conference of International Building Performance Simulation Association, Sydney, Australia, November 14-16, 2011*.
- Coffey, B. 2012. « Using Building Simulation and Optimization to Calculate Lookup Tables for Control ». Thèse de doctorat, UC Berkeley, 154 p.
- Coniff, J. P. 1991. « Strategies for reducing peak air conditioning loads by using heat storage in the building structure ». *ASHRAE Transactions* 97 (1): 704-9.

- Corbin, C. D., G. P. Henze, et P. May-Ostendorp. 2013. « A model predictive control optimization environment for real-time commercial building application ». *Journal of Building Performance Simulation* 6 (3): 159-74. doi:10.1080/19401493.2011.648343.
- Crawley, D. B. 1998. « Which weather data should you use for energy simulations of commercial buildings? ». *Transactions-American society of heating refrigerating and air conditioning engineers* 104: 498-515.
- Crawley, D. B., J. W. Hand, M. Kummert, et B. T. Griffith. 2008. « Contrasting the capabilities of building energy performance simulation programs ». *Building and Environment, Part Special: Building Performance Simulation*, 43 (4): 661-73. doi:10.1016/j.buildenv.2006.10.027.
- Csilléry, K., M. GB Blum, O. E. Gaggiotti, et O. François. 2010. « Approximate Bayesian computation (ABC) in practice ». *Trends in ecology & evolution* 25 (7): 410-18.
- Da Silva, D. 2011. « Analyse de la flexibilité des usages électriques résidentiels: application aux usages thermiques ». Thèse de doctorat, Ecole Nationale Supérieure des Mines de Paris, 269 p.
- De Dear, R., et G. Brager. 2002. « Thermal comfort in naturally ventilated buildings: revisions to ASHRAE Standard 55 ». *eScholarship*, février. <http://escholarship.org/uc/item/2pn696vv>.
- Deoux, P., et S. Deoux. 2002. « Le guide de l'habitat sain ». *Medieco éditions*.
- De Wit, S., et G. Augenbroe. 2002. « Analysis of uncertainty in building design evaluations and its implications ». *Energy and Buildings, A View of Energy and Bilding Performance Simulation at the start of the third millennium*, 34 (9): 951-58. doi:10.1016/S0378-7788(02)00070-1.
- Diagne, M., M. David, P. Lauret, J. Boland, et N. Schmutz. 2013. « Review of solar irradiance forecasting methods and a proposition for small-scale insular grids ». *Renewable and Sustainable Energy Reviews* 27: 65-76. doi:10.1016/j.rser.2013.06.042.
- Dickey, D. A., et W. A. Fuller. 1981. « Likelihood Ratio Statistics for Autoregressive Time Series with a Unit Root ». *Econometrica* 49 (4): 1057. doi:10.2307/1912517.
- Domahidi, A., F. Ullmann, M. Morari, et C. N. Jones. 2014. « Learning decision rules for energy efficient building control ». *Journal of Process Control, Energy Efficient Buildings Special Issue*, 24 (6): 763-72. doi:10.1016/j.jprocont.2014.01.006.
- Dounis, A.I., et C. Caraiscos. 2009. « Advanced control systems engineering for energy and comfort management in a building environment—A review ». *Renewable and Sustainable Energy Reviews* 13 (6-7): 1246-61. doi:10.1016/j.rser.2008.09.015.
- Emmerich, S. J., et A. K. Persily. 2001. *State-Of-The-Art Review of Co2 Demand Controlled Ventilation Technology and Application*. DIANE Publishing.
- EVO. 2009. « International Performance Measurement & Verification Protocol ». Efficiency Valuation Organisation.
- Faivre, R., B. looss, S. Mahévas, D. Makowski, et H. Monod. 2013. *Analyse de sensibilité et exploration de modèles: Application aux sciences de la nature et de l'environnement*. Collection Savoir faire. Editions Quae.
- Fanger, P. O. 1967. « Calculation of Thermal Comfort, Introduction of a Basic Comfort Equation ». *ASHRAE Transactions* 73 (2): III.4.1 - III.4.20.
- . 1970. « Thermal comfort. Analysis and applications in environmental engineering. », 244 pp.
- . 1986. « Thermal Environment — Human Requirements ». *Environmentalist* 6 (4): 275-78. doi:10.1007/BF02238059.

- Faruqui, A., et S. George. 2005. « Quantifying Customer Response to Dynamic Pricing ». *The Electricity Journal* 18 (4): 53-63. doi:10.1016/j.tej.2005.04.005.
- Faruqui, A., et S. Sergici. 2010. « Household Response to Dynamic Pricing of Electricity: A Survey of 15 Experiments ». *Journal of Regulatory Economics* 38 (2): 193-225. doi:10.1007/s11149-010-9127-Y.
- Favre, B. 2013. « Etude de stratégies de gestion énergétique des bâtiments par l'application de la programmation dynamique ». Thèse de doctorat, École Nationale Supérieure des Mines de Paris, 275 p.
- Favre, B., et B. Peuportier. 2012. « Étude d'une stratégie d'effacement de la consommation électrique de pointe dans le bâtiment par l'application de la programmation dynamique ». IBPSA France, Chambéry, France, 6-8 juin 2012.
- . 2013. « Optimization of building control strategies using dynamic programming ». Proceedings of BS2013: 13th Conference of International Building Performance Simulation Association, Chambéry, France, August 26-28, pp. 3449-3456.
- . 2014. « Application of dynamic programming to study load shifting in buildings ». *Energy and Buildings* 82 (octobre): 57-64. doi:10.1016/j.enbuild.2014.07.018.
- Federal Energy Regulatory Commission. 2006. *Assesment of demand response and advanced metering*. Washington DC: Department of Energy. <http://www.ferc.gov/legal/staff-reports/12-20-12-demand-response.pdf>.
- Ferrari, S., et F. Cribari-Neto. 2004. « Beta Regression for Modelling Rates and Proportions ». *Journal of Applied Statistics* 31 (7): 799-815. doi:10.1080/0266476042000214501.
- Freire, R. Z., G.H.C. Oliveira, et Nathan Mendes. 2008. « Predictive controllers for thermal comfort optimization and energy savings ». *Energy and Buildings* 40 (7): 1353-65. doi:10.1016/j.enbuild.2007.12.007.
- Greensfelder, E. M., G. P. Henze, et Clemens Felsmann. 2011. « An investigation of optimal control of passive building thermal storage with real time pricing ». *Journal of Building Performance Simulation* 4 (2): 91-104. doi:10.1080/19401493.2010.494735.
- Guerrier, B., E. Boileau, et C. Benard. 1980. « Analyse statistique temporelle de l'irradiation solaire globale quotidienne : modélisation d'une variable réduite à l'aide de modèles stochastiques A.R.M.A. » *Revue de Physique Appliquée* 15 (2): 93-102. doi:10.1051/rphysap:0198000150209300.
- Hämäläinen, R. P., et J. Mäntysaari. 2002. « Dynamic multi-objective heating optimization ». *European Journal of Operational Research* 142 (1): 1-15. doi:10.1016/S0377-2217(01)00282-X.
- Hämäläinen, R. P., J. Mäntysaari, J. Ruusunen, et P.O. Pineau. 2000. « Cooperative consumers in a deregulated electricity market — dynamic consumption strategies and price coordination ». *Energy* 25 (9): 857-75. doi:10.1016/S0360-5442(00)00024-4.
- Henze, G.P., et C. Neumann. 2010. « Modelling and Simulation in Building Automation Systems (Chapter 14) ». In *Building Performance Simulation for Design and Operation*, Taylor and Francis. J.L.M. Hensen and R. Lamberts.
- Henze, G. P., D.E. Kalz, S. Liu, et C. Felsmann. 2005. « Experimental Analysis of Model-Based Predictive Optimal Control for Active and Passive Building Thermal Storage Inventory ». *HVAC&R Research* 11 (2): 189-213. doi:10.1080/10789669.2005.10391134.

- Heo, Y., R. Choudhary, et G.A. Augenbroe. 2012. « Calibration of building energy models for retrofit analysis under uncertainty ». *Energy and Buildings* 47 (avril): 550-60. doi:10.1016/j.enbuild.2011.12.029.
- Heo, Y. 2011. « Bayesian calibration of building energy models for energy retrofit decision-making under uncertainty ». PhD Thesis, Georgia Institute of Technology, 129 p.
- Heo, Y., D. J. Graziano, L. Guzowski, et R. T. Muehleisen. 2014. « Evaluation of calibration efficacy under different levels of uncertainty ». *Journal of Building Performance Simulation* 0 (0): 1-10. doi:10.1080/19401493.2014.896947.
- Herter, K. 2007. « Residential implementation of critical-peak pricing of electricity ». *Energy Policy* 35 (4): 2121-30. doi:10.1016/j.enpol.2006.06.019.
- Herter, K, P. McAuliffe, et A. Rosenfeld. 2007. « An exploratory analysis of California residential customer response to critical peak pricing of electricity ». *Energy* 32 (1): 25-34. doi:10.1016/j.energy.2006.01.014.
- Humphreys, M. A., et J.F. Nicol. 2002. « The validity of ISO-PMV for predicting comfort votes in everyday thermal environments ». *Energy and Buildings* 34 (6): 667-84. doi:10.1016/S0378-7788(02)00018-X.
- Hyndman, R. J., et Y. Khandakar. 2007. « Automatic time series for forecasting: the forecast package for R ». http://webdoc.sub.gwdg.de/ebook/serien/e/monash_univ/wp6-07.pdf.
- Iooss, B. 2009. « Analyses d'incertitudes et de sensibilité des modèles complexes-Applications dans des problèmes d'ingénierie ». *Rencontres «Maths-Météo» Toulouse*. http://www.math.univ-toulouse.fr/~baehr/meteo_SMAI/Pres/Pres_looss.pdf.
- Keeney, K., et J. Braun. 1996. « A Simplified Method for Determining Optimal Cooling Control Strategies for Thermal Storage in Building Mass ». *HVAC&R Research* 2 (1): 59-78. doi:10.1080/10789669.1996.10391333.
- Kelly, N., J. Hong, I. Richardson, et M. Thomson. 2011. « The influence of thermal storage on microgeneration flexibility ». *Proceedings of the 2nd International Conference in Microgeneration Technologies*, 2011-04-04 - 2011-04-06, Glasgow, Scotland.
- Kennedy, M. C., et A. O'Hagan. 2001. « Bayesian Calibration of Computer Models ». *Journal of the Royal Statistical Society: Series B (Statistical Methodology)* 63 (3): 425-64. doi:10.1111/1467-9868.00294.
- Kwiatkowski, D., P.C.B. Phillips, P. Schmidt, et Y. Shin. 1992. « Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have a unit root? ». *Journal of Econometrics* 54 (1-3): 159-78. doi:10.1016/0304-4076(92)90104-Y.
- Laub, A.J., M.T. Heath, C. Paige, et R. Ward. 1987. « Computation of system balancing transformations and other applications of simultaneous diagonalization algorithms ». *IEEE Transactions on Automatic Control* 32 (2): 115-22. doi:10.1109/TAC.1987.1104549.
- Le, K., R. Bourdais, et H. Guéguen. 2014. « From hybrid model predictive control to logical control for shading system: A support vector machine approach ». *Energy and Buildings* 84 (décembre): 352-59. doi:10.1016/j.enbuild.2014.07.084.
- Le, K. 2008. « Gestion optimale des consommations d'énergie dans les bâtiments ». Thèse de doctorat, Institut National Polytechnique de Grenoble - INPG, 196 p.
- Lenormand, M., F. Jabot, et G. Deffuant. 2013. « Adaptive Approximate Bayesian Computation for Complex Models ». *Computational Statistics* 28 (6): 2777-96. doi:10.1007/s00180-013-0428-3.
- « Le projet EnR-Pool ». 2013. <http://www.enr-pool.pemaco.fr/>. Consulté le 23/01/2014

- Lefebvre, G. 1987. « Analyse et réduction modales d'un modèle de comportement thermique du bâtiment ». Thèse de doctorat, Université Pierre et Marie Curie, Paris VI, 176 p.
- . 2007. *La méthode modale en thermique: Modélisation, simulation, mise en oeuvre, applications*. Ellipses.
- Les Avis de l'ADEME. 2012. *L'effacement des consommations électriques résidentielles*. Consulté le 22/01/2014
- Ljung, L. 1999. *System identification: theory for the user*. Prentice Hall PTR, USA.
- Lomas, K. J., et H. Eppel. 1992. « Sensitivity analysis techniques for building thermal simulation programs ». *Energy and Buildings* 19 (1): 21-44. doi:10.1016/0378-7788(92)90033-D.
- Lund, H. 1985. « Short reference years and test reference years for EEC countries: Final report ». Rapport technique, Thermal Insulation Laboratory, Technical University of Denmark.
- Macdonald, I. A. 2002. « Quantifying the effects of uncertainty in building simulation ». PhD Thesis, University of Strathclyde, 267 p.
- Makowski, D. 2014. « Analyse d'incertitudes, analyse de sensibilité. Objectifs et principales étapes. » présenté à Ecole-chercheurs ASPEN (Analyse de sensibilité, propagation d'incertitudes, et exploration numérique de modèles en sciences de l'environnement), Les Houches, mai.
- Malisani, P. 2012. « Pilotage dynamique de l'énergie du bâtiment par commande optimale sous contraintes utilisant la pénalisation intérieure ». Thèse de doctorat, École Nationale Supérieure des Mines de Paris, 149 p
- Malisani, P., F. Chaplais, et N. Petit. 2014. « An Interior Penalty Method for Optimal Control Problems with State and Input Constraints of Nonlinear Systems ». *Optimal Control Applications and Methods*. doi:10.1002/oca.2134.
- Mare, J. B, J. A. De Dona. 2004. « Use of dynamic programming for the analytical solution of input-constrained LQR problems », 442-48 Vol.1. doi:10.1109/ASCC.2004.184801.
- Marjoram, P., J. Molitor, V. Plagnol, et S. Tavaré. 2003. « Markov Chain Monte Carlo without Likelihoods ». *Proceedings of the National Academy of Sciences, vol. 100, no 26, p. 15324-15328*. doi:10.1073/pnas.0306899100.
- Marshall, S.A. 1966. « An approximate method for reducing the order of a linear system ». *Control* 10: 642-43.
- Marwan, M., et F. Kamel. 2011. « Demand Side Response to Mitigate Electrical Peak Demand in Eastern and Southern Australia ». *Energy Procedia* 12: 133-42. doi:10.1016/j.egypro.2011.10.019.
- Matyasovszky, I. 2001. « A Nonlinear Approach to Modeling Climatological Time Series ». *Theoretical and Applied Climatology* 69 (3-4): 139-47. doi:10.1007/s007040170020.
- Mayne, D. Q., J. B. Rawlings, C. V. Rao, et P. O. M. Scokaert. 2000. « Constrained model predictive control: Stability and optimality ». *Automatica* 36 (6): 789-814. doi:10.1016/S0005-1098(99)00214-9.
- May-Ostendorp, P. T., G. P. Henze, B. Rajagopalan, et C. D. Corbin. 2013. « Extraction of supervisory building control rules from model predictive control of windows in a mixed mode building ». *Journal of Building Performance Simulation* 6 (3): 199-219. doi:10.1080/19401493.2012.665481.
- McCray, J. A., P. L. Bailey, J. L. Parker, et R. Gillman. 1995. « Using data visualization tools for the calibration of hourly DOE-2, 1 simulations ». *Proceedings of BS1995: 4th Conference of International Building Performance Simulation Association, Madison, Wisconsin, USA, August 14-16, 1995*.

- Mellit, A., M. Benghanem, et S.A. Kalogirou. 2006. « An adaptive wavelet-network model for forecasting daily total solar-radiation ». *Applied Energy* 83 (7): 705-22. doi:10.1016/j.apenergy.2005.06.003.
- Météo-France. « Les modèles de prévision de Météo-France - Météo-France ». http://comprendre.meteofrance.com/jsp/site/Portal.jsp?&page_id=16395. Consulté le 01/06/2015.
- Météo-France, et Agence Parisienne du Climat. 2013. *L'îlot de chaleur urbain à Paris: un microclimat au coeur de la ville*.
- Moore, B. 1981. « Principal component analysis in linear systems: Controllability, observability, and model reduction ». *IEEE Transactions on Automatic Control* 26 (1): 17-32. doi:10.1109/TAC.1981.1102568.
- Morosan, P.-D. 2011. « Commande prédictive distribuée. Approches appliquées à la régulation thermique des bâtiments. » Thèse de doctorat, Supélec, 216 p.
- Moroşan, P.-D., R. Bourdais, D. Dumur, et J. Buisson. 2010. « Building temperature regulation using a distributed model predictive control ». *Energy and Buildings* 42 (9): 1445-52. doi:10.1016/j.enbuild.2010.03.014.
- Morris, M. D. 1991. « Factorial Sampling Plans for Preliminary Computational Experiments ». *Technometrics* 33 (2): 161-74. doi:10.1080/00401706.1991.10484804.
- Morris, F.B., J.E. Braun, et S.J. Treado. 1994. « Experimental and simulated performance of optimal control of building thermal storage ». *Ashrae transactions* 100 (1).
- Munaretto, F. 2014. « Etude de l'influence de l'inertie thermique sur les performances énergétiques des bâtiments ». Thèse de doctorat, École Nationale Supérieure des Mines de Paris, 355 p.
- Muselli, M., P. Poggi, G. Notton, et A. Louche. 2001. « First order Markov chain model for generating synthetic "typical days" series of global irradiation in order to design photovoltaic stand alone systems ». *Energy Conversion and Management* 42 (6): 675-87. doi:10.1016/S0196-8904(00)00090-X.
- Musy, M. et E. Bozonnet. 2013. « Micro-climats et interactions avec le bâtiment ». In *Livre Blanc sur les recherches en énergétique des bâtiments*. Presses des MINES. Paris (France). Peuportier Bruno.
- Neveu, A. 1984. « Étude d'un code de calcul d'évolution thermique d'une enveloppe de bâtiment ». Thèse de doctorat, Université Pierre et Marie Curie, Paris VI, 94 p.
- Nicol, J.F., et M. A. Humphreys. 2002. « Adaptive thermal comfort and sustainable thermal standards for buildings ». *Energy and Buildings* 34 (6): 563-72. doi:10.1016/S0378-7788(02)00006-3.
- Nicol, J. F., et M. A. Humphreys. 2004. « A Stochastic Approach to Thermal Comfort–Occupant Behavior and Energy Use in Buildings. » *ASHRAE transactions* 110 (2).
- Nicol, F., et M. Wilson. 2010. « An overview of the European Standard EN 15251 ». In *Proceedings of Conference: Adapting to Change: New Thinking on Comfort. Cumberland Lodge, Windsor, UK*, 9-11. <http://nceub.commoncense.info/uploads/16-01-02-Nicol.pdf>.
- Nygaard Ferguson. 1990. « Predictive thermal control of building systems ». Thèse de doctorat, Ecole polytechnique fédérale de Lausanne, 190 p.
- Olaru, S. 2005. « Contribution à l'étude de la commande prédictive sous contraintes par approche géométrique ». Thèse de doctorat, Université Paris Sud - Paris XI, 269 p.
- Oldewurtel, F., A. Parisio, C. N. Jones, D. Gyalistras, M. Gwerder, V. Stauch, B. Lehmann, et M. Morari. 2012. « Use of model predictive control and weather forecasts for energy efficient building climate control ». *Energy and Buildings* 45 (février): 15-27. doi:10.1016/j.enbuild.2011.09.022.

- Palomo Del Barrio, E., G. Lefebvre, P. Behar, et N. Bailly. 2000. « Using model size reduction techniques for thermal control applications in buildings ». *Energy and Buildings* 33 (1): 1-14. doi:10.1016/S0378-7788(00)00060-8.
- Pedrini, A., F. S. Westphal, et R. Lamberts. 2002. « A methodology for building energy modelling and calibration in warm climates ». *Building and Environment* 37 (8–9): 903-12. doi:10.1016/S0360-1323(02)00051-3.
- Perez, R., R. Seals, R. Stewart, A. Zelenka, et V. Estrada-Cajigal. 1994. « Using satellite-derived insolation data for the site/time specific simulation of solar energy systems ». *Solar Energy* 53 (6): 491-95. doi:10.1016/0038-092X(94)90128-O.
- Petit, N., M. B. Milam, et R. M. Murray. 2001. « Inversion based constrained trajectory optimization ». In *5th IFAC Symposium on Nonlinear Control Systems*, St. Petersburg.
- Petit, N., et A. Sciarretta. 2011. « Optimal drive of electric vehicles using an inversion-based trajectory generation approach ». In *Proc. of the 18th IFAC World Congress*.
- Petit, N., et P. Rouchon. 2014. « Dynamique et contrôle des systèmes ». Cours, MINES ParisTech.
- Peuportier, B., et I. Blanc-Sommereux. 1990. « Simulation tool with its expert interface for the thermal design of multizone buildings ». *International Journal of Sustainable Energy* 8 (2): 109-20. doi:10.1080/01425919008909714.
- Pineau, P.-O., et R. P. Hämmäläinen. 2000. « A perspective on the restructuring of the Finnish electricity market ». *Energy Policy* 28 (3): 181-92.
- Pritchard, J. K., M. T. Seielstad, A. P.-Lezaun, et M. W. Feldman. 1999. « Population growth of human Y chromosomes: a study of Y chromosome microsatellites. » *Molecular Biology and Evolution* 16 (12): 1791-98.
- Prívara, S., J. Šíroký, L. Ferkl, et J. Cigler. 2011. « Model predictive control of a building heating system: The first experience ». *Energy and Buildings* 43 (2–3): 564-72. doi:10.1016/j.enbuild.2010.10.022.
- Prívara, S., Z. Váňa, E. Žáčková, et J. Cigler. 2012. « Building modeling: Selection of the most appropriate model for predictive control ». *Energy and Buildings* 55 (décembre): 341-50. doi:10.1016/j.enbuild.2012.08.040.
- Raftery, A. E., T. Gneiting, F. Balabdaoui, et M. Polakowski. 2005. « Using Bayesian model averaging to calibrate forecast ensembles ». *Monthly Weather Review* 133 (5): 1155-74.
- Raftery, P., M. Keane, et J. O'Donnell. 2011. « Calibrating whole building energy models: An evidence-based methodology ». *Energy and Buildings* 43 (9): 2356-64. doi:10.1016/j.enbuild.2011.05.020.
- R Core Team. 2014. *R: A language and Environment for Statistical Computing*. Vienna, Austria: R Foundation for Statistical Computing.
- Recht, T., F. Munaretto, P. Schalbart, et B. Peuportier. 2014. « Analyse de la fiabilité de COMFIE par comparaison à des mesures. Application à un bâtiment passif. » In *IBPSA France 2014*, Arras, France, 20-21 mai 2014.
- Reddy, T. A., I. Maor, et C. Panjapornpon. 2007. « Calibrating Detailed Building Energy Simulation Programs with Measured Data—Part I: General Methodology (RP-1051) ». *HVAC&R Research* 13 (2): 221-41. doi:10.1080/10789669.2007.10390952.
- Richalet, J., A. Rault, J. L. Testud, et J. Papon. 1978. « Model predictive heuristic control: Applications to industrial processes ». *Automatica* 14 (5): 413-28. doi:10.1016/0005-1098(78)90001-8.

- Riddle, M., et R. T. Muehleisen. 2014. « A GUIDE TO BAYESIAN CALIBRATION OF BUILDING ENERGY MODELS ». 2014 ASHRAE/IBPSA-USA Building Simulation Conference, Atlanta, GA, September 10-12, 2014.
- RTE. 2012. *Bilan prévisionnel de l'équilibre offre-demande d'électricité en France - Édition 2012*. Réseau de transport d'électricité
- . 2013. *Actualisation du bilan prévisionnel de l'équilibre offre-demande d'électricité en France*. Réseau de transport d'électricité
- . 2014. *Bilan prévisionnel de l'équilibre offre-demande d'électricité en France - Édition 2014*. Réseau de transport d'électricité
- Ruud, M. D., J. W. Mitchell, et S. A. Klein. 1990. « Use of Building Thermal Mass to Offset Cooling Loads ». *ASHRAE Transactions (American Society of Heating, Refrigerating and Air-Conditioning Engineers); (United States)* 96:2 (janvier).
- Sane, H., et M. Guay. 2008. « Minmax dynamic optimization over a finite-time horizon for building demand control ». In *American Control Conference, Seattle WA, USA, 11-13 June 2008*, 1469-74. doi:10.1109/ACC.2008.4586699.
- Schmid, M., F. Wickler, K. O. Maloney, R. Mitchell, N. Fenske, et A. Mayr. 2013. « Boosted Beta Regression ». *PLoS ONE* 8 (4): e61623. doi:10.1371/journal.pone.0061623.
- Sempey, A., C. Inard, C. Ghiaus, et C. Allery. 2009. « Fast simulation of temperature distribution in air conditioned rooms by using proper orthogonal decomposition ». *Building and Environment* 44 (2): 280-89. doi:10.1016/j.buildenv.2008.03.004.
- Sfetsos, A., et A.H. Coonick. 2000. « Univariate and multivariate forecasting of hourly solar radiation with artificial intelligence techniques ». *Solar Energy* 68 (2): 169-78. doi:10.1016/S0038-092X(99)00064-X.
- Shampine, L. F., J. Kierzenka, et M. W. Reichelt. 2000. « Solving boundary value problems for ordinary differential equations in MATLAB with *bvp4c* ». *Tutorial notes*.
- Sharif, M., et D. H. Burn. 2006. « Simulating climate change scenarios using an improved K-nearest neighbor model ». *Journal of Hydrology* 325 (1-4): 179-96. doi:10.1016/j.jhydrol.2005.10.015.
- ADEME. 2013. « Les chiffres clé du bâtiment - Energie Environnement ». Agence De l'Environnement et Maitrise de l'Energie.
- CGDD. 2015. « Chiffres clés de l'énergie - Edition 2014 ». Commissariat Général au Développement Durable, Repères, Février 2015
- Sidler, Olivier. 2011. « De la conception à la mesure, comment expliquer les écarts? ». présenté à "Évaluer les performances des bâtiments basse consommation", Colloque CSTB/CETE de l'OUEST, Angers, France, Janvier 2011.
- Siebert, N. 2008. « Développement de méthodes pour la prédiction de la production éolienne régionale ». Thèse de doctorat, École Nationale Supérieure des Mines de Paris, 287 p.
- Sisson, S. A., Y. Fan, et Mark M. Tanaka. 2007. « Sequential Monte Carlo without Likelihoods ». *Proceedings of the National Academy of Sciences*, vol. 104, no 6, p. 1760-1765. doi:10.1073/pnas.0607208104.
- Smithson, M., et J. Verkuilen. 2006. « A Better Lemon Squeezer? Maximum-Likelihood Regression with Beta-Distributed Dependent Variables. » *Psychological Methods* 11 (1): 54-71. doi:10.1037/1082-989X.11.1.54.

- Spitz, C. 2012. « Analyse de la fiabilité des outils de simulation et des incertitudes de métrologie appliquée à l'efficacité énergétique des bâtiments ». Thèse de doctorat, Université de Grenoble, 196 p.
- Sukhbir, M., C. Newcomb, S. Bluck, et R. Ehteshamzadeh. 1993. « Optimizing the use of energy management and control systems to reduce peak load and energy consumption in non-residential buildings ». *Report to California Institute for Energy Efficiency and Sacramento Municipal Utilities District*.
- Tasadduq, I., S. Rehman, et K. Bubshait. 2002. « Application of neural networks for the prediction of hourly mean surface temperatures in Saudi Arabia ». *Renewable Energy* 25 (4): 545-54. doi:10.1016/S0960-1481(01)00082-9.
- Thellier, F., F. Monchoux, S. Spagnol, et M. Bonnis-Sassi. 2009. « Measurement of ambient air temperature for evaluation of human heat convective losses ». *Measurement* 42 (1): 62-70. doi:10.1016/j.measurement.2008.04.001.
- Thellier, F., F. Monchoux, et J.-P. Bedrune. 2012. « Confort dans le bâtiment : n'oublions pas l'habitant! ». *La revue 3E.I*, vol 69, pp. 24-32.
- Touretzky, C. R., et M. Baldea. 2014. « Integrating Scheduling and Control for Economic MPC of Buildings with Energy Storage ». *Journal of Process Control* 24 (8): 1292-1300. doi:10.1016/j.jprocont.2014.04.015.
- Trélat, E. 2005. *Contrôle optimal: théorie & applications*. Vuibert.
- Turner, B. M., et T. Van Zandt. 2012. « A tutorial on approximate Bayesian computation ». *Journal of Mathematical Psychology* 56 (2): 69-85. doi:10.1016/j.jmp.2012.02.005.
- Turner, C., et M. Frankel. 2008. « Energy performance of LEED® for new construction buildings ». *Final Report for US Green Building Council, NBI, Washington DC*.
- Van Oijen, M., J. Rougier, et R. Smith. 2005. « Bayesian calibration of process-based forest models: bridging the gap between models and data ». *Tree Physiology* 25 (7): 915-27.
- Vorger, E. 2014. « Etude de l'influence du comportement des habitants sur la performance énergétique du bâtiment ». Thèse de doctorat, Ecole Nationale Supérieure des Mines de Paris, 474 p.
- Voyant, C. 2011. « Prédiction de séries temporelles de rayonnement solaire global et de production d'énergie photovoltaïque à partir de réseaux de neurones artificiels ». Thèse de doctorat, Université Pascal Paoli, 257 p.
- Wang, S., et X. Xu. 2004. « Optimal and robust control of outdoor ventilation airflow rate for improving energy efficiency and IAQ ». *Building and Environment* 39 (7): 763-73. doi:10.1016/j.buildenv.2004.01.033.
- Wei, C.-C., et N.-S. Hsu. 2009. « Optimal tree-based release rules for real-time flood control operations on a multipurpose multireservoir system ». *Journal of Hydrology* 365 (3-4): 213-24. doi:10.1016/j.jhydrol.2008.11.038.
- Wilkinson, R. D. 2013. « Approximate Bayesian computation (ABC) gives exact results under the assumption of model error ». *Statistical Applications in Genetics and Molecular Biology* 12 (2): 129-41. doi:10.1515/sagmb-2013-0010.
- Wood, S. N. 2010. « Statistical Inference for Noisy Nonlinear Ecological Dynamic Systems ». *Nature* 466 (7310): 1102-4. doi:10.1038/nature09319.
- Wyse, B. 2011. « Investigation into the Time-Shifting of Domestic Heat Loads ». Mémoire de master, University of Strathclyde, 92 p.

- Xu, P., P. Haves, M. A. Piette, et James Braun. 2004. « Peak demand reduction from pre-cooling with zone temperature reset in an office building ». *Lawrence Berkeley National Laboratory*, août. <http://escholarship.org/uc/item/1205612d#page-3>.
- Yahia, A. A., et E. Palomo Del Barrio. 1999. « Thermal systems modelling via singular value decomposition: direct and modular approach ». *Applied Mathematical Modelling* 23 (6): 447-68. doi:10.1016/S0307-904X(98)10091-4.
- Yang, L., C. Dong, C. L. J. Wan, et Chi To Ng. 2013. « Electricity time-of-use tariff with consumer behavior consideration ». *International Journal of Production Economics* 146 (2): 402-10. doi:10.1016/j.ijpe.2013.03.006.

ANNEXE A. RÉSULTATS DE LA MODÉLISATION DE LA TEMPÉRATURE

Tableau 28 : Récapitulatif des résultats de la modélisation de la température en °C

	Modélisation	Modèles	MAE 1 h	MAE 3 h	MAE 6 h	MAE 12 h	MAE 24 h	MBE 1 h	MBE 3 h	MBE 6 h	MBE 12 h	MBE 24 h
Mois de janvier	Directe	SARIMA (1,1,1)(2,1,2)	0,30	0,66	1,10	1,75	2,49	0,01	0,05	0,11	0,23	0,64
	Écart	SARIMA (2,1,3)(1,1,0)	0,45	0,68	0,89	1,10	1,11	0,01	0,03	0,07	0,09	0,10
Mois de février	Directe	SARIMA (1,1,1)(0,1,1)	0,26	0,59	1,04	1,50	1,68	-0,01	-0,02	-0,04	-0,10	-0,27
	Écart	SARIMA (2,1,1)(1,1,0)	0,48	0,79	1,07	1,20	1,10	-0,01	-0,03	-0,07	-0,10	-0,16
Mois de mars	Directe	SARIMA (1,1,0)(0,1,1)	0,31	0,60	0,89	1,24	1,54	0,00	0,00	0,00	-0,02	-0,09
	Écart	SARIMA (0,1,2)(0,1,1)	0,41	0,59	0,75	0,94	0,89	-0,01	-0,03	-0,06	-0,08	-0,10
Mois d'avril	Directe	SARIMA (1,1,1)(0,1,1)	0,43	1,01	1,66	2,46	3,51	-0,03	-0,08	-0,16	-0,29	-0,66
	Écart	SARIMA (0,1,1)(0,1,1)	0,59	0,93	1,30	1,57	1,21	-0,02	-0,07	-0,13	-0,16	-0,18
Mois de mai	Directe	SARIMA (0,1,1)(2,1,2)	0,44	0,85	1,36	1,89	2,08	0,01	0,02	0,04	0,09	0,24
	Écart	SARIMA (1,1,1)(1,1,0)	0,54	0,79	1,09	1,25	1,16	0,00	-0,01	-0,03	-0,03	-0,05
Mois de juin	Directe	SARIMA (2,1,0)(0,1,1)	0,46	1,00	1,51	1,92	2,16	0,00	-0,01	-0,02	-0,01	0,11
	Écart	SARIMA (1,1,1)(0,1,1)	0,47	0,65	0,74	0,75	0,77	-0,02	-0,05	-0,05	-0,04	-0,02

	Modélisation	Modèles	MAE 1 h	MAE 3 h	MAE 6 h	MAE 12 h	MAE 24 h	MBE 1 h	MBE 3 h	MBE 6 h	MBE 12 h	MBE 24 h
Mois de juillet	Directe	SARIMA (1,1,0)(0,1,1)	0,47	0,91	1,30	1,62	1,87	-0,02	-0,05	-0,10	-0,21	-0,37
	Écart	SARIMA (2,1,2)(1,1,0)	0,69	0,89	0,97	1,05	1,03	-0,04	-0,09	-0,13	-0,17	-0,16
Mois d'août	Directe	SARIMA (1,1,0)(0,1,1)	0,34	0,72	1,20	1,77	2,36	0,00	0,00	0,01	0,01	-0,08
	Écart	SARIMA (0,1,0)(2,1,0)	0,64	1,03	1,39	1,80	1,40	0,00	0,00	-0,01	-0,04	-0,09
Mois de septembre	Directe	SARIMA (3,1,2)(0,1,1)	0,42	0,86	1,34	1,95	2,07	0,01	0,04	0,10	0,20	0,23
	Écart	SARIMA (2,1,1)(1,1,0)	0,66	0,87	1,16	1,34	1,50	0,02	0,03	0,05	0,07	0,07
Mois d'octobre	Directe	SARIMA (1,1,3)(0,1,1)	0,36	0,75	1,20	1,62	1,98	-0,02	-0,07	-0,14	-0,25	-0,29
	Écart	SARIMA (1,1,2)(0,1,1)	0,38	0,56	0,71	0,80	0,76	0,02	0,06	0,09	0,12	0,09
Mois de novembre	Directe	SARIMA (0,1,2)(2,1,1)	0,24	0,52	0,82	1,23	1,49	0,01	0,03	0,05	0,09	0,24
	Écart	SARIMA (0,1,0)(2,1,0)	0,32	0,54	0,75	0,93	0,97	0,00	0,00	0,00	-0,01	-0,01
Mois de décembre	Directe	SARIMA (0,1,2)(1,1,2)	0,30	0,68	1,08	1,55	1,89	0,00	-0,01	-0,03	-0,07	-0,11
	Écart	SARIMA (2,1,1)(1,1,0)	0,44	0,71	0,88	1,03	1,19	0,02	0,04	0,07	0,11	0,11

ANNEXE B. RÉSULTATS DE LA MODÉLISATION DU RAYONNEMENT

Tableau 29 : Récapitulatif des résultats de la modélisation du rayonnement en W/m²

	Modélisation	Modèles	MAE 1 h	MAE 3 h	MAE 6 h	MAE 12 h	MAE 24 h	MBE 1 h	MBE 3 h	MBE 6 h	MBE 12 h	MBE 24 h
Mois de janvier	Directe	SARIMA (2,1,2)(0,1,1)	18,1	34,6	35,0	34,4	35,5	0,1	0,0	-0,9	-1,0	-2,0
	Écarts	SARIMA (1,1,1)(0,1,1)	8,7	9,4	9,5	9,6	9,5	1,5	2,2	2,2	1,6	1,3
Mois de février	Directe	SARIMA (2,1,2)(0,1,1)	41,7	68,7	76,2	76,8	77,0	3,9	4,5	1,3	0,5	0,7
	Écarts	SARIMA (1,1,1)(0,1,1)	19,9	23,0	24,1	21,6	26,0	1,2	1,7	0,8	0,2	3,1
Mois de mars	Directe	SARIMA (0,1,1)(0,1,2)	50,7	83,0	85,7	82,7	120,1	2,6	11,4	9,8	46,3	-6,4
	Écarts	SARIMA (0,1,1)(0,1,1)	27,9	28,0	22,0	29,8	30,0	2,3	2,7	2,8	1,1	0,9
Mois d'avril	Directe	SARIMA (1,1,2)(0,1,1)	56,8	104,8	112,7	118,0	119,8	2,9	4,5	-2,3	-6,3	-12,8
	Écarts	SARIMA (2,1,0)(2,1,0)	38,0	54,0	50,2	44,7	50,9	0,7	0,7	-1,7	-4,3	2,0
Mois de mai	Directe	SARIMA (0,1,3)(1,1,2)	65,6	116,7	135,7	129,2	144,1	0,0	-0,2	-10,1	-9,4	-12,4
	Écarts	SARIMA (0,1,1)(0,1,2)	42,6	42,8	42,9	41,8	43,4	-0,1	0,3	1,0	-0,1	-2,7
Mois de juin	Directe	SARIMA (0,1,2)(2,1,2)	86,1	147,2	158,4	149,2	165,0	1,0	2,4	2,0	2,8	8,1
	Écarts	SARIMA (0,1,1)(1,1,0)	44,1	45,4	45,5	43,5	42,9	0,9	0,6	-0,4	-0,5	2,7

	Modélisation	Modèles	MAE 1 h	MAE 3 h	MAE 6 h	MAE 12 h	MAE 24 h	MBE 1 h	MBE 3 h	MBE 6 h	MBE 12 h	MBE 24 h
Mois de juillet	Directe	SARIMA (0,1,2)(1,1,2)	53,4	73,5	74,5	81,5	81,3	-4,8	-12,7	-22,5	-26,5	-2,5
	Écart	SARIMA (4,1,0)(2,1,0)	36,9	39,4	36,7	40,0	36,2	-0,1	-0,3	-0,5	-1,1	0,4
Mois d'août	Directe	SARIMA (1,1,2)(0,1,1)	45,5	86,0	100,9	100,8	112,0	-1,0	-3,1	-9,3	-13,2	-7,3
	Écart	SARIMA (1,1,1)(0,1,1)	23,1	25,9	26,1	26,6	28,0	-3,1	-3,9	-3,9	-3,7	-3,9
Mois de septembre	Directe	SARIMA (1,1,2)(0,1,2)	47,0	85,0	95,7	92,9	93,2	1,0	4,2	8,8	-0,2	-9,7
	Écart	SARIMA (0,1,1)(1,1,2)	21,7	21,8	21,8	22,2	22,4	-1,7	-1,3	-2,1	-1,5	-0,2
Mois d'octobre	Directe	SARIMA (1,1,1)(0,1,1)	37,4	55,4	38,6	50,9	52,7	0,8	1,1	6,0	-1,4	5,1
	Écart	SARIMA (5,1,0)(0,1,1)	17,5	19,6	13,2	16,9	19,1	-0,6	-1,1	-1,9	-2,4	-2,2
Mois de novembre	Directe	SARIMA (0,1,0)(0,1,1)	19,1	32,1	28,7	26,7	24,2	-0,8	-4,4	-12,0	-15,8	-0,3
	Écart	SARIMA (1,1,1)(0,1,1)	8,8	9,0	8,9	8,8	8,7	0,9	1,0	1,1	1,1	0,3
Mois de décembre	Directe	SARIMA (1,1,2)(0,1,1)	15,0	24,9	27,1	27,3	28,6	-1,3	-4,2	-5,5	-5,4	-3,5
	Écart	SARIMA (1,1,1)(0,1,1)	9,3	10,2	10,0	10,2	10,9	0,0	0,0	-0,1	0,3	-0,3

ANNEXE C. PARAMÈTRES CONSIDÉRÉS LORS DU CRIBLAGE DE MORRIS

Tableau 30 : Paramètres du modèle thermique considérés lors du criblage de Morris

Description	Nom	Min	Max	Unité
Albédo du sol environnant	Alb	0,3	0,4	[-]
Latitude	Lat	45,596	45,687	[°]
Longitude	Lon	5,869	-5,881	[°]
Température du sol	Tsl	7	11	[°C]
Orientation par rapport à l'axe sud	Ori	-17	-13	[°]
Variation taux d'infiltration d'air	Inf	-10	10	[%]
Variation débit nominal de ventilation	Qv,nom-1	-15	15	[%]
Variation débit nominal de ventilation	Qv,nom-2	-15	15	[%]
Température de consigne	Tco	-0,5	0,5	[°C]
Puissance dissipée des appareils	Pdi	-10	10	[%]
Puissance de chauffage	Pch	1,14	1,26	[kW]
Résistance thermique des occultations	Roc	0,16	0,24	[(m ² .K)/W]
Facteur d'occultation	Foc	-2	2	[%]
<i>Coefficient d'échange thermique de la menuiserie</i>				
F1	Uwf_F1	1,33	1,47	[W/m ²]
F2	Uwf_F2	1,25	1,38	[W/m ²]
F3	Uwf_F3	1,29	1,42	[W/m ²]
F4	Uwf_F4	1,41	1,56	[W/m ²]
F5 Rdc	Uwf_F5 Rdc	1,37	1,52	[W/m ²]
F6	Uwf_F6	1,36	1,5	[W/m ²]
F7	Uwf_F7	1,23	1,36	[W/m ²]
F8	Uwf_F8	1,3	1,44	[W/m ²]
<i>Évolution de la surface de la menuiserie par rapport à la surface initiale</i>				
F1	Swf_F1	-1	1	[%]
F2	Swf_F2	-1	1	[%]
F3	Swf_F3	-1	1	[%]
F4	Swf_F4	-1	1	[%]
F5 Rdc	Swf_F5 Rdc	-1	1	[%]
F6	Swf_F6	-1	1	[%]
F7	Swf_F7	-1	1	[%]
F8	Swf_F8	-1	1	[%]
<i>Émissivité</i>				
	Eps_Peinture blanche	0,86	0,95	[-]
	Eps_Couleur lisse brun	0,86	0,95	[-]

Eps_Enduit	0,86	0,95	[-]
Absorptivité			
Alp_Peinture blanche	0,17	0,23	[-]
Alp_Couleur lisse brun	0,6	0,81	[-]
Alp_Enduit	0,55	0,75	[-]
Facteur solaire de la menuiserie			
Sow_F1	36	40	[%]
Sow_F2	45	50	[%]
Sow_F3	38	42	[%]
Sow_F4	26	29	[%]
Sow_F5s	31	34	[%]
Sow_F6	32	36	[%]
Sow_F7	23	26	[%]
Sow_F8	20	22	[%]
Épaisseur			
Epa_Polystyrène extrudé Styrofoam	19,5	20,5	[cm]
Epa_Dalle pleine en béton armé	15,5	16,5	[cm]
Epa_Chape Béton	7,5	8,5	[cm]
Epa_Carrelage	0,95	1,05	[cm]
Epa_Placoplâtre BA 13	1,24	1,37	[cm]
Epa_Lame d'air 15 cm	14,5	15,5	[cm]
Epa_Plancher poutrelles + hourdis	19,5	20,5	[cm]
Epa_Platre gypse	0,95	1,05	[cm]
Epa_Laine de verre	3,80	4,20	[cm]
Epa_Crepis	1,43	1,58	[cm]
Epa_Polystyrène extrudé Wallmate	19,5	20,5	[cm]
Epa_Enduit hydrofugé	1,43	1,58	[cm]
Epa_Béton banché	14,5	15,5	[cm]
Epa_LDV ISOCONFORT 35	39,5	40,5	[cm]
Conductivité			
Con_Polystyrène extrudé Styrofoam	0,027	0,033	[W/(m.K)]
Con_Dalle pleine en béton armé	2,34	2,66	[W/(m.K)]
Con_Chape Beton	1,6	1,9	[W/(m.K)]
Con_Carrelage	0,36	0,46	[W/(m.K)]
Con_Placoplatre BA 13	0,28	0,38	[W/(m.K)]
Con_Lame d'air 15 cm	0,84	1,03	[W/(m.K)]
Con_Plancher poutrelles + hourdis	0,96	1,14	[W/(m.K)]
Con_Platre gypse	0,38	0,48	[W/(m.K)]
Con_Laine de verre	0,038	0,044	[W/(m.K)]
Con_Crepis	0,62	0,78	[W/(m.K)]
Con_Polystyrene extrude Wallmate	0,027	0,033	[W/(m.K)]
Con_Enduit hydrofuge	0,92	1,77	[W/(m.K)]
Con_Beton banche	1,6	1,9	[W/(m.K)]
Con_LDV ISOCONFORT 35	0,032	0,039	[W/(m.K)]
Capacité thermique volumique			
Cvl_Polystyrène extrudé Styrofoam	44	54	[kJ/(m3.K)]

	Cvl_Dalle pleine en béton armé	2181	2619	[kJ/(m3.K)]
	Cvl_Chape Béton	1891	2333	[kJ/(m3.K)]
	Cvl_Carrelage	1090	1310	[kJ/(m3.K)]
	Cvl_Placoplâtre BA 13	599	759	[kJ/(m3.K)]
	Cvl_Lame d'air 15 cm	1,1	1,3	[kJ/(m3.K)]
	Cvl_Plancher poutrelles + hourdis	443	593	[kJ/(m3.K)]
	Cvl_Plâtre gypse	1088	1312	[kJ/(m3.K)]
	Cvl_Laine de verre	22	29	[kJ/(m3.K)]
	Cvl_Crepis	1267	1533	[kJ/(m3.K)]
	Cvl_Polystyrène extrudé Wallmate	44	54	[kJ/(m3.K)]
	Cvl_Enduit hydrofuge	1631	1969	[kJ/(m3.K)]
	Cvl_Beton banche	1906	2326	[kJ/(m3.K)]
	Cvl_LDV ISOCONFORT 35	7	13	[kJ/(m3.K)]
Coefficient d'échange convectif intérieur				
	Plancher bas sur vide sanitaire HciPbVS	1,42	2,14	[W/(m².K)]
	Plancher haut sur grenier ventilé HciPhGV	3,67	5,51	[W/(m².K)]
	Plancher intermédiaire HciPi	0,9	3	[W/(m².K)]
	Parois verticales HciPv	1	6	[W/(m².K)]
	Paroi en contact avec le sol HciSol	1	6	[W/(m².K)]
Coefficient d'échange convectif extérieur				
	Parois verticales HcePvExt	5,6	24,67	[W/(m².K)]
	Plancher bas sur vide sanitaire HcePbVS	2,66	4	[W/(m².K)]
	Plancher haut sur grenier ventilé HcePhGV	3,2	4,8	[W/(m².K)]
Coefficient d'échange radiatif intérieur				
	Plancher bas sur vide sanitaire HriPbVS	3,91	5,87	[W/(m².K)]
	Plancher haut sur grenier ventilé HriPhGV	3,87	5,81	[W/(m².K)]
	Plancher intermédiaire HriPi	4	6	[W/(m².K)]
	Parois verticales HriPv	4,84	5,13	[W/(m².K)]
	Paroi en contact avec le sol HriSol	4,89	5,13	[W/(m².K)]
Coefficient d'échange radiatif extérieur				
	Parois verticales HrePvExt	3,3	4,63	[W/(m².K)]
	Plancher bas sur vide sanitaire HrePbVS	2,34	3,5	[W/(m².K)]
	Plancher haut sur grenier ventilé HrePhGV	2,51	3,77	[W/(m².K)]
Évolution des ponts thermiques par rapport à la valeur initiale				
	Psi_Monozone	-5	5	[%]

ANNEXE D. IDENTIFICATION DES MODÈLES DE RÉGRESSION

BÊTA

Tableau 31 : Identification des modèles de régression BETA_1, BETA_4 et BETA_5

Variable explicative conservée	Estimation du paramètre associé
Constante	3,148e+01
$T_{ext}(t + \Delta t)$	-2,011e-01
$T_{ext}(t + 6\Delta t)$	-1,405e-01
$G_h(t + 6\Delta t)$	-5,620e-04
$C_{elec}(t + \Delta t)$	-1,772e-01
$T_{zone}(t)$	-6,847e-01
$T_{zone}(t - 6\Delta t)$	-2,324e-01
$T_{zone}(t - 12\Delta t)$	-7,764e-01
$P(t)$	1,616e-03
$P(t - \Delta t)$	-4,971e-04
$P(t - 12\Delta t)$	5,757e-04

Tableau 32 : Identification du modèle de régression BETA_2

Variable explicative conservée	Estimation du paramètre associé
Constante	3,094e+01
$T_{ext}(t + \Delta t)$	-1,648e-01
$T_{ext}(t + 6\Delta t)$	-1,282e-01
$G_h(t + 6\Delta t)$	-5,070e-04
$C_{elec}(t + \Delta t)$	-1,064e+00
$T_{zone}(t - 6\Delta t)$	-7,229e-01
$T_{zone}(t - 12\Delta t)$	-7,222e-01

$P(t)$	1,116e-03
$P(t - \Delta t)$	4,447e-04
$P(t - 6\Delta t)$	5,076e-04
$P(t - 12\Delta t)$	6,495e-04

Tableau 33 : Identification du modèle de régression BETA_3

Variable explicative conservée	Estimation du paramètre associé
Constante	4,203e+01
$T_{ext}(t + 6\Delta t)$	-6,991e-02
$G_h(t + 6\Delta t)$	-2,911e-04
$T_{zone}(t)$	-2,330e+00
$P(t)$	2,784e-03

1. MODÈLES DE RÉGRESSION BÊTA

1.1 Modèles BETA_1 et BETA_2

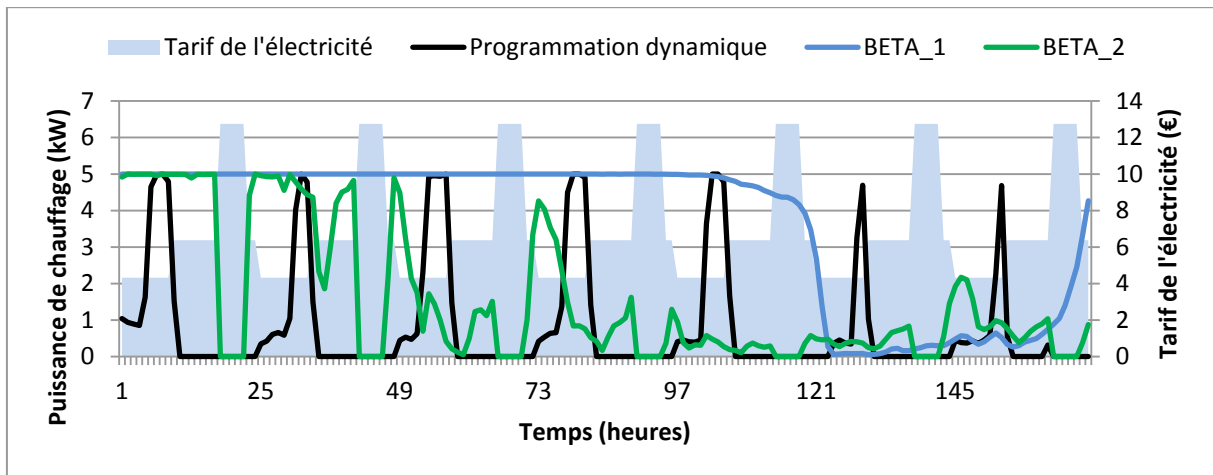


Figure 98 : Puissances de chauffage calculées par la programmation dynamique, BETA_1 et BETA_2 (première semaine)




Figure 99 : Puissances de chauffage calculées par la programmation dynamique, BETA_1 et BETA_2 (deuxième semaine)

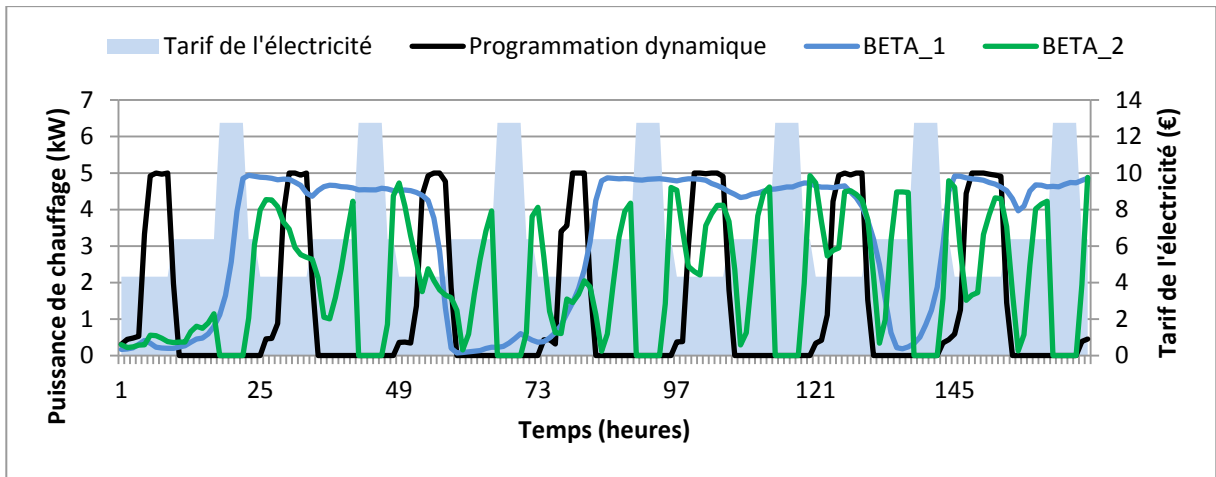


Figure 100 : Puissances de chauffage calculées par la programmation dynamique, BETA_1 et BETA_2 (troisième semaine)

1.2 Modèle BETA_3




Figure 101 : Puissances de chauffage calculées par la programmation dynamique et BETA_3 (première semaine)




Figure 102 : Puissances de chauffage calculées par la programmation dynamique et BETA_3 (deuxième semaine)




Figure 103 : Puissances de chauffage calculées par la programmation dynamique et BETA_3 (troisième semaine)

1.3 Modèles BETA_4 et BETA_5




Figure 104 : Puissances de chauffage calculées par la programmation dynamique, BETA_4 et BETA_5 (première semaine)

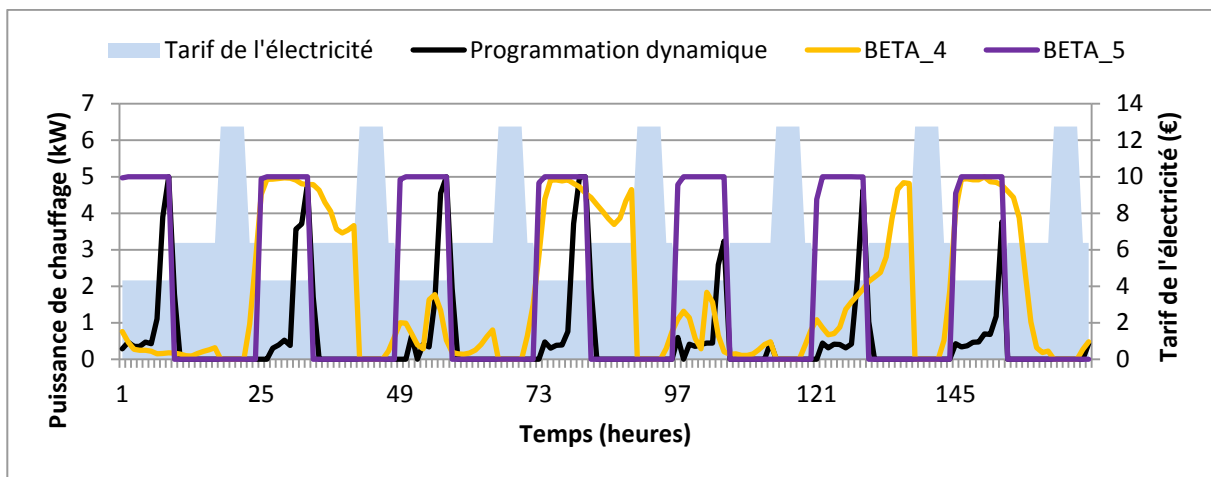


Figure 105 : Puissances de chauffage calculées par la programmation dynamique, BETA_4 et BETA_5 (deuxième semaine)

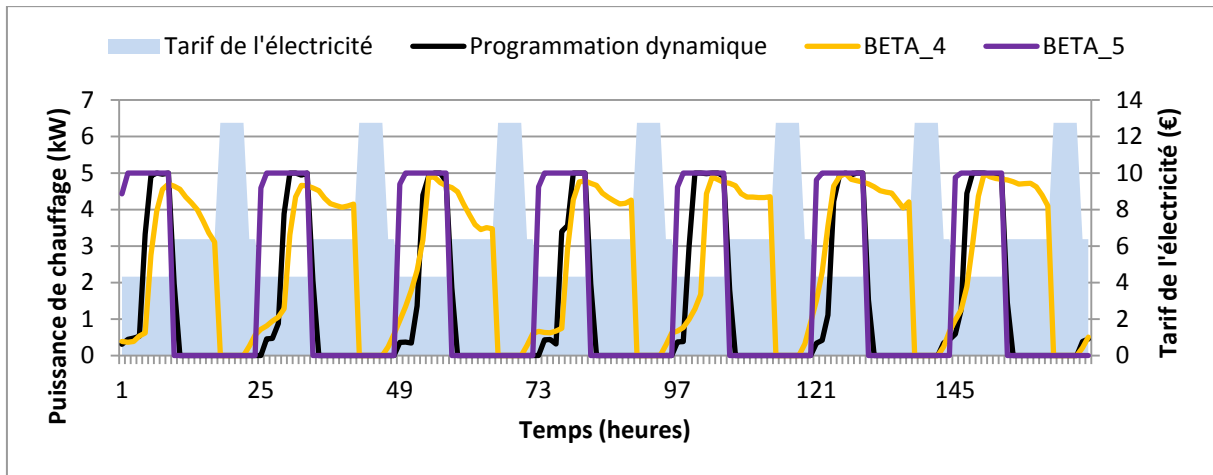


Figure 106 : Puissances de chauffage calculées par la programmation dynamique, BETA_4 et BETA_5 (troisième semaine)

2. AJOUT D'UN CONTRÔLEUR




Figure 107 : Puissances de chauffage calculées par la programmation dynamique, BETA_3 et BETA_3 + contrôleur (première semaine)




Figure 108 : Puissances de chauffage calculées par la programmation dynamique, BETA_3 et BETA_3 + contrôleur (deuxième semaine)

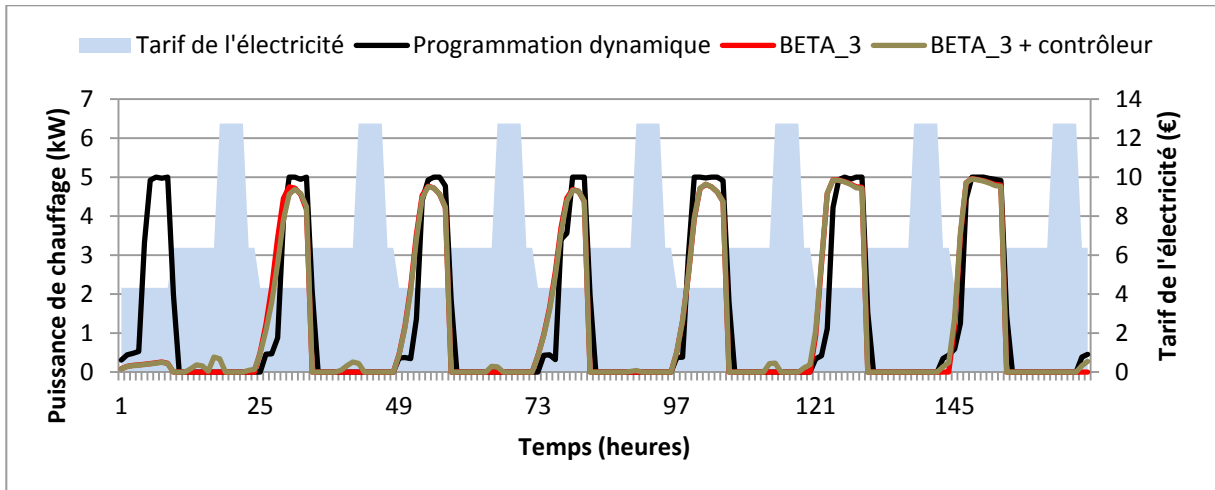


Figure 109 : Puissances de chauffage calculées par la programmation dynamique, BETA_3 et BETA_3 + contrôleur (troisième semaine)

3. COMPARAISON À UNE LOI PUREMENT HEURISTIQUE




Figure 110 : Puissances de chauffage calculées par la loi purement heuristique, la programmation dynamique, et BETA_3 + contrôleur (première semaine)




Figure 111 : Puissances de chauffage calculées par la loi purement heuristique, la programmation dynamique, et BETA_3 + contrôleur (deuxième semaine)




Figure 112 : Puissances de chauffage calculées par la loi purement heuristique, la programmation dynamique, et BETA_3 + contrôleur (troisième semaine)

4. INFLUENCE DE LA PRÉVISION DE LA MÉTÉOROLOGIE SUR LES LOIS HEURISTIQUES IDENTIFIÉES

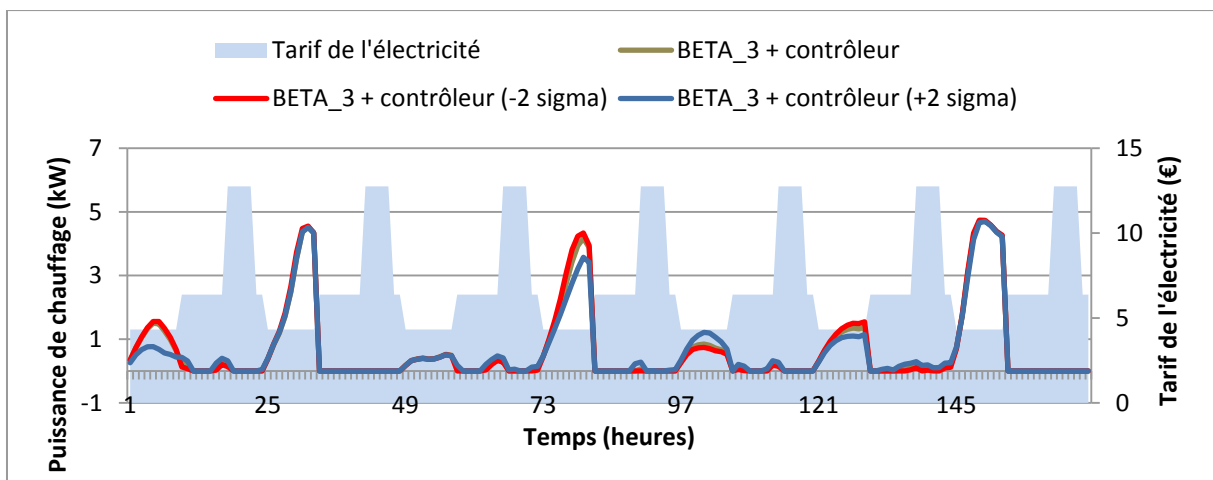


Figure 113 : Puissances de chauffage calculées par BETA_3 + contrôleur, BETA_3 + contrôleur (-2 sigma) et BETA_3 + contrôleur (+2 sigma) (deuxième semaine)




Figure 114 : Puissances de chauffage calculées par BETA_3 + contrôleur, BETA_3 + contrôleur (-2 sigma) et BETA_3 + contrôleur (+2 sigma) (troisième semaine)




Figure 115 : Puissances de chauffage calculées par BETA_3 + contrôleur, BETA_3 + contrôleur (-2 sigma) et BETA_3 + contrôleur (+2 sigma) (quatrième semaine)




Figure 116 : Températures de zone correspondant aux régulations calculées par les modèles BETA_3 + contrôleur, BETA_3 + contrôleur (-2 sigma) et BETA_3 + contrôleur (+2 sigma) (deuxième semaine)

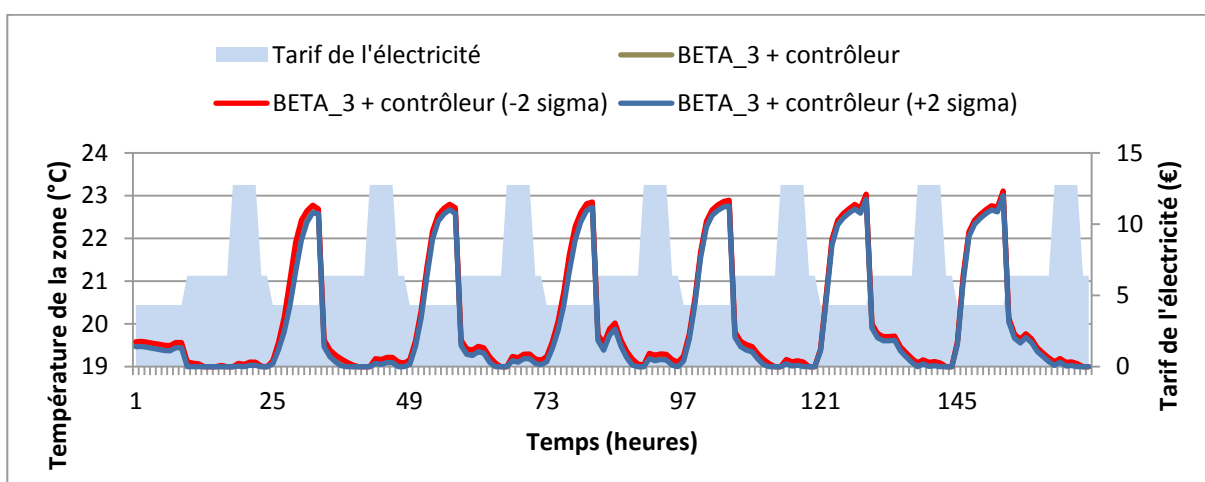


Figure 117 : Températures de zone correspondant aux régulations calculées par les modèles BETA_3 + contrôleur, BETA_3 + contrôleur (-2 sigma) et BETA_3 + contrôleur (+2 sigma) (troisième semaine)

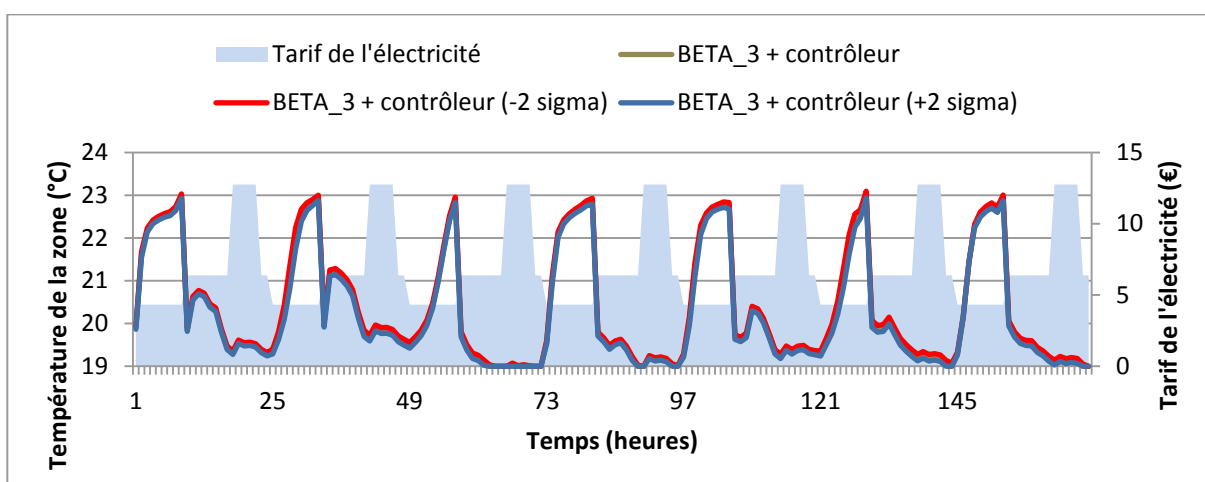


Figure 118 : Températures de zone correspondant aux régulations calculées par les modèles BETA_3 + contrôleur, BETA_3 + contrôleur (-2 sigma) et BETA_3 + contrôleur (+2 sigma) (quatrième semaine)

Étude de stratégies de gestion en temps réel pour des bâtiments énergétiquement performants

RÉSUMÉ : Dans l'objectif de réduire les consommations énergétiques des bâtiments et de diminuer leur impact sur le réseau électrique, il est utile de disposer de stratégies de gestion énergétique en temps réel. Il s'agit en effet d'un verrou clé dans la perspective des réseaux intelligents (« *smart grids* ») et des programmes de gestion de la demande (« *demand response* »). Cette thèse propose ainsi le développement de stratégies de gestion en temps réel du chauffage électrique d'un bâtiment énergétiquement performant en période de pointe électrique. Tout d'abord, ces stratégies nécessitent l'utilisation et le développement de plusieurs modèles, à savoir un modèle de prévision météorologique, un modèle d'occupation et un modèle énergétique dynamique du bâtiment. Ensuite, dans l'objectif d'un suivi fiable des performances énergétiques et pour un pilotage optimal des installations, le calibrage du modèle de bâtiment à partir de relevés *in situ* est préférable. Une nouvelle méthodologie, basée sur un criblage des paramètres incertains et sur l'utilisation d'une méthode d'inférence bayésienne (calcul bayésien approché) a ainsi été développée. Enfin, deux méthodes d'optimisation ont été étudiées pour le développement de stratégies de régulation adaptées au temps réel. La première repose sur une méthode d'optimisation hors-ligne dont l'objectif est d'approximer les résultats d'une stratégie optimale calculée par une méthode d'optimisation exacte et ainsi identifier des lois de commandes simplifiées. La deuxième méthode repose quant à elle sur la commande prédictive et l'adaptation au temps réel de la commande optimale sous contraintes d'état et de commande utilisant la pénalisation intérieure. Une maison de la plateforme INCAS de l'Institut National de l'Énergie Solaire (INES) a été utilisée comme cas d'application pour étudier par simulation les différentes stratégies développées.

Mots clés : Bâtiment, régulation, effacement, commande prédictive, lois heuristiques, calibrage bayésien.

Study of real time control strategies for energy efficient buildings

ABSTRACT : To reach the objectives of reducing the energy consumption of buildings and decreasing their impact on the electrical grid, it is necessary to elaborate real time control strategies in view of smart grids and demand response programs. In this context, this thesis aims at developing real time control strategies for electric load shifting in energy efficient buildings. First, these strategies require appropriate models regarding weather forecast, occupants' behaviour and building energy simulation. Then, in order to improve the reliability of building energy simulation and to ensure optimal control of facilities, a calibration process of the model based on on-site measurements is recommended. In this way a new methodology was developed, based on a screening technique and a bayesian inference method (approximate bayesian computation). Finally, two optimisation techniques were studied to develop real time control strategies. The first technique was based on offline optimisation methods. The principle is to approximate optimisation results (and more specifically model based predictive controllers results) and to extract simplified control strategies. The second method consisted in using model predictive control and, more precisely, in solving in real time a state and input constrained optimal control problem by interior penalty methods. An actual experimental passive house being part of the INCAS platform built by the National Solar Energy Institute (INES) was used to study by numerical simulation the different strategies developed.

Keywords : Building, control, load shifting, model predictive control, heuristic law, bayesian calibration.