UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES

APPRENTISSAGE AUTOMATIQUE POUR LA SOLUTION DES PROBLÈMES INVERSES DANS LA GESTION OPTIMALE DE LA DEMANDE D'ÉLECTRICITÉ EN MILIEU RÉSIDENTIEL

THÈSE PRÉSENTÉE
COMME EXIGENCE PARTIELLE DU
DOCTORAT EN GÉNIE ÉLECTRIQUE

PAR
MOUSSA IBRAHIM MOUMOUNI

JUILLET 2026

Université du Québec à Trois-Rivières

Service de la bibliothèque

Avertissement

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

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

UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES

Doctorat en génie électrique (Ph.D.)

Direction de recherche :

Prof. Kodjo Agbossou	Directeur de recherche
Prof. Roland P. Malhamé	Codirecteur de recherche

Jury d'évaluation

Prof. Kodjo Agbossou	Directeur de recherche
Prof. Frédéric Domingue	Président du jury
Prof. Messaoud Ahmed Ouameur	Membre interne
Prof. Lyne Woodward	Membre externe

Thèse soutenue le 28 avril 2026

Résumé

Dans une approche de réponse à la demande, les agents résidentiels doivent réaliser des tâches d'optimisation et d'apprentissage automatique. Ces tâches sont complexifiées lorsque l'agent automatisé ne peut pas contrôler de façon directe la puissance des charges flexibles (chauffages, véhicules électriques, chauffe-eau, batteries de stockage domestique). Par exemple, il peut changer la consigne d'un thermostat, mais il ne peut pas imposer la puissance des plinthes électriques. Il peut délester le chauffage (signal On-Off), mais il ne peut moduler la puissance des éléments chauffants. Dans ces circonstances, la relation entre le coût de l'énergie et la variable de décision n'est pas directe et est en principe inconnue. On sait intuitivement que diminuer la consigne d'un thermostat permet de consommer moins en chauffage , toutefois on ne sait pas avec certitude la reduction de puissance consommée résultante. Cette relation peut aussi être soumise à des dynamiques non linéaires et stochastiques qui doivent être comptabilisées (au moins en partie) afin d'assurer une certaine optimalité dans la décision. Deux objectifs sont normalement établis dans la formulation du problème d'optimisation : 1) maximiser le confort des occupants de la résidence , 2) minimiser le coût de l'énergie. Le premier objectif est introduit à l'aide d'une fonction d'utilité prenant différentes formes selon le type de charge à gérer. Par exemple, le confort thermique pour la gestion du chauffage, la satisfaction pour la recharge complète et rapide d'un véhicule électrique, ou bien la disponibilité d'eau chaude dans le réservoir. Le deuxième objectif entre en conflit avec le premier et consiste à réduire au maximum la facture à payer. En effet, moins l'agent consomme de l'énergie pour réduire sa facture, plus cela va nuire au confort thermique du client. À la lumière des points soulevés ci-haut, nous proposons au travers de ce projet d'introduire au niveau de l'agent résidentiel, un mécanisme d'inversion afin de générer les profils de décisions optimales lui permettant de satisfaire les deux objectifs conflictuels

cités ci-haut. Cela va consister dans un premier temps à établir un modèle direct entre la variable de décision et la consommation et ensuite l'introduire comme contrainte au niveau de la fonction objectif afin de produire les trajectoires des variables de décision. Pour le cas des plinthes électriques, la variable de décision sera le profil de température de consigne à appliquer sur le thermostat. Le deuxième volet consiste à mettre au point une technique de mise à jour en temps réel du modèle énergétique d'une résidence afin de garantir la traçabilité de sa dynamique thermique malgré les stochasticités introduites par le comportement des occupants et les changements météorologiques. Les deux étapes combinées ont pour rôle de permettre une meilleure prise de décision sous incertitudes et d'éviter une importante déviation par rapport au plan de consommation. Les contributions majeures de cette thèse sont au nombre de trois : (1) une méthode de recherche en espace réduit, pour l'identification des paramètres des thermostats communicants à tension secteur (paramètres uniques et modèle interprétable) ; (2) une technique d'estimation et de prédiction en ligne des charges résiduelles qui intégrée à un modèle thermo-thermostatique permet de prédire le potentiel de réponse à la demande d'une résidence ; (3) un algorithme de contrôle par optimisation inverse convertissant un profil de puissance cible en consignes applicables aux thermostats. Ces contributions ont été validées sur des données réelles.

Abstract

In a Demand Response context, residential agents must perform optimization and machine learning tasks. Those tasks become more complex when the automated agent cannot directly control the power of flexible loads (heating loads, electric vehicles, water heaters, home storage batteries). For example, it can adjust the setpoint of a thermostat, but it cannot impose the power of electric baseboards heater. It can switch heaters (with an on and off signal), but it cannot modulate the power of heating elements. In these circumstances, the relationship between energy cost and the decision variable is not direct and is essentially unknown. Intuitively, we know that lowering a thermostat's set-point temperature helps reduce heating load consumption; however, we are not certain about the amount of power consumption resulting. This relationship may also be subject to nonlinear and stochastic dynamics that need to be considered (at least partially) to ensure some optimality in the decision-making. Two objectives are typically established in the optimization problem formulation: 1) maximize the comfort of the residence occupants and 2) minimize the cost of energy. The first objective is introduced through a utility function that takes different forms depending on the type of load to be managed. For example, thermal comfort for heating management, satisfaction for the complete and rapid recharge of an electric vehicle, or the availability of hot water in the tank. The second objective conflicts with the first and aims to minimize the energy bill as much as possible. Indeed, the less energy the agent consumes to reduce its bill, the more this will compromise the thermal comfort of the customer. In light of the points raised above, we propose, through this project, to introduce an inverse mechanism at the residential agent level to generate optimal decision profiles that satisfy the two conflicting objectives mentioned above. This will involve, initially, establishing a forward model between the decision variable and consumption and then introducing it as a constraint

in the objective function to produce the trajectories of the decision variables. For electric baseboards, the decision variable will be the setpoint temperature profile to be applied to the thermostat. The second aspect involves developing a real-time update technique for the energy model of a residence to ensure the traceability of its thermal dynamics despite the stochasticity introduced by occupant behavior and weather changes. The combined two steps aim to enable better decision-making under uncertainties and avoid significant deviation from the consumption plan. The major contributions of this thesis are threefold : (1) a shrinked-space search method for identifying the parameters of line-voltage communicating thermostats (yielding a unique set of parameters and an interpretable model) ; (2) an online estimation and prediction technique for residual thermal loads, embedded in a thermo-thermostatic model that predicts a residence's demand-response potential ; and (3) an inverse-optimization-based control algorithm that converts a target power profile into setpoints applicable to the thermostats. These contributions were validated on real-world data.

Remerciements

Mes sincères remerciements à l'endroit de mon directeur de thèse, le professeur Kodjo Agbossou, qui a bien voulu m'accorder la chance de réaliser une thèse de doctorat. Mes remerciements vont également à mon codirecteur de thèse, le professeur Roland Malhamé. Leurs encadrements, soutiens scientifiques et conseils ont été d'une grande aide dans la conduite de mes recherches. Je saisis également cette occasion pour remercier le Dr Nilson Henao pour son suivi et ses contributions tout au long de ce travail de recherche.

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

C'est aussi pour moi l'occasion de remercier les organismes subventionnaires qui ont généreusement soutenu cette recherche : le LTE d'Hydro-Québec, le Conseil de recherches en sciences naturelles et en génie du Canada (CRSNG), l'Institut de recherche sur l'hydrogène (IRH) et la Fondation de l'UQTR.

Enfin, je tiens à exprimer ma profonde reconnaissance envers mes parents, ainsi que mes sœurs et mes frères, pour leur patience, leur soutien et leur amour ineffables. Mes amis au Canada et dans le monde entier ont été d'un soutien inestimable. Je tiens à leur adresser mes sincères remerciements.

Table des matières

Résumé iii

Remerciements vii

Table des matières viii

Liste des tableaux xii

Liste des figures xiii

Liste des symboles xv

Liste des acronymes xx

Chapitre 1 - Introduction 1

1.1 Contexte général 1

1.2 Eléments de la problématique 6

1.3 Objectifs de recherche 10

1.4 Contributions 11

1.5 Plan de la thèse 15

Chapitre 2 - Revue de littérature 16

2.1 Problèmes inverses dans la gestion de la demande d'électricité 16

2.2 Identification des paramètres d'un contrôleur PI 19

2.3 Identification des paramètres d'un modèle RC 23

2.4 Mesure (non intrusive) des charges thermiques 28

2.5 Optimisation inverse pour la génération des consignes 30

2.6 Positionnement scientifique et verrous de recherche 32
2.6.1 Verrous scientifiques identifiés 32
2.6.2 Positionnement des contributions de la thèse 33
2.7 Synthèse du chapitre 34

Chapitre 3 - Solutions des problèmes inverses et gestion efficace de la demande en chauffage 37
3.1 Introduction 37
3.1.1 Définition des concepts de base 39
3.1.2 Problèmes inverses : classification, méthodes de résolution et cas d'étude 42
3.1.3 Objectif scientifique du chapitre: 47
3.1.4 Méthodologie générale et objectifs: 47
3.1.5 Conditions de mise en œuvre: 49
3.2 Modélisation et identification des paramètres des thermostats préinstallés . 50
3.2.1 Modèle de référence 50
3.2.2 Méthode de recherche dans un espace réduit (*Shrinked-Space Search*, S-SS) 52
3.2.3 Suivi de la dynamique du terme intégrateur 64
3.3 Prédiction du potentiel de réponse à la demande 66
3.3.1 Modélisation et identification 69
3.3.1.1 Structure du modèle RC 70
3.3.1.2 Identification des paramètres du modèle et reconstitution des profils de charges résiduelles 73
3.3.2 Procédure de prédiction du potentiel de réponse à la demande 79

3.4 Algorithme de contrôle des charges de chauffage basé sur une optimisation inverse 88
3.4.1 Optimisation basée sur la simulation et optimisation inverse 91
3.4.2 Quantification du confort et de la flexibilité 94
3.4.3 L'algorithme de contrôle 97

Chapitre 4 - Évaluation des solutions aux problèmes inverses 108
4.1 Introduction 108
4.2 Acquisition des données 108
4.3 Validation de la méthode d'identification des paramètres des thermostats préinstallés 109
4.3.1 Performance de la méthode proposée 110
4.3.2 Étude de cas : implémentation d'un programme de DR 116
4.4 Validation de la méthode de prédiction du potentiel de réponse à la demande 118
4.4.1 Résultats d'identification et de réconstitution des GRLs pour la maison réelle 121
4.4.2 Résultats d'identification et de réconstitution des GRLs pour les maisons simulées 124
4.4.3 Résultats de la prédiction du potentiel de demande à la réponse pour la maison réelle 128
4.5 Validation de l'algorithme de contrôles des charges de chauffage basé sur une optimisation inverse 131

Chapitre 5 - Discussion, conclusion générale et recommandation 136
5.1 Discussion 136
5.1.1 Synthèse des travaux 136

5.1.2 Limites 138

5.2 Conclusion générale et recommandations 139

Liste des tableaux

Tableau 2-1 Synthèse comparative des approches d'identification des paramètres d'un contrôleur PI (thermostat). 22
Tableau 2-2 Synthèse comparative des approches d'identification d'un modèle thermique RC. 27
Tableau 2-3 Synthèse comparative des approches de mesure non intrusive des charges thermiques (NITLM). 29
Tableau 2-4 Matrice de positionnement : contributions de la thèse par rapport à la littérature. 34

Tableau 4-1 Concordance des paramètres utilisant la stratégie de suivi du terme intégrateur et leur écart par rapport à ceux identifiés par la méthode S-SS 115
Tableau 4-2 Performance dans la reconstruction des profils de demande de chauffage 115
Tableau 4-3 Résumé des résultats d'identification et de réconstitution des charges résiduelles pour la maison réelle 123
Tableau 4-4 Résultats d'identification et de reconstitution des profils de charges résiduelles pour les maisons simulées 127
Tableau 4-5 Variables de comparaison 128
Tableau 4-6 Résumé des résultats de la prédiction du potentiel de DR 129
Tableau 4-7 Résumé des résultats de contrôle 132

Liste des figures

Figure 1.1 Répartition de la consommation d'énergie, bâtiment résidentiel, Québec [1]. 4

Figure 1.2 illustration: causes, effets, phénomènes 9

Figure 3.1 Vue d'ensemble du pipeline méthodologique : de l'identification au contrôle. 47

Figure 3.2 Schéma illustratif de la méthodologie 48

Figure 3.3 Schéma-bloc de la structure PI. 51

Figure 3.4 Procédure de la méthode de recherche dans un espace réduit (S-SS). 54

Figure 3.5 Exploration de l'espace de recherche. 54

Figure 3.6 Illustration de la sortie du contrôleur. 56

Figure 3.7 Sortie désagrégée du régulateur. 65

Figure 3.8 Procédure d'identification. 73

Figure 3.9 Cadre d'implémentation d'un programme DR. 81

Figure 3.10 Cadre d'implémentation d'un programme DR. 98

Figure 4.1 Data acquisition architecture. 109

Figure 4.2 Variation persistante de la température intérieure. 110

Figure 4.3 Réduction de l'erreur d'estimation. 111

Figure 4.4 Comparaison entre le profil réel et le profil estimé. 112

Figure 4.5 Graphique de la différence d'espace de recherche. 112

Figure 4.6 DR avec modèles de thermostats établis. 117

Figure 4.7 Résultat du cadre de DR mis en œuvre. 118

Figure 4.8 Distribution des GR Loads 122

Figure 4.9 Puissance agrégée et température moyenne pour la maison réelle ... 124
Figure 4.10 Distribution des données des maisons simulées 125
Figure 4.11 Pourcentages moyens de similarité des matrices identifiées avec les matrices réelles 126
Figure 4.12 Qualité d'estimation de la température, des charges de chauffage et des charges résiduelles 127
Figure 4.13 Qualité d'estimation, consommation mesurée vs consommation de référence 130
Figure 4.14 Résultat du contrôle par ajustement du rapport cyclique 131
Figure 4.15 Coût énergétique 133
Figure 4.16 Reconstitution de la puissance optimale 133
Figure 4.17 Ratio de réduction d'énergie 134
Figure 4.18 Efficacité de confort 134

Liste des symboles

$\mathbb{I}_n, \mathbb{J}_n, \mathbb{M}_n$ Ensembles des indices au nœud n du réseau *RC*

$\mathbb{N}^*$ Ensemble des entiers naturels privés de 0

$\{\mathbb{N}^* \backslash n\}$ Ensemble des entiers naturels privés de 0 et n

$\mathbb{R}$ Ensemble des nombres réels

$\mathbb{R}^{(\blacksquare)}$ Ensemble de nombres réels de dimension $\blacksquare$

$\mathbb{C}_t$ Ensemble des contraintes à l'instant t

p_t Sortie du régulateur à l'instant t

p_{max} Seuil de saturation supérieur de la sortie du régulateur

p_{min} Seuil de saturation inférieur de la sortie du régulateur

I_t Terme intégrateur à l'instant t

I_{ss} Valeur de l'intégrateur en régime permanent

I_{0s} Valeur initiale de l'intégrateur aux instants post-saturation

I_{t_s} Valeur de l'intégrateur à l'instant t_s pour un indice de saturation s

$q_0(t_s)$ Valeur de biais pour un indice de saturation s

k_p Gain proportionnel

k_i Gain intégral

τ_i Temps de réinitialisation (aussi noté par τ_p)

ε Selon le contexte : bruit ou petite constante strictement positive ($0 < \varepsilon \ll 10^{-2}$) régularisant les métriques DR.

$(k_{p,\min}^{(l,j)}, k_{p,\max}^{(l,j)})$ Bornes supérieure et inférieure de l'intervalle de recherche associé au gain proportionnel (niveau d'evaluation l, indice de décalage j)

$(\tau_{i,\min}^{(l,j)}, \tau_{i,\max}^{(l,j)})$ Bornes supérieure et inférieure de l'intervalle de recherche associé au temps de réinitialisation de l'intégrateur (niveau d'evaluation l, indice de décalage j)

$(\tau_{p,\min}^{(l,j)}, \tau_{p,\max}^{(l,p)})$ apparait à la figure 3.4, même définition que $(\tau_{i,\min}^{(l,j)}, \tau_{i,\max}^{(l,j)})$

$K_{\min}^{(l)}$ **et** $K_{\max}^{(l)}$ Valeurs raisonnables minimale et maximale pour le gain proportionnel (niveau d'evaluation l)

$T_{\min}^{(l)}$ **et** $T_{\max}^{(l)}$ Valeurs raisonnables minimale et maximale pour le temps de réinitialisation (niveau d'evaluation l)

$\delta_p^{(l)}$ **et** $\delta_\tau^{(l)}$ Taux de décalage liés à l'intervalle de recherche du gain proportionnel et du temps de réinitialisation de l'intégrateur

$\theta^{(l,j)}$ Paramètres inconnus du régulateurs (niveau d'evaluation l, indice de décalage j)

$\tilde{\theta}_s^{(l,j)^*}$ Sous-vecteur d'un ensemble pseudo-optimal de paramètres (k_p, τ_i) (niveau d'evaluation l, indice de décalage j)

$X_s^{(l,*)}$ Vecteur bidimensionnel d'un ensemble pseudo-optimal de paramètres la $s^{\text{ème}}$ saturation

$Y^{(l,*)}$ Vecteur bidimensionnel d'un ensemble pseudo-optimal de paramètres pour la $l^{\text{ème}}$ évaluation

$\widehat{H}$ Matrice de lissage symétrique définie positive

T_n Température du noeud n

C_n Capacité thermique du noeud n

T_a Température ambiante

T_i Température du noeud i

$R_{a,n}$ Résistance thermique entre l'extérieur et le noeud n

$R_{i,n}$ Résistance thermique entre le noeud n et i

ϕ_j Flux thermique provenant du chauffage j

F_j Facteur de pondération pour le flux thermique du chauffage j

ϕ_m^r Flux thermique provenant de la charge résiduelle m

G_j Facteur de pondération pour le flux thermique de la charge résiduelle m

ϕ_n Flux thermique direct global au noeud n

ϕ_n^r Charge résiduelle global au noeud n

F_n Facteur de pondération associé à ϕ_n

G_n Facteur de pondération associé à ϕ_n^r

$x_t \in \mathbb{R}^{n_x \times 1}$ Vecteur d'état regroupant les températures nodales à l'instant t

$u_t \in \mathbb{R}^{n_u \times 1}$ Vecteur des entrées du système (maison)à l'instant t

$\bar{u} \in \mathbb{R}^{n_x \times 1}$ Vecteur des entrées liés au flux thermique direct global (GDHF) à l'instant t

$u_t^r \in \mathbb{R}^{n_x \times 1}$ Vecteur des entrées liés aux charges résiduelles globales (GRLs) à l'instant t

$\tilde{u}_t^r \in \mathbb{R}^{n_x \times 1}$ Valeur estimée du vecteur des entrées liés aux charges résiduelles globales (GRLs) à l'instant t

$\hat{u}_t^r \in \mathbb{R}^{n_x \times 1}$ Valeur prédite du vecteur des entrées liés aux charges résiduelles globales (GRLs) à l'instant t

$\hat{\mathbf{u}}_t^r = \hat{u}_{t-p:t-1}^r$ Élement contenant les p valeurs prédite du vecteur des charges résiduelles ($\hat{u}^r$) à l'instant t

$\bar{x}_t \in \mathbb{R}^{n_x \times 1}$ Vecteur d'état (système est exempt des effets des GRLs) à l'instant t

$y_t \in \mathbb{R}^{n_x \times 1}$ Vecteur d'état bruité mesuré à l'instant t

$\bar{y}_t \in \mathbb{R}^{n_x \times 1}$ Vecteur d'état bruité mesuré (système est exempt des effets des GRLs) à l'instant t

$\tilde{\bar{x}}_t \in \mathbb{R}^{n_x \times 1}$ Pseudo-vecteur d'état à l'instant t

$\xi_t \in \mathbb{R}^{n_x \times 1}$ Vecteur consignes de température à l'instant t

Vecteur consignes de température de référence à l'instant t

$D_t \in \mathbb{R}^{n_x \times 1}$ Vecteur des rapports cycliques à l'instant t

$D_{max} \in \mathbb{R}^{n_x \times 1}$ Vecteur des rapports cycliques maximaux

$D_{min} \in \mathbb{R}^{n_x \times 1}$ Vecteur des rapports cycliques minimaux

$\bar{\pi}_t \in \mathbb{R}^{1 \times n_x}$ Vecteur de prix à l'instant t

$\pi_t \in \mathbb{R}^{1 \times n_u}$ Vecteur de prix (lorsque charges résiduelles prises en compte) à l'instant t

R_t Consigne de température moyenne de référence à l'instant t

$\bar{Y}_t$ Température moyenne effective à l'instant t

$\bar{U}_t$ Demande de chauffage effective (agrégée) à l'instant t

$\bar{E}_t$ Erreur de régulation moyenne effective à l'instant t

γ_t Ratio de réduction d'énergie à l'instant t

η_t Efficacité en confort à l'instant t

N Horizon de prédiction

N_c Horizon de contrôle

φ Facteur de confort

$\pm\delta y$ Plage de tolérance de température

$\pm\Delta y$ Plage effective de tolérance de température

$\mathrm{diag}(\cdot)$ Opérateur diagonal

$\mathbf{EI}(\cdot)$ Fonction d'acquisition *Expected Improvement*

$E(\cdot)$ Espérance mathématique

$K(\cdot)$ Fonction noyau multivariée

$C_d(\cdot)$ Fonction des thermostats

$Concat(\cdot)$ Fonction concaténation de vecteurs

$f_d(\cdot)$ Fonction d'état

$h_d(\cdot)$ Fonction de mesure

$g_d(\cdot)$ Fonction d'estimation des charges résiduelles

$(\cdot)_t$ Indice de pas de temps discret

$(\cdot)_k$ indice pour étape de prédiction k

$\blacksquare^m$ Valeur $\blacksquare$ mesurée

$\blacksquare^p$ Valeur $\blacksquare$ potentielle

$\blacksquare^{ref}$ Valeur $\blacksquare$ de référence

$\hat{\blacksquare}$ Valeur $\blacksquare$ prédite

$n_{\blacksquare}$ Nombre d'élements du vecteur $\blacksquare$

Liste des acronymes

AI Intelligence Artificielle

AR AutoRégressif

BO Optimisation Bayésienne

BTM Derrière le compteur

CE Efficacité en Confort

CMA Moyenne mobile cumulée

DR Réponse à la demande

EKF Filtre de Kalman Étendu

ERR Ratio de Réduction d'Énergie

FTM Devant le compteur

GRLs Charges Résiduelles Globales

IEA Agence Internationale de l'Énergie

IdO Internet des Objets

LVCT Thermostat à tension de secteur

MAE Erreur absolue moyenne

MDE Maîtrise de la Demande en Énergie

MPC Commande prédictive

NA Non Applicable

NILM Mesure non intrusive

NITLM Mesure non intrusive de charge thermique

PID Proportionnel Intégral Dérivé

PI Proportionnel Intégral

PINNs Réseaux neuronaux informés par la physique

PMV Predicted Mean Vote

PWAS Système affine par morceaux

REI Réseau Électrique Intelligent

s.c Sous contrainte

S-SS Recherche dans un espace réduit

SWAS Système affine commuté

UKF Filtre de Kalman sans parfum

Chapitre 1 - Introduction

1.1 Contexte général

Face à l'urgence climatique et à la diminution des combustibles fossiles, l'efficacité énergétique apparaît comme un instrument nécessaire pour concilier développement économique, bien-être de la population et protection de l'environnement. En effet, l'efficacité énergétique permettra de réduire les coûts de production et de consommation, de soutenir l'essor et la compétitivité des industries ainsi que de réduire la dépendance énergétique vis-à-vis de l'extérieur. Par ailleurs, elle pourrait garantir l'accès à un système énergétique plus performant où le confort thermique et la qualité de vie seront améliorés. Mais également, contribuer à la réduction des inégalités liées à l'accès et au coût de l'énergie. Sur le plan environnemental, en contribuant à limiter l'utilisation des combustibles fossiles dans la production d'énergie, elle permettrait de réduire les émissions de gaz à effet de serre. Comme souligné dans un rapport de l'Agence Internationale de l'Énergie [1], près de 40% des réductions d'émissions nécessaires pour atteindre la neutralité carbone à l'horizon 2050 pourraient, en effet, provenir d'améliorations de l'efficacité énergétique. Cet état de fait a suscité, chez les décideurs mondiaux, un engagement soutenu vers une accélération de la transition énergétique. L'objectif étant de passer d'un système énergétique à dominante fossile vers un système dominé par des sources d'énergie propre (solaire, éolien, hydraulique, etc.) et qui intègre un mode de consommation plus intelligent. Outre les avantages relatifs à la préservation de l'environnement et à une meilleure gestion des ressources, la transition énergétique permet également de réduire la demande globale d'électricité. Ce qui a pour bénéfices d'alléger la pression sur les infrastructures électriques et de favoriser un report d'investissement quant à l'augmentation des capacités de production et de distribution de l'électricité. En effet, de façon traditionnelle et dans l'optique d'anticiper la demande croissante en électricité,

les opérateurs du réseau ont recours à une expansion de leurs actifs, c'est-à-dire des transformateurs, des lignes de distribution ou même de production [2]. Cette solution reste néanmoins coûteuse et peu efficace dès lors qu'il y a un risque de surdimensionnement du réseau électrique qui pourrait être évité avec une gestion plus efficace de la demande. C'est pourquoi, il a été introduit dans les années 1980 [3], le concept de Réseau électrique intelligent (REI) ou smart grid en anglais. Ce concept consiste à placer le client en tant que consommateur final d'électricité, comme acteur dans la gestion de la demande. Le REI favorise, grâce à l'intégration des nouvelles technologies, une communication bidirectionnelle entre les fournisseurs d'énergie et les consommateurs, permettant ainsi une participation active de ces derniers. Les clients sont donc incités à gérer leur consommation, en temps réel, dépendamment des conditions du réseau. Cette participation proactive des clients, en temps réel et en fonction des conditions du réseau, est appelée réponse à la demande ou *Demand Response* en anglais. Pour participer à un programme de DR (*Demand Response*), il est généralement requis un système de gestion locale de la demande ou système de maîtrise de la demande en énergie (MDE) côté consommateurs. Ce système de gestion locale a pour rôle de faciliter aux clients la modulation de leur consommation en réponse aux conditions du réseau, et cela en régulant la consommation des charges flexibles grâce à des contrôleurs intelligents [4]. Par exemple, dans le secteur résidentiel, les charges flexibles qui sont d'intérêt pour un système de MDE dans le cadre d'un réseau électrique intelligent (REI) sont essentiellement : les appareils électroménagers, la climatisation, le chauffe-eau électrique, les véhicules électriques et le chauffage électrique. Au Québec, en particulier, avec une consommation énergétique dédiée aux chauffages des locaux dans les bâtiments résidentiels qui s'élève à 59 % (voir figure 1.1 [1]) [2], à peu près 64,1% de cette consommation est attribuable au chauffage électrique en 2022. Cela représente une hausse de 18,2% de l'électrification des chauffages

1. Sources: Rapport État de l'énergie au Québec 2025 et Office de l'Efficacité Énergétique (OEÉ)

des locaux sur les 20 dernières années [5]. Ainsi, les besoins du confort thermique, particulièrement durant les périodes hivernales, placent le secteur résidentiel comme l'un des plus gros consommateurs d'électricité. Cette tendance risque de s'intensifier à l'avenir, notamment à cause de la croissance démographique et de l'électrification croissante des usages. Dans ce contexte, la stabilité du réseau électrique peut être mise à rude épreuve, avec un risque accru de congestion et d'interruptions de service, notamment lors des périodes de pointe. Les chauffages électriques représentent donc une opportunité pour l'intégration du mécanisme de réponse à la demande (*Demand Response*) au sein des résidences. Les consommateurs pourraient être incités à adapter leur consommation selon les signaux tarifaires ou les contraintes du réseau. Dans cette configuration, des mécanismes d'optimisation pour automatiser la prise de décisions côté consommateur sont en général nécessaires. La mise en place de ces mécanismes recèle de nombreux défis en termes de modélisation, d'estimation et de contrôle. Ces défis deviennent particulièrement complexes lorsqu'ils relèvent de problèmes de nature inverse. Il convient alors de développer des approches méthodologiques spécifiques, capables de traiter rigoureusement ce type de problématique.

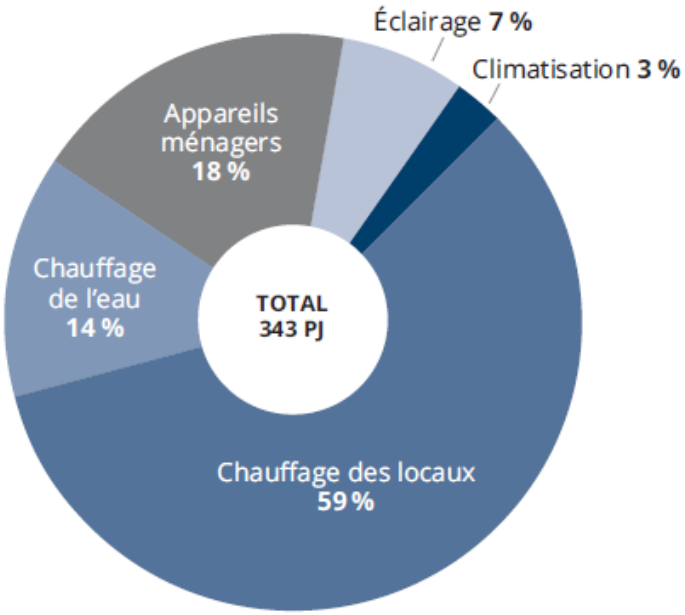


Figure 1.1 Répartition de la consommation d'énergie, bâtiment résidentiel, Québec [1].

Les techniques d'apprentissage automatique apparaissent comme des solutions privilégiées dans le processus d'automatisation de la prise de décision. Par exemple, les modèles d'apprentissage supervisés ou non supervisés pourraient être à même de prédire la demande énergétique des bâtiments en termes de chauffage. Cela peut être possible en utilisant diverses variables relatives aux conditions météorologiques, aux périodes d'occupation ou au prix de l'électricité. Ces modèles peuvent ainsi apprendre à minimiser progressivement les écarts entre la demande en chauffage prédite et réelle, permettant de ce fait une gestion plus éclairée de la consommation. Aussi, suivant une approche multiobjectifs qui consiste à réduire le coût énergétique et à assurer le confort des occupants, l'apprentissage par renforcement apparaît comme une solution potentielle. En effet, l'agent automatique peut apprendre, en interagissant avec un système de gestion thermique, à ajuster ses décisions sur la base des récompenses qu'il reçoit selon que les

actions prises ont amélioré la performance énergétique sans compromettre le confort.

Il existe dans la littérature différentes études mentionnant l'utilisation de l'apprentissage automatique pour une gestion efficace de la consommation énergétique. Par exemple, dans [6], une analyse de l'effet des erreurs de prévision sur la performance des systèmes de gestion de l'énergie a été menée. Les auteurs dans [7] et [8] ont conduit des études pour démontrer l'efficacité de l'apprentissage par renforcement profond (*Deep Reinforcement Learning*) dans le contrôle des charges de chauffage ou dans une meilleure coordination des bâtiments interagissant avec le réseau dans un contexte de réponse à la demande. Un algorithme de réponse à la demande et basé sur l'apprentissage automatique a été proposé par [9]. Il permet le contrôle de l'éclairage et des systèmes de climatisation dans les bâtiments. Les auteurs dans [10, 11] dressent une revue de littérature assez exhaustive sur les différentes techniques d'apprentissage automatique pour un système de gestion énergétique des bâtiments intelligents.

L'apprentissage automatique ou, de façon plus globale, l'intelligence artificielle permet d'introduire une dimension proactive et prédictive dans la gestion énergétique en général ou la gestion des charges de chauffage (ou de climatisation) en particulier. Elle se positionne donc comme un élément pouvant favoriser des prises de décision éclairées vis-à-vis de la gestion de la demande participant ainsi à l'équilibre du réseau électrique, tout en intégrant les contraintes de confort des usagers et les contraintes du réseau électrique.

Les récents progrès de l'Internet des Objets (IdO) et de l'apprentissage automatique en périphérie (*Edge AI*) participent à faciliter la gestion énergétique intelligente et réactive. Les dispositifs IdO assurent la collecte en temps réel de données sur la consommation et les conditions environnementales, et le *Edge AI* permet un traitement local et rapide de

ces informations. Cette combinaison pourrait réduire la latence et améliorer la réactivité des systèmes de contrôle des charges thermiques. Les bâtiments dotés de cette technologie seront capables d'ajuster automatiquement leur consommation énergétique en fonction des besoins et des conditions du réseau, tout en maintenant le confort des occupants. Ainsi, grâce à des dispositifs IdO, capteurs, thermostats connectés, nous proposons dans cette thèse l'implémentation d'une méthode permettant une gestion efficace des charges de chauffage en milieu résidentiel. Cette méthode a pour but de garantir la conversion d'une puissance optimale en termes de température de consigne (et/ou de rapport cyclique), d'offrir une prédictibilité de la consommation des usages ainsi que de la flexibilité au réseau.

1.2 Eléments de la problématique

Au Québec, l'utilisation des plinthes électriques comme éléments chauffants en période hivernale est assez répandue. On constate également une adaptation soutenue des thermostats intelligents pour le contrôle des chauffes d'espace. Ces thermostats intègrent des fonctionnalités avancées, comme la communication bidirectionnelle (et sans fil) qui permet le contrôle à distance et la collecte des données. Ces fonctionnalités peuvent être utilisées pour améliorer la gestion des charges de chauffage (ou de leur consommation) dans un contexte de réponse à la demande (*Demand Response ou DR*). L'inertie thermique dans un bâtiment représente une source de stockage thermique passif. Cette propriété peut être exploitée pour induire une consommation plus importante des plinthes électriques en période creuse (préchauffage). Ainsi, lorsque les chauffages seront délestés ou leur consommation réduite en période de pointe ou à la demande, on peut garantir un confort thermique acceptable tout en participant à la décongestion du réseau. La demande en chauffage au sein d'un bâtiment peut être influencée par plusieurs

facteurs : besoins du client (préférences thermiques), conditions climatiques, activités des occupants. La prise en compte de ces facteurs pour contrôler les chauffages peut aider à mieux exploiter l'inertie thermique du bâtiment à des fins de déplacement de charge. Un mécanisme automatisé pour l'optimisation des signaux de contrôle (consignes à appliquer aux thermostats) est dans ce cas nécessaire. En plus des facteurs susmentionnés, ce mécanisme doit tenir compte de la dynamique inhérente au fonctionnement des thermostats préinstallés. En effet, c'est eux qui modulent directement les puissances des chauffages sur la base des températures de consignes qu'ils reçoivent en entrée (et/ou en fonction du rapport cyclique maximal défini). Pour que le mécanisme de prise de décisions soit opérationnel, les éléments suivants sont donc requis :

- un modèle capable de reproduire le fonctionnement des thermostats ;
- un modèle énergétique et thermique du bâtiment ;
- un modèle qui permet de quantifier les charges thermiques liées aux activités des occupants et aux conditions climatiques (rayonnements solaires, par exemple) ;
- un algorithme d'optimisation pour la génération de consignes.

Un modèle capable de reproduire le fonctionnement des thermostats : il doit pouvoir capturer la logique de régulation utilisée par les thermostats. Le plus souvent, une régulation de type proportionnel intégral est employée. La sortie de ce type de régulateur est saturée à des valeurs maximales et minimales. Une stratégie *anti-windup* est également employée pour limiter l'emballement du terme intégrateur. La dynamique du système thermostat est donc non linéaire et est discontinue aux limites. Sa discontinuité aux limites implique que la troisième condition d'un problème dit bien posé (au sens de Hadamard [12]) n'est pas remplie. Il en résulte que la solution du problème n'est pas unique. L'identification des paramètres d'un tel système correspond à un problème inverse pour

lequel une technique de résolution appropriée doit être conçue.

Un modèle énergétique et thermique du bâtiment : il résulte du couplage entre le modèle des thermostats et d'un modèle thermique (modèle *RC* par exemple). La partie thermostatique prend comme entrée les températures de consigne et intérieures et calcule les puissances de chauffage requises. Ces dernières servent d'entrée pour la partie thermique qui modélise la dynamique thermique du bâtiment. Le modèle thermique tient compte des conditions climatiques, des échanges thermiques entre zones, mais surtout de l'inertie thermique des matériaux de construction. Il permet de suivre l'évolution des températures intérieures. Le modèle thermostatique assure, lui, le suivi de la consommation énergétique (ou en puissance) des chauffages. Retrouver les valeurs des paramètres *RC* peut être une tâche très complexe, surtout lorsque les données sont bruitées. Ce qui peut conduire à une non-unicité de solutions. Il s'agira de proposer une procédure d'identification dédiée qui soit robuste.

Un modèle qui permet de quantifier les charges thermiques : ce modèle consiste à estimer les valeurs des charges thermiques. Ces charges thermiques peuvent représenter aussi bien les gains que les pertes en chaleur. Les gains thermiques peuvent provenir : des équipements électriques thermogènes (cuisinière par exemple), de l'éclairage, de la chaleur dégagée par les humains, de l'ensoleillement. Les pertes de chaleur peuvent avoir pour cause, la conduction thermique des matériaux de construction, l'infiltration d'air, la ventilation, l'ouverture des portes/fenêtres, les ponts thermiques (liaison mur-toiture, contours des fenêtres, ossature métallique). Le modèle doit être capable d'estimer, sous forme de puissance, les causes de ces phénomènes (gains, pertes thermiques). Les systèmes qui produisent ces phénomènes sont irréversibles. L'estimation de leurs effets (charges résultantes) ne peut être effectuée que lorsque les phénomènes (pertes ou gains

thermiques) se produisent (illustration dans la figure 1.2). Par conséquent, estimer les charges thermiques correspond à un problème de reconstitution. Il s'agit donc d'un problème inverse.

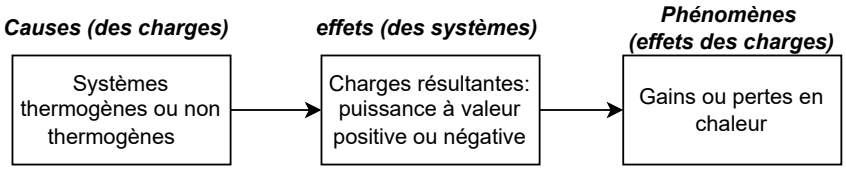


Figure 1.2 illustration: causes, effets, phénomènes

Un algorithme d'optimisation pour la génération des consignes : il consiste à déterminer les températures de consigne optimales (ou souvent du rapport cyclique maximal autorisé) en considérant dans son mécanisme les modèles précédemment établis. Il doit également tenir compte des contraintes de confort thermique et d'objectif énergétique : réduction de la consommation en puissance en période de pointe ou à la demande. On cherchera par exemple à reproduire un profil optimal qui satisfait aux contraintes de confort thermique et d'objectif énergétique en produisant les setpoints (en température) et/ou rapports cycliques qui permettront cette reconstitution. Il peut dans ce cas s'agir d'un problème d'optimisation inverse.

En sommes, l'identification des paramètres du modèle thermostatique et thermique, l'estimation des charges thermiques et la génération des consignes sont autant des problèmes inverses qui nécessitent de concevoir des techniques appropriées à leur résolution. Ce qui peut grandement contribuer à la mise en place d'un mécanisme de gestion optimale des charges de chauffage en milieu résidentiel. Les consommateurs résidentiels pourront ainsi participer de façon efficiente aux programmes de réponse à la demande.

1.3 Objectifs de recherche

Au regard des problématiques soulevées ci-dessus, nous nous assignons de proposer à travers cette thèse des solutions spécifiques à chacun des problèmes inverses susmentionnés. Les modèles et méthodes qui en résulteront seront unifiés dans un cadre qui permette l'implémentation effective d'un système de gestion efficace des charges de chauffage. Plus précisément, l'objectif principal de cette thèse est de concevoir un ensemble cohérent de méthodes de résolution de problèmes inverses, intégrées dans un cadre unifié, permettant la gestion efficace des charges de chauffage résidentielles dans un contexte de réponse à la demande, tout en préservant le confort des occupants. Cet objectif principal se décline en sous-objectifs opérationnels qui décrivent les briques méthodologiques à mettre en place :

a) Développer une méthode d'identification des paramètres des thermostats préinstallés au sein d'une résidence.
b) Concevoir une méthodologie d'identification des paramètres du modèle thermique de la résidence, de coupler le modèle thermique avec le modèle de thermostat pour établir un modèle thermo-thermostatique de la résidence.
c) Proposer une méthode d'estimation des charges thermiques (provoquant gains ou pertes en chaleur).
d) Utiliser le modèle thermo-thermostatique et la technique d'estimation des charges thermiques pour proposer un cadre de prédiction en ligne de la température et de la demande en chauffage. Et faire une évaluation en ligne du potentiel de participation de la résidence à un programme de réponse à la demande (*Demand response*).
e) S'appuyer sur la résultante des quatre objectifs précités pour proposer un algorithme de contrôle des charges de chauffage basé sur une optimisation inverse dans un

contexte de réponse à la demande.

Il convient de préciser que l'identification du modèle thermo-thermostatique constitue une étape nécessaire mais pas suffisante. En effet, bien que son utilité soit d'abord évaluée à travers sa capacité de prédiction, son objectif ultime est de fournir un modèle interne fiable pour le problème de contrôle. C'est donc la *contrôlabilité* qui en est la finalité : le modèle identifié est exploité au sein de l'algorithme de génération des consignes (cinquième sous-objectif), où la précision de prédiction conditionne directement la qualité du contrôle obtenu.

Étant donné que l'objectif d) dépend des objectifs a), b) et c), nous pouvons résumer les sous-objectifs précités en trois principaux objectifs: ces trois objectifs constituent les axes structurants de la thèse et correspondent respectivement aux trois principales contributions présentées à la section suivante.

1. Modélisation et identification des paramètres des thermostats préinstallés dans une résidence.
2. Prédiction du potentiel de réponse à la demande d'une résidence en s'appuyant sur une estimation et prédiction des charges thermiques résiduelles.
3. Implémentation d'un contrôle des charges de chauffage (d'une résidence) basé sur une optimisation inverse dans un contexte de réponse à la demande.

1.4 Contributions

Les principales contributions apportées à travers cette thèse se rapportent aux trois principaux objectifs cités ci-dessus. Ces contributions peuvent être résumées comme suit:

- Une méthode de recherche dans un espace réduit afin d'identifier les paramètres

d'ajustement des thermostats communicants à tension secteur (*Line voltage Communicating Thermostats*). L'approche proposée, basée sur un algorithme d'optimisation Bayésienne (BO), s'appuie sur un modèle de référence pour réduire drastiquement l'espace de recherche, tout en garantissant l'identification d'un ensemble unique de paramètres compatibles avec toutes les dynamiques du contrôleur, et en facilitant l'établissement d'un modèle interprétable. De plus, une stratégie de suivi du terme intégrateur a été adoptée par la suite afin de rendre convexe la fonction objectif (à des fins d'identification) tout en tenant compte des contraintes liées aux logiques qui régissent la dynamique du thermostat. Cela permet de reconstituer la logique de mise à jour du terme intégrateur présent dans le modèle du contrôleur (thermostat). Les résultats de validation expérimentale menée sur huit thermostats à tension de secteur et fonctionnant dans une maison habitée montrent l'efficacité de la méthode proposée, puisqu'elle conduit à l'établissement de jumeaux numériques pour les contrôleurs préinstallés. En outre, une étude de cas est présentée afin de démontrer l'utilité du modèle reconstruit dans un cadre de réponse à la demande (*Demand Response*). Cette première contribution (identification des paramètres des thermostats communicants à tension secteur) a fait l'objet d'une publication dans une revue évaluée par les pairs [13]. L'article est intitulé: "Shrinked-Space Search method for LVCT's parameters' identification".

- Une technique de prédiction d'état, en ligne, permettant de mettre à jour le statut thermique d'un bâtiment à partir de nouvelles mesures. Le modèle développé repose sur deux composantes principales. La première décrit le comportement thermique du bâtiment, à partir d'un modèle basé sur un réseau de type RC. La seconde composante repose sur un modèle autorégressif destiné à anticiper les comportements irréguliers liés aux gains et pertes de chaleur lors de l'occupation

et de l'utilisation du bâtiment. Les prédictions de ces phénomènes, désignés sous le terme de charges résiduelles (ou *sous-charges*), et directement associées aux comportements et activités des occupants, sont utilisées pour affiner les prédictions de l'état thermique du bâtiment. Une méthodologie est ainsi proposée afin d'extraire les profils de charges résiduelles et de construire leurs modèles de prédiction. Ces modèles sont ensuite ajustés dynamiquement, en temps réel, en fonction des nouvelles estimations des charges résiduelles. Cette approche permet de prendre en compte la variabilité temporelle des dynamiques thermiques et de minimiser les écarts observés entre les mesures et les prédictions de l'état du bâtiment ainsi que de la demande en chauffage. Par ailleurs, une heuristique est développée afin d'estimer le potentiel de réponse à la demande (*Demand Response*) du bâtiment. Celle-ci s'appuie sur la disponibilité des mises à jour en temps réel du modèle énergétique résidentiel (modèle thermo-thermostatique). Enfin, l'efficacité de la méthode proposée est évaluée à travers une étude de cas basée sur des données réelles issues d'un bâtiment résidentiel équipé de plinthes électriques. Cette seconde contribution a été documentée dans un article intitulé: "Two-stage Method for Grey-box Model Identification and Demand Response Potential Prediction Enabled by a Non-intrusive Thermal Loads Monitoring" [14].

- Un algorithme de contrôle exploitant la disponibilité d'estimations et de prédictions en temps réel des charges résiduelles (*sous-charges* thermiques), des états thermiques du bâtiment (températures) ainsi que des besoins de chauffage (puissance). Cet algorithme permet d'améliorer la gestion des charges de chauffage en fonction du signal de prix. La configuration proposée consiste en un contrôleur central recevant en entrée les informations relatives aux tarifs d'électricité ainsi qu'aux consignes de confort propres à chaque pièce du bâtiment. À partir de ces

informations, le contrôleur génère un plan optimal de consignes de température et/ou de rapport cyclique (duty cycle) à envoyer aux thermostats qui contrôlent les systèmes de chauffage. Afin de reproduire la dynamique thermique du bâtiment, le contrôleur intègre un modèle thermo-thermostatique non linéaire (combinant la modèle thermique et la modèle thermostatique). Les consignes optimales de température et/ou de rapport cyclique sont obtenues en résolvant un problème d'optimisation non linéaire visant à minimiser les coûts opérationnels associés aux systèmes de chauffage tout en garantissant le confort des occupants. Deux approches sont proposées pour la résolution de ce problème d'optimisation :

1. Une approche directe (*forward approach*), reposant sur l'optimisation par simulation, permet de déterminer directement les plannings optimaux de consignes à l'aide d'une fonction de coût dédiée. Cette fonction établit un compromis entre le coût de fonctionnement des systèmes de chauffage et le confort des occupants.
2. Une approche hiérarchique (*bilevel optimization*), dans laquelle une heuristique basée sur la modulation du rapport cyclique est d'abord utilisée pour identifier une trajectoire optimale de consommation électrique. Dans un second temps, une optimisation par simulation permet de déduire le planning des consignes de température et/ou de rapport cyclique correspondant à la trajectoire de consommation optimale prédéfinie. Cette méthode peut être qualifiée d'≪ approche inverse ≫.

Cette troisième contribution a été documentée dans un article intitulé: "Forward and inverse joint-optimization-based supervisory control of heating loads in demand response context" [15].

1.5 Plan de la thèse

La thèse est organisée comme suit : le chapitre 2 est dédié à une revue de littérature. Le **chapitre 3** présente les méthodologies relatives aux solutions des problèmes inverses et à la gestion éfficace des charges de chauffage. Le **chapitre 4** évalue et discute des résultats obtenus en testant les solutions proposées au **chapitre 3**. Enfin, le **chapitre 5** fait une synthèse des travaux, expose les limites des solutions proposées, propose une conclusion aux travaux menés dans la thèse et enfin énumère quelques recommandations..

Chapitre 2 - Revue de littérature

Le principal objectif de la présente thèse est de proposer des techniques, méthodes ou algorithmes permettant de résoudre les problèmes inverses que l'on peut rencontrer dans le cadre de la mise en place d'un système de gestion de la demande d'électricité en milieu résidentiel. Nous nous focalisons spécifiquement sur la gestion des charges de chauffage. Nous avons identifié quatre éléments qui sont essentiels à la mise en place d'un tel système. Ils se rapportent tous à des problèmes de type inverses pour lesquels des solutions spécifiques doivent être établies. Ces problèmes inverses concernent l'identification des paramètres du modèle des thermostats préinstallés au sein d'une résidence, l'identification des paramètres du modèle thermique d'une résidence, l'estimation des charges thermiques (liée aux activités des occupants, à l'ensoleillement, etc.) et enfin un algorithme de contrôle des charges de chauffage basé sur une optimisation inverse dans un contexte de réponse à la demande. Dans le présent chapitre, une revue de littérature est effectuée d'abord sur les problèmes inverses rencontrés dans le cadre de la gestion de la demande d'électricité en générale. Ensuite, une revue de littérature pour chacun des problèmes inverses se rapportant aux éléments énumérés ci-haut est proposée.

2.1 Problèmes inverses dans la gestion de la demande d'électricité

Dans le cadre de la gestion de la demande d'électricité, spécialement en Amérique du Nord, il existe des opérateurs chargés de la régulation du marché de l'électricité. Ils ont entre autres pour rôle de faire la planification de la production d'électricité en faisant concorder la demande avec l'offre pour des périodes futures (intrahoraire, jour, etc.) dans le respect des contraintes institutionnelles et règlementaires préétablies [16]. Dans ce cadre l'estimation des paramètres relatifs aux contraintes institutionnelles est formulée comme un problème d'optimisation inverse [17]. L'estimation de ces contraintes aura

pour bénéfice de guider les décisions des acteurs du marché et des politiques publiques pour une meilleure planification et un meilleur investissement en infrastructures. Par ailleurs, les centres de données, les bâtiments intelligents, les véhicules électriques sont des entités pouvant ajuster leur consommation suivant un signal de prix. Une estimation de leurs fonctions utilité est un exemple typique de problème inverse dans le cadre de la gestion de la demande d'électricité. L'estimation de la fonction utilité, relative au modèle de consommation des clients, permettra de générer des prédictions sur la demande d'électricités. Avec ces informations, de meilleures planifications, tarifications et offres peuvent être proposées [18–21].

Ces problèmes ont été abordés suivant plusieurs angles dans la littérature. Par exemple, les auteurs dans [22], proposent une approche d'optimisation inverse pour la reconstitution du prix marginal d'électricité proposé par les producteurs d'électricité sur le marché de l'énergie. Le processus sous-jacent d'équilibrage du marché a été exploité pour établir une relation explicite entre les paramètres inconnus et les résultats du processus qui sont disponibles publiquement. Pour solutionner le problème d'optimisation, une méthode de descente de gradient a été employée. Un processus de modélisation inverse des charges à l'échelle urbaine est proposé dans [23]. Le modèle établi est de type boite noire. Il permet, en faisant varier des paramètres (physiquement interprétables), de tester différents scénarios pour évaluer à l'avance l'impact d'un programme d'efficacité énergétique. Une méthode d'estimation des paramètres d'un problème d'optimisation latent a été proposée dans [24]. Elle se base uniquement sur la mesure de la demande nette au point de connexion du réseau pour estimer les paramètres et prédire les composantes non observables. Il permet donc de caractériser les profils de consommation de manière désagrégée sans effectuer une mesure directe derrière le compteur (mesure directe au niveau des appareils). Une étude permettant de reproduire les habitudes de consommation

des occupants suivant différents types de foyers a été proposé dans [25]. Elle s'appuie sur l'optimisation inverse et calibre le modèle énergétique à partir des données mesurées au niveau du compteur toutes les demi-heures. Une approche stochastique de simulation inverse et de théorie du chaos polynomiale a été investiguée par l'auteur dans [26] pour résoudre des problèmes inverses sous incertitudes dans le cadre de la conception d'un système énergétique. La reconstruction du modèle de décision des consommateurs via une optimisation inverse a été explorée dans [27]. Il se place dans le cadre d'un jeu de Stackelberg pour une réponse à la demande. Une approche inverse à partir d'un modèle physique de chauffe-eau est employée dans [28] pour déterminer le débit d'eau chaude à partir des informations sur la consommation d'électricité. Les informations sur le débit d'eau chaude sont utilisées pour simuler un contrôle intelligent du chauffe-eau. Un problème de prévision de la demande agrégée d'un groupe de consommateurs sensibles au prix a été abordé dans [19]. La détermination des paramètres du problème a été abordée sous l'angle d'une optimisation inverse. Dans [29], les auteurs ont proposé une méthode pour la résolution du problème inverse consistant à modéliser le comportement des occupants et le fonctionnement des équipements de chauffage et de climatisation. Ils utilisent les données du compteur à cette fin.

De ce qui précède, il ressort que les problèmes inverses dans la gestion de la demande d'électricité se retrouvent dans des applications tels que : l'inférence de la réponse aux prix des consommateurs, la désagrégation pour caractériser la consommation des charges (derrière le compteur) ou de leur contrôle, la caractérisation du comportement des occupants, la reconstitution des offres de prix sur les marchés de l'électricité. On pourrait entrevoir une catégorisation des problèmes inverses en problèmes inverses FTM (*Front of The Meter: devant le compteur*) et problèmes inverses BTM (*Behind The Meter: derrière le compteur*). Même s'ils sont intrinsèquement liés, les premiers sont ceux qui

sont susceptibles d'être gérés par les opérateurs du réseau et les seconds intéresseront les systèmes de gestion cotés consommateurs. La plupart des articles cités ci-dessus concernent les problèmes inverses de la première catégorie. Conformément à notre objectif de thèse, les problèmes inverses BTM sont ceux qui nous intéressent. Nous les avons déjà identifiés plus haut. Ainsi, une revue de littérature concernant chacun de ces problèmes est présentée ci-dessous.

2.2 Identification des paramètres d'un contrôleur PI

L'identification des paramètres des thermostats (ou contrôleurs) déjà opérationnels peut être très utile en pratique. Par exemple, pour la mise en place d'un jumeau numérique ou la conception d'un système de contrôle plus avancé, comme le MPC (*Model Predictive Control*). Ainsi, caractériser leur comportement en établissant ou en identifiant un modèle physiquement interprétable est une étape nécessaire. Une hypothèse raisonnable consiste à considérer une structure de régulateur PI pour l'identification, puisqu'il est connu comme étant la structure de commande la plus répandue dans l'industrie [30], en raison de sa simplicité et de sa capacité à atteindre le régime permanent même en présence de perturbations. Cependant, l'utilisation de ce type de régulateur dans des systèmes avec une limitation sur la valeur d'entrée, et sachant que nous pouvons être confrontés à des variations importantes de consigne, doit prendre en compte le phénomène indésirable appelé *integrator wind-up* (emballement de la partie intégrateur), qui provoque la saturation des actionneurs, une diminution des performances du système de commande, et parfois une instabilité dans la réponse en boucle fermée du système de commande [31]. Différentes stratégies *anti-windup* (”anti-emballement”) ont été proposées dans la littérature. Cependant, malgré leur diversité, on peut les classer en trois grandes catégories : (i) *conditional integration*: le PID est activé uniquement

lorsque l'entrée est inférieure à la valeur de saturation ; ainsi, le régime permanent peut être garanti. Sinon, l'action intégrateur est suspendue pour éviter la dégradation des performances. Dans ce cas, la valeur initiale de l'intégrateur peut être estimée à partir de la dernière valeur qu'il a atteinte en régime permanent [32]. (ii) méthode *tracking back-calculation*: génération d'un signal agissant sur l'entrée de l'intégrateur en utilisant la différence entre les entrées de commande saturée et non saturée [33]. (iii) *limited integrator*: limitation de la valeur de l'intégrateur en réinjectant la commande avec une zone morte à fort gain, garantissant le fonctionnement de la commande dans la zone linéaire [34]. Au regard des différentes stratégies *anti-windup*, on peut déduire que la dynamique du thermostat peut varier en fonction de l'occurrence des saturations. Cela est dû aux différentes conditions initiales de l'intégrateur qui vont affecter la dynamique du système dans les périodes post-saturation. De plus, comme le thermostat est un dispositif logique interagissant avec un système continu, sa dynamique peut être décrite comme celle des systèmes hybrides, dont le comportement dépend de l'interaction entre les dynamiques discrètes et continues. Cela implique qu'un comportement dynamique spécifique peut être attendu à différents intervalles de temps [35].

Pour identifier ce type de système, de nombreuses études ont utilisé l'identification des systèmes affines par morceaux (*Piecewise Affine System*, PWAS) ou des systèmes affines commutés (*Switched Affine System*, SWAS), en raison de leurs propriétés d'approximation universelle [36]. Dans la littérature, on retrouve différentes approches pour identifier les PWAS et SWAS, allant de l'approche *bounded-error* [37], à l'approche Bayésienne [38], l'approche algébrique [39], *mixed-integer programming* [40] et les techniques de *clustering* [41]. Dans [42], les auteurs ont identifié de nombreux paramètres/sous-systèmes pour un seul régulateur PI en utilisant des techniques de *clustering*. Le formalisme des modèles affines par morceaux (*Piecwise Affine model*, PWA

model) offre un outil puissant et flexible pour décrire des relations complexes et non linéaires entre entrées et sorties par un ensemble de *sous-modèles* affines simples, chacun associé à une région polyédrique du domaine des entrées [43].

Dans les systèmes dynamiques en boucle fermée, la prise en compte de la dynamique des régulateurs pour l'identification de ces systèmes est nécessaire [44] ; ce qui implique de retrouver les paramètres du modèle du régulateur. Les méthodes d'identification de systèmes en boucle fermée peuvent être classées en trois catégories : méthodes directes, méthodes conjointes entrée-sortie, et méthodes indirectes. Dans la première méthode, l'identification du modèle du système peut être réalisée sans tenir compte de l'effet du régulateur en boucle fermée [45]. Cependant, cela peut conduire à un modèle non cohérent puisque la structure exacte du modèle de bruit n'est pas garantie. Dans la méthode conjointe entrée-sortie, le régulateur et le système sont identifiés simultanément [46] ; néanmoins, la complexité de la dynamique du régulateur peut conduire à un échec de l'identification. Dans [47], les auteurs ont mentionné la robustesse des méthodes indirectes telles que la méthode *dual Youla*, en soulignant que la présence de délimiteurs, de fonctions anti-windup et d'autres non-linéarités pouvait mener à une estimation biaisée. À cet égard, le recouvrement (en boucle fermée) des paramètres du régulateur reste un sujet de recherche actif et difficile, avec des applications pratiques dans l'industrie pour l'évaluation de la commande optimale, comme le confirment certaines études récentes sur les régulateurs embarqués (principalement un régulateur PI) pour parvenir à une identification de systèmes en boucle fermée [48] [49]. En outre, le principal inconvénient de toutes les approches citées est que nous devons à la fois effectuer un partitionnement de l'espace pour assigner les zones dans lesquelles se trouvent différents *sous-modèles*, et déterminer tous les paramètres des *sous-systèmes* correspondants. Par conséquent, on peut se retrouver avec des modèles qui ne sont pas physiquement interprétables et un

très grand nombre de *sous-modèles* dès lors que ces approches ne sont pas conçues pour forcer l'identification d'un ensemble unique de paramètres compatibles avec toutes les dynamiques du système (ici le régulateur, contrôleur ou thermostat). Une synthèse comparative des méthodes évoquées ci-haut est présentée dans le tableau 2-1.

Tableau 2-1 Synthèse comparative des approches d'identification des paramètres d'un contrôleur PI (thermostat).

Référence	**Approche / type**	**Hypothèses et données**	**Avantages**	**Limites**	**Pertinence pour la thèse**
[37]	PWAS, *bounded-error*	Borne sur le bruit connue	Garanties théoriques	Partitionnement de l'espace, nombreux sous-modèles	–
[38]	PWAS bayésien	Information a priori sur les modes	Quantification de l'incertitude	Coût de calcul élevé	–
[40]	PWA, *mixed-integer*	Nombre de modes connu	Solution optimale	Complexité combinatoire	–
[41, 42]	*Clustering*	Choix du nombre de *clusters*	Flexible	Modèles peu interprétables, multiples sous-modèles	–
[48, 49]	Boucle fermée (sous-espace)	Structure du régulateur connue	Adapté aux régulateurs embarqués	Biais en présence d'*anti-windup* et de non-linéarités	–
Cette thèse [13]	Recherche en espace réduit (S-SS) + optimisation bayésienne + suivi de l'intégrateur	Modèle de référence PI avec *anti-windup*	Ensemble unique de paramètres, modèle interprétable, validé expérimentalement	Dépend de l'espace de recherche initial	Contribution principale (objectif 1)

2.3 Identification des paramètres d'un modèle RC

Les modèles utilisés pour traduire la dynamique thermique des bâtiments sont en général divisés en deux catégories : les modèles basés sur la physique et ceux basés sur les données [50]. Les premiers reposent sur une représentation détaillée de la physique du bâtiment, ce qui rend le processus d'identification de leurs paramètres gourmand en calcul [51]. En revanche, les seconds sont construits sur la base de statistiques ou de réseaux de neurones artificiels et sont connus pour être très demandants en termes de données d'entrainement [52]. Les modèles de type réseaux RC (Résistance Capacités) [53] établissent un compromis entre les modèles basés purement sur la physique, gourmands en temps de calcul, et les modèles purement mathématiques, moins interprétables. Ils permettent de décrire assez bien la thermodynamique des bâtiments. Ils ont trouvé des applications pour divers objectifs, notamment la conception d'un modèle de simulation pour l'automatisation du contrôle des bâtiments [54], le contrôle prédictif des ressources électriques et thermiques dans un bâtiment intelligent [55], la répartition synergique source-charge-stockage pour un système de gestion énergétique basé sur la tarification TOU (Time-Of-Use, TOU) [56], ou encore une optimisation énergétique pour la gestion interactive des bâtiments résidentiels grâce à un modèle thermique hybride intégré [57].

L'établissement des modèles de type réseau RC implique l'identification de leurs paramètres au moyen de méthodes telles que l'étalonnage des paramètres à partir de données de mesure. Cet étalonnage, considéré comme un problème inverse [58], peut être abordé par des méthodes manuelles, des techniques basées sur l'optimisation [59, 60], ou des algorithmes de filtrage stochastique [61]. Cependant, la plupart des études existantes se concentrent sur l'étalonnage hors ligne, rendant ainsi le modèle calibré obsolète en

raison de l'évolution temporelle des données disponibles et des incertitudes liées à des facteurs tels que le comportement des occupants, les conditions météorologiques et les modifications du bâtiment.

Pour apporter une solution aux limites de l'étalonnage hors ligne, diverses techniques d'estimation en ligne, telles que la minimisation récursive de l'erreur, les moindres carrés récursifs, le filtre de Kalman linéaire, le filtre de Kalman étendu (*Extended Kalman Filter*, EKF), le filtre de Kalman *sans parfum* (*Unscented Kalman filter*, UKF), ou encore le filtre particulaire (*particle filter*), ont été développées. Par exemple, les auteurs dans, [61] ont développé une prédiction séquentielle des états et une estimation des paramètres en utilisant un filtre de Kalman, afin de suivre l'évolution de l'état thermique d'un bâtiment. Mazar et Rezaeizadeh [62] ont proposé un contrôleur de température adaptatif pour des bâtiments en utilisant une identification des paramètres en ligne via un filtre de Kalman *sans parfum* (UKF). De même, l'UKF a été utilisé pour l'estimation en ligne des paramètres des modèles RC en présence d'incertitudes dues aux activités des usagers, à l'état de la construction, et aux conditions météorologiques [50]. Dans [63], une analyse de la dynamique thermique en temps réel d'une maison familiale a été rendue possible grâce à l'utilisation d'un UKF pour estimer conjointement les états et paramètres du modèle RC de la maison . Les auteurs ont également utilisé un *fading memory Kalman filter* pour réduire le nombre de capteurs requis sans affecter la précision de l'analyse. Les auteurs de [52] ont mis en œuvre une estimation en temps réel du potentiel de DR (*Demand Response*) des bâtiments et des états du réseau électrique via un filtre de Kalman étendu itératif (EKF).

Bien que les filtres de Kalman et leurs différentes variantes se soient révélés prometteurs pour l'estimation en ligne des paramètres des modèles RC, certaines

préoccupations subsistent concernant les hypothèses faites sur la prise en compte de charges supplémentaires (dues à l'activité des occupants ou à d'autres processus aléatoires) contribuant aux variations de la thermodynamique des bâtiments. La plupart des études citées ci-dessus ont considéré ces charges comme du bruit blanc gaussien, ce qui n'est pas nécessairement le cas. Des travaux récents ont introduit des modèles thermiques basés sur des réseaux de neurones informés par la physique (Physics-Informed Neural Networks, PiNN), combinant les approches « grey-box » et « black-box » pour contourner ce problème. Comme indiqué dans [64], la partie « grey-box » du modèle, représentée par un réseau RC classique, agit comme un biais inductif pour aider les réseaux de neurones à n'accommoder que la partie non linéaire de la dynamique du système. Par exemple, dans [65], les auteurs ont proposé une approche de modélisation pour la prédiction de la température dans des maisons à deux étages. La prédiction de la température moyenne du bâtiment a été réalisée grâce à un modèle RC, tandis que diverses méthodes d'apprentissage automatique, dont ANN (réseau de neurones artificiels), SVR (régression à vecteurs de support), RF (forêts aléatoires), GBM (Gradient Boosting Machines), XGBoost (eXtreme Gradient Boosting), et LightGBM (Light Gradient-Boosting Machine), ont été utilisées pour prédire la différence de température entre l'étage inférieur et supérieur. Gargya Gokhale et ses coauteurs [66] ont construit un modèle de réseaux de neurones guidé par la physique du bâtiment afin de capturer l'évolution temporelle de la température des pièces et de la consommation énergétique. Dans [67], Di Natale et ses coauteurs ont étendu leurs travaux menés dans [64] aux modèles thermiques multi-zones, en proposant des réseaux de neurones physiquement interprétable capables de capturer l'évolution de la température avec des zones thermiques interconnectées.

En résumé, malgré l'interprétabilité [68] et les capacités de généralisation des modèles

basés purement sur la physique [69], leur coût computationnel élevé et leur difficulté à être étalonnés les rendent inadaptés. Par ailleurs, les modèles « black-box » sont plus faciles à utiliser, ne nécessitent pas l'intervention d'un expert, et restent flexibles et transférables. Cependant, ils sont peu généralisables, exigent de grandes quantités de données, et sont sensibles au choix des variables [70]. Ces constats ont favorisé l'émergence de modèles hybrides, catégorisés en modèles « grey-box » et en modèles de réseaux de neurones informés par la physique. Les premiers combinent la physique (modèle type réseau RC) avec les données existantes. Les seconds reposent sur une combinaison d'un réseau RC et de réseaux de neurones. Tous deux requièrent moins d'intervention par un expert, moins de temps que les modèles purement physiques, et moins de données que les modèles « black-box » [71]. Sur le plan des besoins en données, là où un modèle « black-box » pourrait requérir typiquement plusieurs mois de mesures à haute résolution pour bien généraliser, une approche hybride « grey-box » pourrait être calibrée à partir de quelques semaines de données. La quantification précise de l'écart de réduction sur le jeu de données considéré pourra être effectuée selon le problème traité. Toutefois, un modèle PiNN surpasse un modèle RC pur, ce dernier pouvant être sensible aux données et incapable de capturer les non-linéarités [72]. Il a été constaté que, malgré sa capacité à tenir compte de la physique, le modèle PiNN peut souffrir de problèmes de généralisation, d'interprétation, de surcharge computationnelle et peux ne pas toujours réussir à accommoder toutes les non-linéarités, comme mentionné dans [67]. Nous avons à travers le tableau 2-2 présenté une comparaison entre les différente approche de modélisation abordé dans la littérature. Il importe enfin de souligner un point peu abordé dans la littérature et pourtant essentiel : l'identification des paramètres du thermostat (section précédente) et celle du modèle thermique du bâtiment sont presque toujours traitées séparément. Or, dans un logement réel, le thermostat module directement

la puissance de chauffage qui alimente la dynamique thermique ; le *couplage* entre la composante thermostatique et la composante thermique est donc indissociable dès lors que l'on vise une régulation avancée de la température (p. ex. un contrôle prédictif). C'est précisément ce couplage, formalisé sous la forme d'un modèle *thermo-thermostatique*, qui est exploité dans la présente thèse.

Tableau 2-2 Synthèse comparative des approches d'identification d'un modèle thermique RC.

Référence	**Approche / type**	**Hypothèses et données**	**Avantages**	**Limites**	**Pertinence pour la thèse**
[51]	Modèle physique détaillé	Géométrie et matériaux connus	Interprétable, généralisable	Coût de calcul, calibration difficile	–
[70]	*Black-box* (apprentissage automatique)	Grandes quantités de données	Flexible, sans expertise préalable	Peu généralisable, sensible aux variables	–
[53]	*Grey-box* (réseau RC)	Structure RC + données de mesure	Bon compromis interprétabilité / précision	Sensible au bruit, non-linéarités limitées	Modèle de base retenu
[52, 61, 63]	RC + filtre de Kalman (UKF/EKF) en ligne	Charges additionnelles assimilées à un bruit blanc gaussien	Estimation en ligne des états et paramètres	Hypothèse de bruit blanc souvent irréaliste	–
[64, 66, 67]	PiNN (hybride RC + réseaux de neurones)	Données + biais inductif physique	Capture des non-linéarités	Généralisation limitée, interprétation souvent difficile, coût de calcul élevé	–
Cette thèse [14]	RC + modèle autorégressif des charges résiduelles	Séparation chauffage / charges résiduelles	Capture les non-linéarités via les sous-charges, mise à jour en ligne	Modèle de sous-charges simplifié	Contribution principale (objectif 2)

2.4 Mesure (non intrusive) des charges thermiques

Au regard des insuffisances mentionnées dans la précédente section (2.3), pour prendre en compte presque toutes les non-linéarités, il pourrait être avantageux d'examiner les *sous-charges* (positives et négatives) susceptibles d'affecter la dynamique thermique d'une maison. Elles peuvent être mesurées directement ou estimées à partir des données disponibles. Le *monitoring* des *sous-charges* par mesure directe nécessite l'installation de capteurs, ce qui est moins pratique et beaucoup plus coûteux, en plus des problèmes de confidentialité qui en découlent. Pour pallier ces limitations, les chercheurs ont proposé le *Non-Intrusive Thermal Load Monitoring* (NITLM) afin de mesurer les *sous-charges* générées par chaque source de chaleur, qu'il s'agisse d'équipements, du rayonnement solaire, des occupants, etc. Par exemple, les auteurs dans [73] ont développé une technique de NITLM basée sur l'apprentissage automatique (*Random Forest*) en désagrégeant la charge thermique totale pour estimer les *sous-charges*. L'auteur dans [74] a étendu ce travail en intégrant la possibilité de prévoir les *sous-charges* futures grâce au *Non-Intrusive Thermal Load Disaggregation and Forecasting* (NITLDF). La prévision des *sous-charges* permettra aux systèmes CVC (Chauffage, Climatisation, Ventilation) de planifier leurs opérations en tenant compte des propriétés thermiques futures des pièces. Même si les études précédentes sur le NITLM ont atteint une précision intéressante, leur forte sensibilité aux variables d'entrée et aux hyperparamètres les rend moins adaptés. Comme mentionné par l'auteur de [75], une approche de modélisation basée sur la physique pourrait constituer une solution potentielle pour surmonter ces limitations. Ainsi, une procédure de modélisation simple pourrait être proposée pour capturer la dynamique des *sous-charges*. Les modèles établis serviront de substituts virtuels aux capteurs physiques.

Une analyse de l'état de l'art (NITLM): au-delà de l'énumération des techniques

existantes, deux lacunes méritent d'être soulignées. Premièrement, les méthodes NITLM basées sur l'apprentissage automatique offrent une bonne précision mais restent fortement dépendantes des hyperparamètres et des variables d'entrée, ce qui limite leur transférabilité d'un logement à l'autre. Deuxièmement, et surtout, ces approches se concentrent sur les sous-charges *positives* (gains de chaleur) et ne traitent pas explicitement les sous-charges *négatives* (pertes), pourtant déterminantes pour la dynamique thermique hivernale en milieu résidentiel. Ces deux verrous motivent l'approche physique proposée dans cette thèse. Le tableau 2-3 présente une analyse comparative des différentes techniques existantes.

Tableau 2-3 Synthèse comparative des approches de mesure non intrusive des charges thermiques (NITLM).

Référence	**Approche / type**	**Hypothèses et données**	**Avantages**	**Limites**	**Pertinence pour la thèse**
[73]	NITLM (*Random Forest*, apprentissage automatique)	Données d'entraînement	Désagrégation des sous-charges	Sensible aux hyperparamètres et aux variables d'entrée	–
[74]	NITLDF (désagrégation + prévision)	Historique des charges	Prévision des sous-charges futures	Mêmes limites ; charges positives uniquement	–
[75]	Approche basée sur la physique	Modèle physique	Robuste, nécessite peu de données	À valider expérimentalement	Piste retenue
Cette thèse [14]	Modèle physique des charges résiduelles (positives *et* négatives)	Modèle RC + modèle de correction	Substitut virtuel de capteurs, mise à jour en temps réel	Hypothèse de stabilité des charges résiduelles	Contribution (objectif 2)

2.5 Optimisation inverse pour la génération des consignes

Contrairement aux bâtiments commerciaux et institutionnels, le potentiel de mise en œuvre de la réponse à la demande dans les bâtiments résidentiels n'a pas été suffisamment exploré. Les auteurs de [76] ont attribué ce fait à deux principaux facteurs : une faible réduction de puissance attendue par logement, et l'absence d'une infrastructure de communication et de contrôle adéquate. À cela s'ajoutent le manque d'un algorithme de contrôle dédié et efficace ainsi que l'absence d'un modèle d'affaires approprié pour inciter les clients à participer au programme de Réponse à la demande (*Demand Response*, DR) [77].

En ce qui concerne l'infrastructure de communication, l'adoption croissante des thermostats intelligents et de certaines technologies de l'information facilite l'échange d'informations entre les fournisseurs et les clients [78]. Obtenir la réduction de puissance attendue pourrait dépendre de la volonté des clients résidentiels à participer au programme de DR. Leur réticence provient souvent d'un manque d'information concernant le niveau d'inconfort auquel ils seront exposés [79]. Ainsi, concevoir une stratégie de DR qui priorise le confort des occupants tout en exploitant la flexibilité de la charge et en permettant une réduction du coût de l'électricité devient essentiel. En fait, une stratégie centrée sur l'occupant a plus de chances d'être adoptée par de nombreux clients [76]. Cela est d'autant plus important que le taux de participation est crucial pour caractériser le modèle d'affaire dédié au programme de DR pour le résidentiel [80].

Un certain nombre d'études proposant un contrôleur DR qui équilibre le coût de l'électricité et le confort des usagers peut être trouvé dans la littérature [81–84]. Cependant, comme mentionné dans [76], une analyse approfondie de leurs performances sous des contraintes liées aux limitations en termes de communication et de contrôle

dans des systèmes physiques réels est nécessaire. Dans ce sens, les auteurs ont testé physiquement une approche qui utilise un rapport cyclique adaptatif pour maintenir la température intérieure dans une plage prédéfinie choisie par l'occupant. Ils ont démontré que cette stratégie assurait un confort thermique tout en réduisant la demande aux heures de pointe. Bien que l'approche semble attrayante, on peut noter quelques limites: a) Même en suivant une règle cohérente, la stratégie ne parvient pas à faire correspondre efficacement la plage de confort avec la réduction de puissance potentielle pouvant être fournie, en particulier dans un environnement soumis à des événements fortement stochastiques. b) La dynamique du thermostat n'est pas considérée de manière exhaustive pour prédire la puissance qu'il peut fournir en fonction des conditions environnementales. c) La configuration n'est pas conçue pour fournir une quantification de la flexibilité à l'agrégateur ; elle se contente plutôt de répondre à un signal externe (demande de réduction, tarification selon l'heure d'utilisation).

Une étude antérieure dans [85] a abordé certains de ces inconvénients en proposant une méthode d'optimisation inverse visant à faire correspondre les spécifications de confort des clients à une puissance et à un potentiel de flexibilité. La méthode consiste en un modèle de simulation inverse qui convertit une température intérieure souhaitée en puissance thermique requise pour l'atteindre. Elle utilise également une approche MPC pour rendre la stratégie robuste face à l'incertitude. Néanmoins, comme la seule source d'incertitude considérée est celle liée à la météo, cela peut créer un écart entre la consommation réelle révélée et celle proposée à l'agrégateur. De plus, le fait de générer plusieurs profils de puissance réalisables à envoyer à l'agrégateur accroît de son côté la complexité de calcul dans l'optimisation de la fonction objectif du système (ici constitué par un ensemble des maisons participant à un programme DR).

En somme, le but de l'optimisation inverse pour la génération des consignes est de déterminer les décisions (consignes) en température (et/ou limite maximale du rapport cyclique) qui permettent de reproduire plus ou moins fidèlement un plan de consommation optimale préétablie (découlant possiblement d'un processus d'optimisation indépendant ou d'une heuristique).

Vers l'optimisation inverse sous incertitude: Les méthodes d'optimisation inverse présentées ci-dessus se placent essentiellement dans un cadre *déterministe*. Or, le comportement des occupants et les conditions météorologiques introduisent une forte stochasticité qui peut creuser un écart entre la consommation réellement révélée et celle annoncée à l'agrégateur. Une branche plus récente de la littérature aborde l'optimisation inverse *sous incertitude* : simulation inverse stochastique et chaos polynomial [26], optimisation inverse robuste / par échantillonnage [86], et caractérisation de la flexibilité par optimisation inverse pilotée par les données [87]. Ces travaux restent toutefois rarement appliqués au contrôle résidentiel temps réel des charges de chauffage, ce qui constitue l'un des angles explorés dans cette thèse.

2.6 Positionnement scientifique et verrous de recherche

La revue présentée ci-dessus décrit l'état de l'art relatif à chacun des problèmes inverses considérés. Au-delà de cette description, il est nécessaire d'en dégager une lecture critique et de positionner explicitement les contributions de la thèse, ce qui fait l'objet de la présente section.

2.6.1 Verrous scientifiques identifiés

La synthèse de la littérature fait ressortir plusieurs verrous (*research gaps*) que cette thèse cherche à lever :

- l'absence d'une procedure d'identification de l'enveloppe du bâtiment intégrant le modèle de thermostat, ces deux entités étant traités séparément ;
- l'absence d'une estimation réaliste des charges liées aux occupants et intégrant aussi bien les gains que les pertes thermiques internes ;
- l'hypothèse de bruit blanc, souvent irréaliste, retenue pour représenter les charges résiduelles ;
- le manque de modèles réellement compatibles avec un contexte de réponse à la demande (DR) résidentiel et opérationnel ;
- l'absence de quantification de la flexibilité effectivement exploitable par un agrégateur.

2.6.2 Positionnement des contributions de la thèse

La littérature existante traite séparément (i) l'identification des modèles RC, (ii) l'estimation des charges thermiques et (iii) la réponse à la demande résidentielle, mais rarement leur intégration dans un cadre inverse unifié de type thermo-thermostatique. C'est précisément cette intégration méthodologique qui constitue le fil conducteur de la thèse. Le tableau 2-4 récapitule, problème par problème, l'apport de la thèse au regard des limites de l'état de l'art.

Tableau 2-4 Matrice de positionnement : contributions de la thèse par rapport à la littérature.

Problème inverse	**Littérature dominante**	**Limites principales**	**Contribution de la thèse**
Identification du thermostat (contrôleur PI)	PWAS/SWAS, *clustering*	Modèles non interprétables, multiples sous-modèles	Modèle PI; ensemble unique de paramètres interprétables [13]
Modèle thermique du bâtiment	RC + filtre de Kalman (EKF/UKF)	Hypothèse de bruit blanc	Estimation robuste via la prise en compte explicite des charges résiduelles [14]
Estimation des charges thermiques	NITLM (apprentissage automatique)	Dépendance aux hyperparamètres ; sous-charges négatives souvent ignorées	Modèle physique simplifié couvrant les sous-charges positives et négatives [14]
Génération des consignes (DR)	MPC / approches directes	Applicabilité limitée en contexte résidentiel réel	Optimisation inverse centrée sur l'occupant et compatible avec la DR [15]

2.7 Synthèse du chapitre

La revue de littérature ci-dessus présentée traite des éléments de la problématique. La résolution des problèmes inverses qui y sont rattachés est *sine qua non* à la mise en place d'un système de gestion efficace des charges de chauffage. Il est évident qu'il persiste des manquements quant aux méthodes existantes dédiées à la résolution des problèmes inverses évoqués ci-haut. Par exemple, pour l'identification des paramètres d'un contrôleur PI, il ressort que la proposition d'une méthode capable d'établir un modèle physiquement interprétable reste nécessaire. Dans la partie dédiée à l'identification

de paramètres d'un modèle RC, différentes méthodes pour établir le modèle thermique d'un bâtiment ont été évoquées. La méthode hybride qui combine le modèle RC et des réseaux neuronaux semble sortir du lot, surtout qu'elle permet de tenir compte des dynamiques non linéaires. Cependant, il a été révélé qu'elle pouvait souffrir de problèmes de généralisation, d'interprétation, de surcharge computationnelle et peut ne pas toujours réussir à accommoder toutes les non-linéarités. Une alternative serait de considérer les *sous-charges* thermiques (positive et négative) afin d'accommoder presque toutes les non-linéarités. La considération de ces *sous-charges* passe par la mise en place d'une méthode permettant de les mesurer de manière non intrusive. Nous avons mentionné quelques études dédiées à cette tâche dans la partie "mesure (non intrusive) des charges thermiques". Nous y avons mis en exergue la nécessité d'utiliser une méthode basée sur la physique pour capturer la dynamique des sous-charges thermiques. Il est aussi important de noter que les méthodes de mesure non intrusives des *sous-charges* thermiques ne tiennent pas compte des *sous-charges* négatives, ce qui constitue également un manquement à combler. Enfin, dans la section "optimisation inverse pour la génération des consignes", nous avons mis en évidence le rôle que peut jouer l'optimisation inverse dans la gestion de la consommation des charges et le maintien du confort des clients dans un contexte de réponse à la demande.

Cette thèse propose un cadre unifié qui permet de combiner les solutions émanant de la résolution de chacun des problémes inverses identifiés pour établir un système de gestion des charges de chauffages capables de:

- tenir compte des stochasticité relatives au comportement des occupants et de leurs activités dans la gestion de leurs consommations,
- garantir une prédictibilité de la consommation des ménages pour les fournisseurs d'électricités,

- garantir le bénéfice économique des consommateurs résidentiel relativement à leurs consommations,
- offrir de la flexibilité aux réseaux électriques.

Tous les avantages précités seront mis en exergue à travers les développements des chapitres qui suivent.

Chapitre 3 - Solutions des problèmes inverses et gestion efficace de la demande en chauffage

3.1 Introduction

En ce qui concerne la consommation énergétique mondiale, les statistiques ont montré que 40% de cette consommation est attribuée au secteur du bâtiment, lequel représente 30% des émissions de CO_2. Cette consommation relativement élevée peut être considérée comme la conséquence d'un besoin impératif de confort thermique [88]. Sachant que la population augmentera, cette tendance sera beaucoup plus marquée à l'avenir. Ainsi, les périodes de pointe de consommation d'électricité peuvent congestionner le réseau, entraînant une forte probabilité d'interruptions de service, en particulier durant l'hiver [89]. Par conséquent, une gestion efficace de la consommation d'énergie en milieu résidentiel devient nécessaire. Cette gestion participera à améliorer le bénéfice économique des consommateurs et du fournisseur d'électricité tout en réduisant l'empreinte carbone. Le concept émergent de réseau intelligent (*smart grid*), qui favorise l'échange d'informations entre fournisseurs et consommateurs à travers les technologies de l'information et de la communication, apparaît comme un atout pour répondre à ces enjeux en améliorant la stabilité, l'efficacité des ressources et la durabilité dans les domaines de la production, du transport et de la distribution d'énergie [90]. Il est important de noter qu'une adoption croissante des thermostats intelligents (pour le contrôle du chauffage) soutenant des applications avancées et une intégration élargie dans le contexte des maisons intelligentes a été observée dans le secteur résidentiel [91]. Ainsi, l'importance de tirer parti de leurs capacités de contrôle à distance et de collecte de données afin d'améliorer la participation aux programmes d'efficacité énergétique et de gestion de la charge devient évidente, le mécanisme de réponse à la demande (*Demand*

Response, DR) apparaissant comme une perspective prometteuse [92]. Cependant, même si certaines études ont été menées pour explorer l'efficacité d'un système de gestion de l'énergie avec thermostats intelligents intégrés dans un contexte de DR, elles ne considèrent pas le comportement de cet appareil dans le sens d'apprendre a priori sa réponse vis-à-vis d'un plan de consigne programmé et de la consommation en chauffage qui en résulte. On peut donc imaginer un contrôleur central utilisant des techniques d'optimisation, prenant en compte différents tarifs, plan de tarification et paramètres de confort pour différentes pièces chauffées d'une maison, puis envoyant le planning optimal de consignes à chaque thermostat de la maison. Par conséquent, il apparaît essentiel, pour une génération appropriée de plannings de consignes, d'apprendre, à partir des données de consommation électrique, le comportement des thermostats communicants à tension secteur préinstallés (ou thermostats programmables communicants). Un second aspect, qu'il est impératif de traiter, concerne l'établissement d'un modèle thermique qui plus ou moins fidèlement sera capable de reproduire la dynamique thermique de la maison. En outre, les incertitudes relatives au comportement des occupants, au rayonnement solaire, à l'apport en chaleurs des équipements et aux pertes thermiques doivent être nécessairement prises en compte. Nous nommons ces type d'incertitudes *sous-charges* thermiques ou charges résiduelles. À travers le développement du présent chapitre, nous allons établir les modèles des thermostats préinstallés, établir le modèle thermique de la maison, offrir un cadre permettant l'estimation et la modélisation des incertitudes évoquées ci-dessus, proposer un modèle de prédiction de ces incertitudes, mais surtout proposer un cadre unifié où ces modèles seront couplés afin de permettre une prédiction du potentiel de réponse à la demande, mais également une meilleure prise de décision sous incertitudes. Le processus de mise en œuvre d'un algorithme qui permettra de générer les décisions optimales sera également abordé. Une fois ces aspects traités, le système de gestion

efficace de la demande en chauffage pourra être mis en œuvre. Tel que nous l'avions évoqué au chapitre introductif, l'établissement des modèles de thermostats préinstallés, du modèle thermique, l'estimation des incertitudes ou encore l'algorithme de génération de consigne sont autant de problèmes inverses pour lesquels des techniques de résolution appropriées doivent être conçues. Nous allons donc rappeler les notions de base sur les problèmes inverses, leur classification, les méthodes de résolution existantes ainsi que la catégorisation des problèmes inverses qui font l'objet de cas d'étude dans cette thèse.

3.1.1 Définition des concepts de base

- ***Problème direct-Problème inverse*** **:** deux problèmes sont dits inverses l'un de l'autre si la formulation de l'un d'eux implique l'autre, selon la définition donnée par KELLER dans [93]. Une autre façon de définir un problème inverse est de considérer ce dernier comme consistant à déterminer les causes à partir des effets. Son contraire suppose donc la détermination des effets sachant les causes d'où la dénomination problème direct. Considérons l'équation suivante :

$$m(\Omega) = \omega \tag{3.1}$$

Elle représente le modèle mathématique (d'un système physique) qui pour tout paramètre Ω associe des observations ω. Ces observations peuvent être assujetties à des bruits liés, par exemple au mesurage (sensibilité des capteurs). En supposant ω^* comme représentant des observations qui seraient exemptes de tout bruit, on peut établir :

$$m(\Omega^*) + \varepsilon = \omega^* + \varepsilon = \omega \tag{3.2}$$

Le terme ε, correspond aux bruits et Ω^* aux vrais paramètres du système. Il est attendu qu'une valeur de ε ayant une amplitude même faible peut induire une différence significative entre Ω^* et la valeur établie Ω. Suivant les dénominations couramment utilisées, *m* peut être appelé fonction ou opérateur. Un problème direct consiste à déterminer la valeur de ω (effets) sachant Ω (causes) tandis que le problème inverse consiste à retrouver la valeur de Ω sachant ω. Le plus souvent, en ingénierie le fait de retrouver la valeur de Ω sachant ω est dénommé identification ou estimation des paramètres. Établir la forme de la fonction (ou de l'opérateur) *m*, avec des valeurs de Ω et ω connus correspond au problème d'identification de système.

Une des caractéristiques des problèmes inverses et qui d'ailleurs les rend difficiles à résoudre est la non-unicité de solution. Cela est dû au fait qu'un même effet peut avoir plusieurs causes. Il convient donc de choisir entre les solutions candidates et déterminer celle qui le mieux concorde avec le problème posé.

Un exemple de problème inverse est la détermination des paramètres d'un système ayant une connaissance même partielle de sa dynamique. On peut aussi ajouter la détermination de l'état antérieur d'un système (*irréversible*) connaissant son état actuel. Un exemple typique de problème direct est celui de la prédiction de l'état futur d'un système physique sachant son état actuel.

Il faut aussi noter qu'un problème inverse peut être linéaire ou non-linéaire. La non-linéarité du problème peut ajouter une couche de difficulté à sa résolution.

Supposons qu'on soit en présence d'un signal ω^* que l'on aimerait reconstruire à partir d'un ensemble de décisions Ω. Une autre façon d'entrevoir un problème

inverse est celle de la prédiction d'un profil ω qui correspond dans une certaine mesure à la restitution fidèle du signal ω^*. On peut traduire cela sous la forme du problème d'optimisation suivant:

$$\begin{aligned} &\min_{\Omega \in P} \Psi(\omega, \omega^*) \\ &\text{st: } m(\Omega) = \omega \end{aligned} \tag{3.3}$$

Avec Ψ, une fonction qui mesure la différence entre les prédictions ω et le signal original ω^*. Le problème décrit dans (3.3), est un problème d'optimisation inverse. Si dans sa structure, la fonction ou l'opérateur m est non-linéaire, il peut en résulter que (3.3) soit un problème d'optimisation nonconvexe.

- ***Notion de problème bien-posé et de problème mal-posé*:** la notion de problème bien-posé a été introduite par Hadamard [12]. Il stipule qu'un problème peut être considéré comme bien-posé si :

  — une solution existe ;

  — la solution est unique ;

  — la solution dépend continûment des données.

Un problème est dit mal-posé s'il ne remplit pas au moins une seule de ces conditions ou même les trois en même temps. C'est le cas des problèmes inverses.

IL n'est pas toujours garanti que le modèle physique établi pour trouver une solution au problème représente le système réel. Les données de mesure utilisées sont le plus souvent bruitées et peuvent compromettre la solution au problème. Même dans le cas où la solution existe, il est à prévoir que des paramètres distincts produisent

une même observation. Toutefois, même si la solution n'existe pas (inexistence de solution), il est toujours possible de proposer une forme relaxée du problème qui présente une solution. Si le problème présente plusieurs solutions (non-unicité), il doit y avoir un moyen de choisir entre elles en s'appuyant sur une information a priori. La non-continuité est cependant un peu plus problématique. En effet, la non-continuité pourrait impliquer qu'il n'est pas possible, quel que soit le procédé numérique utilisé d'approcher une solution satisfaisante du problème inverse, car les données étant bruitées, elles sont proches des valeurs réelles, mais distinctes de celles-ci.

3.1.2 Problèmes inverses : classification, méthodes de résolution et cas d'étude

- ***Classification*:** nous pouvons entrevoir la classification des problèmes inverses sous divers angles afin de pouvoir comprendre la nature du problème et de déterminer les méthodes de résolution qu'il convient d'utiliser. Une première catégorisation s'appuie sur la nature statique ou dynamique du problème direct duquel le problème inverse s'origine. En effet, contrairement aux systèmes statiques où l'inversion peut se réaliser de façon analytique, les systèmes dynamiques requièrent la prise en compte de l'évolution temporelle du système. Cela peut se faire par simulation de l'équation différentielle décrivant le système [94, 95]. La résolution de certains problèmes peut concerner l'identification de paramètres fixes ou de constantes physiques (gain d'un contrôleur, paramètres d'un modèle RC). Tandis que d'autres supposent la reconstitution des sources qui influencent le système étudié [96].

  D'un point de vue mathématique, on peut évoquer le fait que la formulation du problème peut être linéaire ou non linéaire. Pour un problème linéaire, la relation entre paramètres et observations est directe. La résolution des problèmes de type

non linéaire, quant à elle, peut requérir l'utilisation de méthodes itératives. Comme évoqué plus haut, un problème non linéaire peut souvent être non convexe.

Enfin, on peut noter que les problèmes inverses sont souvent mal posés, selon le postulat de Hadamard. Ils peuvent aussi être classés comme problèmes inverses déterministes ou stochastiques selon que les observations ou le modèle présentent des incertitudes [97, 98].

- ***Méthodes de résolution*:** la méthode de résolution employée va donc dépendre des caractéristiques du problème inverse. Par exemple, pour un problème déterministe, on peut privilégier des solutions analytiques, Laplace, transformé de Fourier [97].

  Les méthodes numériques, comme les moindres carrés, gradient conjugué, Gauss-Newton ou Levenberg-Marquardt peuvent aussi être employées pour la résolution des problèmes linéaires ou même non linéaires. Le fait qu'un problème inverse soit le plus souvent mal posé (au sens de Hadamard) peut commander l'utilisation des techniques de régularisation, telles que la régularisation de Tikhonov ou les moindres carrés régularisés pour stabiliser les solutions et limiter l'impact du bruit ou des données manquantes [99]. On privilégiera les méthodes statistiques et Bayésiennes pour les problèmes inverses stochastiques. Ainsi l'inférence Bayésienne et les méthodes Monte Carlo par chaînes de Markov (MCMC) permettront de caractériser la plausibilité de chaque solution candidate, et l'utilisation de modèles de substitution (*surrogate model*) probabilistes, tels que les processus gaussiens (GP), permettront de réduire le coût de calcul tout en quantifiant l'incertitude [94, 96, 100, 101].

  Pour des systèmes complexes et non linéaires, des approches d'optimisation globale, par exemple des algorithmes évolutionnaires , pourraient offrir des

solutions robustes. Les méthodes d'apprentissage automatique, notamment les réseaux de neurones profonds ou l'apprentissage supervisé, permettraient aussi de modéliser des relations complexes et non linéaires qui seraient difficiles à définir analytiquement [102, 103]. On peut mentionner que l'optimisation Bayésienne utilisant un processus gaussien comme modèle de substitution (*surrogate model*) permet de combiner le cadre d'apprentissage automatique basé sur une approche probabiliste et l'optimisation. Ainsi, elle contribue à réduire le nombre d'évaluations du modèle réel, à quantifier l'incertitude sur l'approximation de la fonction objective et peut inclure des contraintes physiques ou des régularisations, garantissant l'efficacité, la robustesse et la cohérence des solutions, même pour des problèmes non linéaires et mal posés [100, 104, 105].

- ***Cas d'étude, catégorisation et choix de solution:*** l'identification des gains d'un contrôleur PI déjà opérationnel constitue un problème inverse dynamique non linéaire et mal posé ; des méthodes numériques itératives, éventuellement complétées par des approches statistiques, permettraient d'estimer ces paramètres tout en quantifiant l'incertitude. En effet, le problème est catégorisé comme dynamique dans la mesure où, le comportement du contrôleur est appelé à évoluer dans le temps. Par ailleurs, comme évoqué dans le chapitre introductif, la dynamique du système thermostat est non linéaire et est discontinue aux limites du fait d'une fonction de saturation et de la stratégie $anti-windup$ [106]. Le modèle mathématique d'un tel système peut se rapporter à l'équation définie dans (3.1). Connaissant la structure de l'opérateur m, établir un tel modèle, revient à déterminer les valeurs des paramètres Ω permettant de reproduire plus ou moins fidèlement la dynamique du système. Sa discontinuité aux limites implique que la troisième condition d'un problème dit bien posé n'est pas remplie. C'est donc un problème

mal-posé. Il en résulte que la solution du problème n'est pas unique. L'identification des paramètres Ω correspond donc à un problème inverse pour lequel une technique de résolution appropriée doit être conçue.

L'identification des paramètres d'un modèle thermique de type RC et l'estimation de charges résiduelles combinent dynamique, non-linéarité et incertitude ; les méthodes classique d'optimisation ou de filtre stochastique sont generalement employés pour l'identification des paramètres *RC*. L'utilisation des approches Bayésiennes ou hybrides comme l'optimisation Bayésienne avec processus gaussien (GP) permettraient une estimation efficace. On peut toujours se référer à l'équation (3.1) pour définir le modèle thermique *RC*, le paramètre Ω représentera le vecteur des valeurs R et C à déterminer. Retrouver les valeurs dans Ω peut être une tache très complexe ; les données ω sont potentiellement bruités. Ce qui implique que la valeur de Ω qui satisfasse (3.1), n'est pas unique. Le problème d'identification des paramètres du modèle thermique est un problème mal-posé donc inverse. Il s'agira de proposer une procédure d'identification dédiée. Par ailleurs, estimer les charges thermiques ou résiduelles correspond à déterminer l'état passé d'un système *irréversible* connaissant son état actuel. Il s'agit donc d'un problème inverse.

Enfin, l'inversion d'un plan de puissance pour générer des consignes de température illustre également un problème dynamique, non linéaire et mal posé, où plusieurs configurations de consignes peuvent produire des puissances similaires ; les méthodes numériques et d'apprentissage automatique, ou des techniques hybrides pourraient offrir une robustesse et une précision dans la solution. Dans ce cas précis, on cherchera par exemple à reproduire un profil optimal ω^* qui satisfait la contrainte de confort thermique et d'objectif énergétique en produisant les paramètres Ω

qui permettront cette reconstitution. On peut traduire cela comme un problème d'optimisation inverse tel que défini dans (3.3).

Les problèmes inverses qui sont traités dans cette thèse sont donc dynamiques, non linéaires et mal posé. Les données étant potentiellement bruitées, résoudre ce type de problèmes va donc nécessiter l'utilisation d'une approche probabiliste. Ainsi, l'optimisation Bayésienne utilisant un processus gaussien comme modèle de substitution (*surrogate model*) apparaît comme un choix judicieux. En effet, son efficacité et sa robustesse lui permettent de supplanter les méthodes de résolution classiques généralement utilisées pour la résolution des problèmes inverses ici évoqués. Un bon usage de cette méthode peut conduire à combler les lacunes des méthodes classiques, telles que nous les avons déjà énumérées au chapitre dédié à la revue de la littérature. Ces lacunes concernent principalement : a) la difficulté d'identification des paramètres uniques pour le contrôleur PI, b) Problème de généralisation, d'interprétation et de surcharge computationnelle pour ce qui est de l'établissement d'un modèle thermique lorsque des méthodes hybrides utilisant les réseaux neuronaux sont employées. Les méthodes hybrides étant celles qui le mieux accommodent les non-linéarités, il est nécessaire d'apporter une alternative présentant la même efficacité mais avec un coût computationnel réduit. Pour ce qui est de l'inversion du plan de puissance pour le *traduire* en termes de consignes de température, c'est surtout la survenance des incertitudes qu'il faut prendre en compte pour ne pas dévier du plan de consommation (puissance) établit. Ce qui va nécessiter de proposer une méthodologie de résolution assez robuste.

3.1.3 Objectif scientifique du chapitre:

Ce chapitre constitue le cœur méthodologique de la thèse. Son objectif scientifique est de formuler et résoudre, dans un cadre unifié, les problèmes inverses qui sous-tendent la gestion des charges de chauffage résidentielles : identification des thermostats préinstallés, identification du modèle thermique du bâtiment, estimation des charges résiduelles, puis la génération des consignes par optimisation inverse. La logique de progression suivie est *identification* $\rightarrow$ *estimation* $\rightarrow$ *contrôle* : chaque brique alimente la suivante, et leur articulation autour d'un modèle thermo-thermostatique unique constitue la contribution centrale du chapitre. La figure 3.1 en donne une vue d'ensemble.

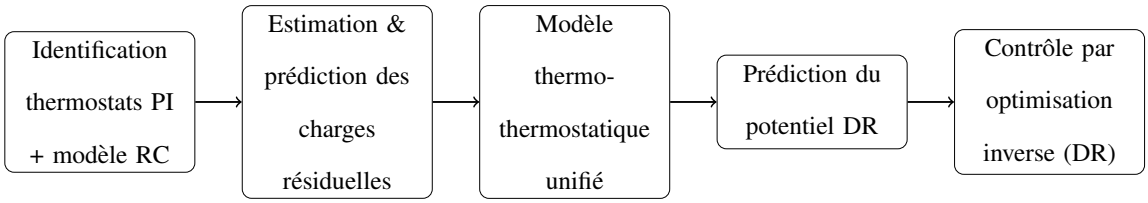


Figure 3.1 Vue d'ensemble du pipeline méthodologique : de l'identification au contrôle.

3.1.4 Méthodologie générale et objectifs:

Ci-dessous (figure 3.2), un schéma qui illustre de manière simplifiée comment différentes étapes sont combinées pour passer de la modélisation, l'identification jusqu'à l'établissement du mécanisme d'inversion. Ce dernier assure la conversion d'une puissance optimale en paramètres de contrôle à appliquer aux thermostats, afin de gérer efficacement les charges de chauffage. Comme indiqué sur la figure 3.2, l'objectif 1 porte sur la modélisation et l'identification du thermostat. L'objectif 2 consiste à établir le modele de simulation de la maison puis à passer à l'implémentation du programme DR au niveau de la maison. Cela passe d'abord par la modélisation et

l'identification des paramètres d'un modèle thermique multizone (de type RC) suivies de la définition de l'estimateur et du prédicteur des charges thermiques résiduelles (*sous-charges* thermiques). À la fin de cette étape, nous obtenons un simulateur de maison ou de bâtiment (modèle thermo-thermostatique), un estimateur de charges résiduelles et un prédicteur de charges résiduelles. On pourra donc ainsi passer à l'implémentation du programme DR. L'objectif 3 va consister à tirer parti des éléments obtenus à la suite des étapes précédentes pour assurer l'inversion de puissance optimale en décisions applicables aux thermostats. Dans le développement de ce chapitre, nous détaillerons la manière dont cela est réalisé.

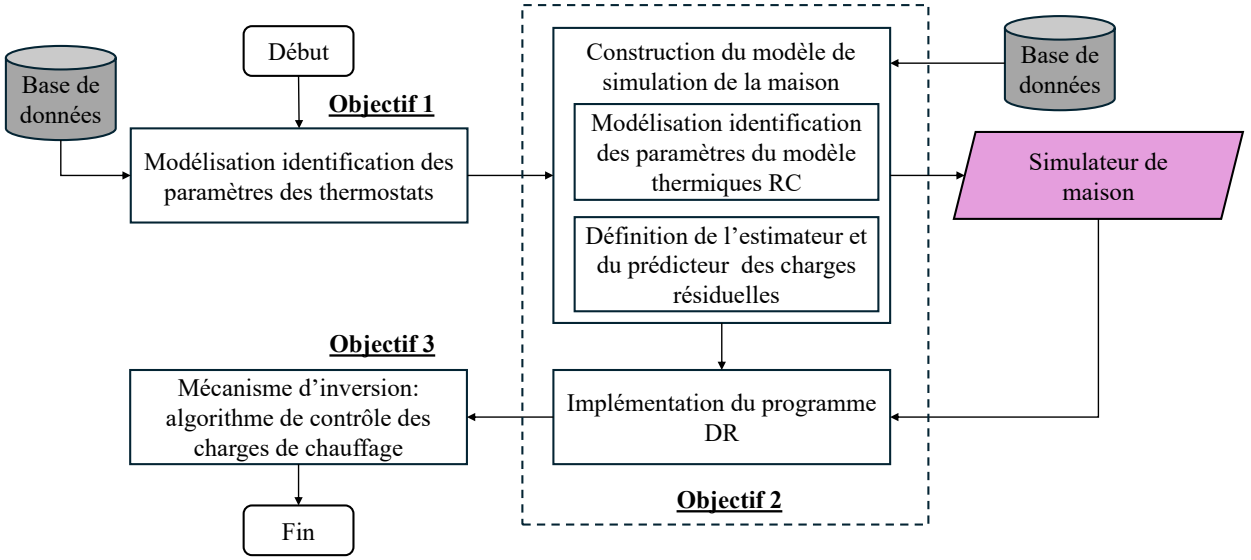


Figure 3.2 Schéma illustratif de la méthodologie

Ainsi, conformément aux objectifs de la thèse tels que declinés au chapitre introductif, nous scindons le présent chapitre en trois sections:

1. *Modélisation et identification des paramètres des thermostats préinstallés*: exclusivement dédié à une méthodologie d'identification des paramètres des contrôleurs préinstallés sous l'hypothèse que la structure de contrôle est celle d'un contrôleur PI.
2. *Prédiction du potentiel de réponse à la demande*: dans cette partie, nous allons décliner une méthode pour l'identification des paramètres d'un modèle thermique de type réseau RC, l'établissement d'un modèle thermo-thermostatique, ensuite, nous allons proposer une technique pour l'estimation des charges résiduelles (*sous-charges* thermiques), établir un modèle de prédiction de ces charges et prendre avantage des modèles établis pour définir un cadre permettant de faire une prédiction du potentiel de réponse à la demande au sein d'une résidence.
3. *Algorithme de contrôle des charges de chauffage basé sur une optimisation inverse*: dans cette partie, nous allons définir et implémenter l'algorithme qui permettra de générer des décisions optimales permettant une meilleure gestion des charges de chauffage.

3.1.5 Conditions de mise en œuvre:

Les méthodes proposées dans ce chapitre reposent sur quelques conditions pratiques qu'il convient d'énoncer : (i) la disponibilité de mesures de consigne, de température intérieure et de puissance (ou de rapport cyclique) issues des thermostats communicants ; (ii) la connaissance *a priori* d'une plage de fonctionnement raisonnable des paramètres du contrôleur, exploitée pour amorcer la recherche en espace réduit ; (iii) l'existence de périodes où les charges résiduelles sont quasi nulles, nécessaires à l'identification du modèle RC sans résiduel ; et (iv) une hypothèse de structure de contrôle de type PI avec stratégie *anti-windup*. Ces conditions sont raisonnables pour un parc résidentiel équipé de

thermostats communicants modernes.

3.2 Modélisation et identification des paramètres des thermostats préinstallés

Pour établir un modèle physiquement interprétable des thermostats, nous proposons à travers un algorithme une approche de recherche dans un espace réduit (*Shrinked-Space Search*) qui rétrécit, au cours du processus d'identification, le domaine dans lequel les paramètres de réglage du contôleur peuvent se situer. Ainsi, nous proposons une approche de recherche dans un espace réduit basée sur l'optimisation Bayésienne (*Shrinked-Space Search*, S-SS) . Elle introduit une procédure à deux niveaux qui exploite les informations provenant de différents points de fonctionnement des thermostats afin d'imposer l'identification des états (conditions initiales) et d'un ensemble unique de paramètres offrant une bonne précision au modèle établi. L'algorithme proposé évite d'explorer un espace de recherche non réaliste, réduisant considérablement le nombre d'itérations nécessaires pour la convergence en exploitant un modèle de référence. Une stratégie de suivi de la partie intégrateur (du modèle PI) est utilisée pour déterminer la logique qui sous-tend cette partie.

La section 3.2.1 présente un modèle de référence décrivant la dynamique du contrôleur ; la section 3.2.2 donne une explication détaillée de la méthode de recherche dans un espace réduit proposée et la section 3.2.3 explique la stratégie de suivi de l'intégrateur pour évaluer son efficacité.

3.2.1 Modèle de référence

La méthode proposée est basée sur une optimisation Bayésienne contrainte et exploite un modèle de référence pour former sa fonction objectif. Le schéma-bloc du dispositif

proposé est présenté dans la Fig. 3.3, où une structure de régulateur PI [31] [107] [108] est adoptée pour construire le modèle de référence, c.-à-d:

$$p_t = k_p e_t + k_i I_t, \tag{3.4}$$

où e_t correspond à l'erreur du régulateur et I_t représente la valeur de l'intégrateur. Les deux valeurs, e_t et I_t, sont pondérés respectivement par le gain proportionnel k_p et le gain intégral $k_i = (k_p/\tau_i)$, τ_i étant le temps de réinitialisation. L'indice t désigne le $t^{ième}$ instant discret. La saturation du régulateur (3.4) basée sur une limitation de l'actionneur est décrite

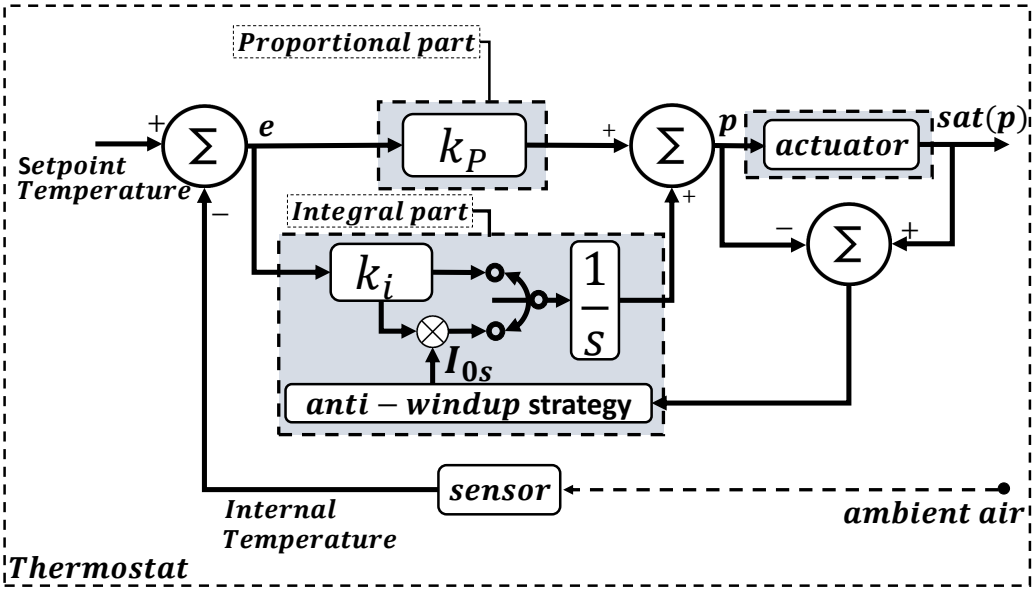


Figure 3.3 Schéma-bloc de la structure PI.

comme suit :

$$\text{sat}(p_t) = \begin{cases} p_{\max}, & p_t \geq p_{\max}, \\ p_t, & p_t \in (p_{\min}, p_{\max}), \\ p_{\min}, & p_t \leq p_{\min}. \end{cases} \tag{3.5}$$

Dans (3.5), sat(.) désigne la fonction de saturation avec un seuil supérieur $p_{\max}$ et un seuil inférieur $p_{\min}$. L'intégrateur I_t prend différentes valeurs lorsque le régulateur sort de la saturation en fonction de la stratégie *anti-windup* appliquée, c.-à-d.:

$$I_t = \begin{cases} I_{ss,t}, & e_t = 0, \\ I_{t-1} + e_t, & \text{sat}(p_{t-1}) \notin \{p_{\min}, p_{\max}\}, \\ I_{0s,} & \text{sat}(p_{t-1}) \in \{p_{\min}, p_{\max}\}, \end{cases} \tag{3.6}$$

Où les valeurs initiales de l'intégrateur aux instants post-saturation sont notées I_{0s} et les valeurs en régime permanent I_{ss}. En combinant (3.4) et (3.6), le comportement du régulateur peut être réécrit comme suit :

$$p_t = \begin{cases} k_i I_{ss,t}, & e_t = 0, \\ k_p e_t + k_i (I_{t-1} + e_t), & \text{sat}(p_{t-1}) \notin \{p_{\min}, p_{\max}\}, \\ p_{\min} \vee p_{\max}, & p_t \leq p_{\min} \vee p_t \geq p_{\max}, \\ k_p e_t + k_i I_{0s}, & \text{sat}(p_{t-1}) \in \{p_{\min}, p_{\max}\}. \end{cases} \tag{3.7}$$

3.2.2 Méthode de recherche dans un espace réduit (Shrinked-Space Search, S-SS)

Ici, nous discutons de la méthode proposée de recherche dans un espace réduit (*Shrinked-Space Search*, S-SS) et de sa formulation mathématique. La méthode proposée repose sur l'optimisation Bayésienne pour résoudre le problème inverse d'identification des paramètres du thermostat. Le choix de l'optimisation Bayésienne repose entre autre sur sa nature *exploratoire* permettant d'évaluer différents modes de la fonction objectif [109]. Plus précisément, l'optimisation bayésienne est particulièrement adaptée à notre problème inverse pour trois raisons. D'abord, la fonction de dissimilarité à minimiser

peut présenter plusieurs minima locaux dus aux saturations et aux stratégies *anti-windup* ; un modèle de substitution (processus gaussien) permet d'en explorer efficacement les différents modes. Ensuite, chaque évaluation de la fonction objectif pourrait requerir une simulation coûteuse du thermostat ; l'optimisation bayésienne minimise précisément le nombre d'évaluations nécessaires. Enfin, la recherche est contrainte à un espace de paramètres physiquement admissible, ce que la fonction d'acquisition intègre naturellement. Comparée aux méthodes de descente de gradient (sensibles aux minima locaux) ou aux méthodes évolutionnaires (coûteuses en évaluations), l'optimisation bayésienne offre ainsi le meilleur compromis pour ce type de problème inverse. Les non-linéarités dans la dynamique du thermostat résultent des occurrences de saturation, et de nouvelles conditions initiales sont établies après saturation. Dans la méthode S-SS proposée, les données sont collectées à différents instants entre deux saturations, et les paramètres sont estimés séquentiellement jusqu'à ce que l'espace de recherche se réduise suffisamment pour converger vers un seul ensemble de paramètres compatibles avec la dynamique de tous les groupes. La Fig. 3.4 illustre le fonctionnement de la méthode proposée ; chaque étape de la procédure est expliquée ci-dessous.

a) Initialisation des paramètres :

La Fig.3.5 décrit l'idée d'exploration des paramètres du contrôleur dans l'espace de recherche dans le cadre de la méthode proposée. Dans la Fig. 3.5, les bornes supérieure et inférieure de l'intervalle de recherche associé au gain proportionnel et au temps de réinitialisation de l'intégrateur sont respectivement $(k_{p,\min}^{(l,j)}, k_{p,\max}^{(l,j)}) \in \left[K_{\min}^{(l)}, K_{\max}^{(l)}\right]$ et $(\tau_{i,\min}^{(l,j)}, \tau_{i,\max}^{(l,j)}) \in \left[T_{\min}^{(l)}, T_{\max}^{(l)}\right]$. Les termes $K_{\min}^{(l)}$, $K_{\max}^{(l)}$, $T_{\min}^{(l)}$ et $T_{\max}^{(l)}$ jouent le rôle de valeurs raisonnables minimales et maximales pour les bornes. Il est important de noter que l est

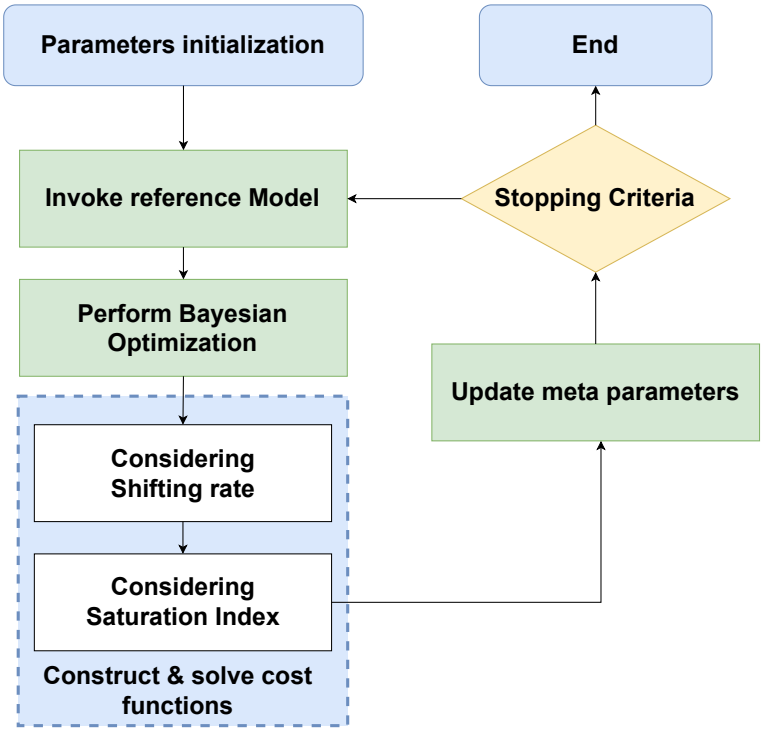


Figure 3.4 Procédure de la méthode de recherche dans un espace réduit (S-SS).

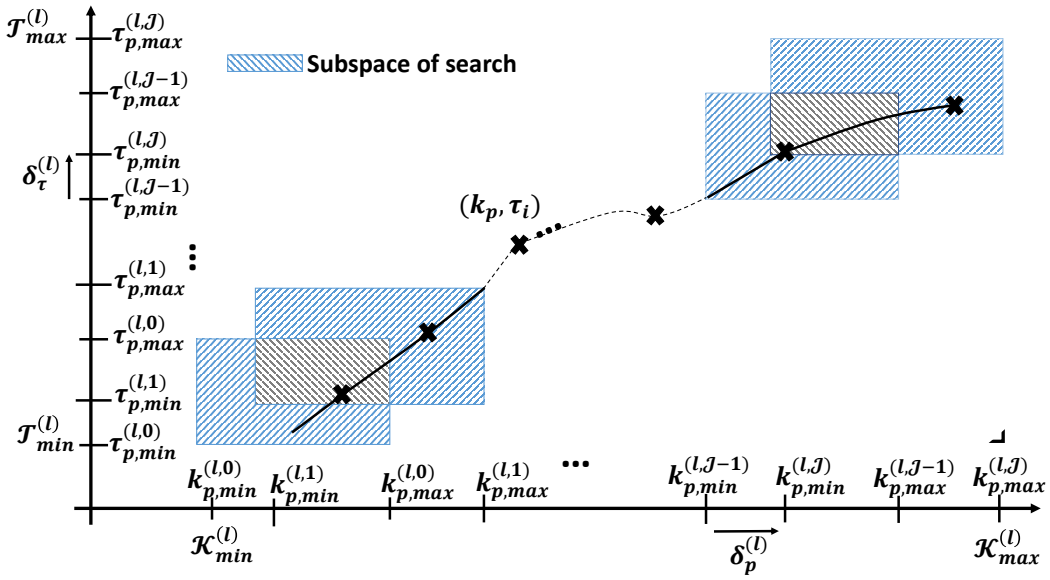


Figure 3.5 Exploration de l'espace de recherche.

défini comme un niveau d'évaluation de l'algorithme S-SS proposé (Fig. 3.4). De plus, $j = \{0, \ldots J\}$ représente l'indice de taux de décalage, qui module les taux de décalage $\delta_p^{(l)}$ et $\delta_\tau^{(l)}$ liés à l'intervalle de recherche du gain proportionnel et du temps de réinitialisation de l'intégrateur, respectivement. À noter que le taux de décalage est responsable du déplacement de l'intervalle de recherche de chaque paramètre à l'intérieur des valeurs raisonnables définies. Pour $l = 0$, les méta-paramètres J, $K_{\min}^{(l)}$, $K_{\max}^{(l)}$, $T_{\min}^{(l)}$ et $T_{\max}^{(l)}$ sont initialisés. Pour chaque niveau d'évaluation l, comme illustré dans la Fig. 3.5, les relations suivantes doivent être considérées :

$$k_{p,\min}^{(l,0)} = K_{\min}^{(l)}, \tau_{i,\min}^{(l,0)} = T_{\min}^{(l)}, k_{p,\max}^{(l,J)} = K_{\max}^{(l)}, \tau_{i,\max}^{(l,J)} = T_{\max}^{(l)}. \tag{3.8}$$

De plus, pour chaque indice de taux de décalage j dans l, les relations suivantes sont considérées pour déplacer l'intervalle de recherche à travers les bornes raisonnables :

$$\begin{cases} k_{p,\min/\max}^{(l,j)} = k_{p,\min/\max}^{(l,0)} + j\delta_p^{(l)}, \\ \tau_{i,\min/\max}^{(l,j)} = \tau_{i,\min/\max}^{(l,0)} + j\delta_\tau^{(l)}. \end{cases} \tag{3.9}$$

b) Invoquer le modèle de référence et définir la fonction objectif : La Fig. 3.6 illustre les changements dynamiques du contrôleur en fonction de la déviation de la variable contrôlée par rapport à la consigne, ainsi que l'apparition de la saturation au fil du temps.

Pour invoquer le modèle de référence, (3.7) peut être réécrit en fonction des instants de saturation :

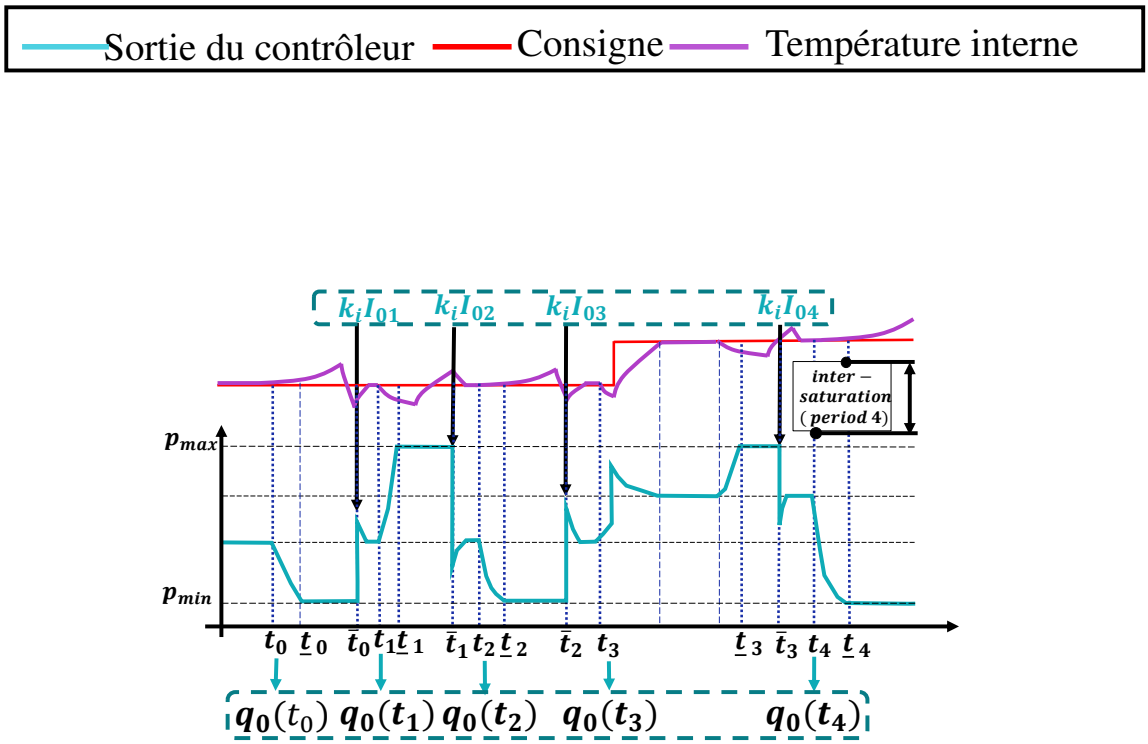


Figure 3.6 Illustration de la sortie du contrôleur.

$$p_t = \begin{cases} k_i I_{ss,t} & \text{pour } e_t = 0, \\ k_p e_t + k_i \left(I_{t-1} + e_t\right) & \text{pour } t_s < t < \underline{t}_s, \\ p_{\min} \vee p_{\max} & \text{pour } \underline{t}_s < t < \bar{t}_s, \\ k_p e_t + k_i I_{0s} & \text{pour } \bar{t}_s < t < t_{s+1}, \end{cases} \tag{3.10}$$

avec $I_{t_s} = \frac{\tau_i}{k_p} q_0(t_s)$. La quantité I_{t_s} désigne la valeur du terme intégrateur à l'instant initial t_s de la période inter-saturation s ; elle fixe la condition initiale de l'intégrateur sur cette période. Elle intervient donc implicitement dans la branche $k_p e_t + k_i(I_{t-1} + e_t)$ de l'équation précédente à travers la récurrence sur I_{t-1} (initialisée par I_{t_s}), et non comme un terme additif explicite. C'est cette dépendance à la condition initiale post-saturation qui rend la dynamique non linéaire et motive l'identification séquentielle par période

inter-saturation.

Pour un indice de saturation donné s, l'intervalle $[t_s, \underline{t}_s]$ indique le fonctionnement normal du contrôleur pour traiter les variations de la variable contrôlée, où $\underline{t}_s$ désigne l'instant où il atteint l'état de saturation et reste jusqu'à $\bar{t}_s$. Plus précisément, I_{0s} représente la valeur de l'intégrateur définie par la stratégie *anti-windup*, à l'instant $\bar{t}_s$, lorsque le contrôleur sort de l'état de saturation. À chaque régime permanent, après avoir atteint la consigne, une nouvelle valeur de biais $q_0(t_s)$ est considérée. Il est évident que le phénomène de *windup* (emballement) de l'intégrateur dépend de la valeur du terme intégrateur I_{0s}, qui peut être proche de $q_0(t_s)$ selon la stratégie *anti-windup* appliquée à chaque période inter-saturation.

Une connaissance a priori de la plage de fonctionnement du thermostat permet de contraindre la recherche des paramètres du thermostat dans des intervalles correspondant à la zone de recherche appropriée. L'espace de recherche raisonnable A est défini comme :

$$A = \left[I_{0,\min}, I_{0,\max}\right] \times \left[k_{p,\min}^{(l,j)}, k_{p,\max}^{(l,j)}\right] \times \left[\tau_{i,\min}^{(l,j)}, \tau_{i,\max}^{(l,j)}\right],$$

et le sous-espace dynamique de recherche est exprimé comme

$$B = \left[k_{p,\min}^{(l,j)}, k_{p,\max}^{(l,j)}\right] \times \left[\tau_{i,\min}^{(l,j)}, \tau_{i,\max}^{(l,j)}\right].$$

L'espace A est tridimensionnel et inclut la condition initiale de l'intégrateur I_0 en plus de (k_p, τ_i) ; il sert à l'identification complète sur une période inter-saturation donnée (où

la condition initiale est à determiner). Le sous-espace B, bidimensionnel, concerne les seuls paramètres de réglage (k_p, τ_i), qui, eux, sont communs à toutes les périodes. C'est ce sous-espace B, et non A, qui est réduit itérativement et qui correspond à l'espace de recherche illustré à la figure 3.5.

Soit la sortie observée du thermostat aux $k^{\text{ème}}$ instants discrets $p_t^o \in P$ et le modèle de référence $p_t : A \subset \mathbb{R}^3 \to P \subset \mathbb{R}$ avec des paramètres inconnus $\theta^{(l,j)} \in A$. Comme le modèle de référence (3.7) est supposé être correctement spécifié, l'objectif est de trouver le meilleur $\theta^{(l,j)^*} \in A$ de sorte à vérifier l'égalité suivante :

$$p_t^o = p_t(\theta^{(l,j)^*}) + \varepsilon_t, \tag{3.11}$$

où ε_t représente l'erreur de mesurage qui est inconnue. Pour trouver les paramètres pseudo-optimaux, nous définissons une fonction de dissimilarité Γ_s pour chaque indice de saturation s :

$$\Gamma_s(\theta_s^{(l,j)}) = \frac{1}{N_s} \sum_{k_s=0}^{N_s-1} \left| p_{k_s}(\theta_s^{(l,j)}) - p_{k_s}^o \right|, \tag{3.12}$$

où N_s désigne le nombre de pas de temps dans une période inter-saturation.

c) Appliquer l'optimisation Bayésienne : l'équation (3.12) est assignée comme fonction de coût locale pour la $s^{\text{ème}}$ période inter-saturation à minimiser en exploitant l'optimisation Bayésienne afin d'obtenir :

$$\theta_s^{(l,j)^*} = \underset{\theta_s^{(l,j)} \in A}{\arg\min}\, \Gamma_s(\theta_s^{(l,j)}). \tag{3.13}$$

Pour trouver l'ensemble pseudo-optimal de paramètres $\theta_s^{(l,j)^*}$, la fonction d'acquisition *Expected improvement* (*EI*) est utilisée [110] :

$$EI(\theta_s^{(l,j)}) := E[[\Gamma_{s,\min} - \Gamma_s(\theta_s^{(l,j)})]^+], \tag{3.14}$$

où,

$$\Gamma_{s,\min} = \min\{\Gamma_s(\theta_{s,0}^{(l,j)}), \Gamma_s(\theta_{s,1}^{(l,j)}) \ldots \Gamma_s(\theta_{s,m}^{(l,j)})\}. \tag{3.15}$$

Dans (3.14), $E[.]$ indique l'espérance par rapport à une distribution à posteriori. Comme l'optimisation Bayésienne procède par itérations, $\theta_{s,m}^{(l,j)}$ dans (3.15) représente le point échantillonné à la $m^{\text{ème}}$ itération et $\Gamma_s(\theta_{s,m}^{(l,j)})$ est la valeur observée en ce point particulier. À noter que l'ensemble des observations $D = [\theta_{s,0:m}^{(l,j)}, \Gamma_s(\theta_{s,0:m}^{(l,j)})]$ est normalement distribué avec une moyenne $\mu_m(\theta_s^{(l,j)})$ et une variance $\sigma_m^2(\theta_s^{(l,j)})$. Comme m est le nombre d'évaluations de Γ_s, le minimum global de la réponse observée jusqu'à l'itération m est considéré (3.15).

L'amélioration de la meilleure valeur observée est donnée par $\Gamma_{s,\min} - \Gamma_s(\theta_s^{(l,j)})$ si la quantité est positive, et 0 sinon, c.-à-d. $[\Gamma_{s,\min} - \Gamma_s(\theta_s^{(l,j)})]^+ = \max(\Gamma_{s,\min} - \Gamma_s(\theta_s^{(l,j)}), 0)$.

Lorsque la réponse de la fonction est évaluée en un nouveau point $\theta_s^{(l,j)}$, alors

le meilleur point observé est mis à jour selon : $(\Gamma_s(\theta_s^{(l,j)}) \leq \Gamma_{s,\min}) \Rightarrow \Gamma_s(\theta_s^{(l,j)})$ ou $(\Gamma_s(\theta_s^{(l,j)}) \geq \Gamma_{s,\min}) \Rightarrow \Gamma_{s,\min}$. L'objectif est de choisir $\theta_s^{(l,j)}$ de sorte à maximiser l'amélioration ; cependant, sans évaluation, $\Gamma_s(\theta_s^{(l,j)})$ reste inconnu. Ainsi, une valeur d'amélioration attendue sous la distribution à posteriori des évaluations précédentes est considérée et $\theta_s^{(l,j)}$ est choisi pour maximiser l'espérance. Finalement, le prochain point présentant la plus grande amélioration est obtenu par :

$$\theta_{s,m+1}^{(l,j)} = \arg\max_{\theta_s^{l,j}} EI(\theta_s^{(l,j)}). \tag{3.16}$$

Ici, l'évaluation interne s'arrête à un certain point m après avoir atteint le nombre maximal d'itérations fixé ou lorsque le meilleur ensemble de paramètres est obtenu, montrant que le coût minimal reste inchangé pendant un certain nombre d'évaluations [111]. La procédure expliquée ci-dessus pour appliquer l'optimisation Bayésienne est résumée dans l'Algorithme 1.

Algorithme 1 Optimisation Bayésienne

Entrée : Espace de recherche A, Jeu de données correspondant à la séquence s
Tant que $j \leq J$ **faire**
    Pour M nombre d'itérations **faire**
        Maximiser la fonction d'acquisition selon (3.14)
        Évaluer la fonction objectif en $\theta_{s,m+1}^{(l,j)}$ et obtenir $\Gamma_s(\theta_{s,m+1}^{(l,j)})$
        Ajouter le point $(\theta_{s,m+1}^{(l,j)}, \Gamma_s(\theta_{s,m+1}^{(l,j)}))$ au jeu de données D
    Fin Pour
    Sortie : $\theta_s^{(l,j)^*}$
Fin Tant que
Sorties : $\{\theta_s^{(l,0)^*}, \theta_s^{(l,1)^*} \dots \theta_s^{(l,J)^*}\}$

d) Construction et résolution des fonctions de coût globales : Puisque nous cherchons à identifier un ensemble unique de paramètres (k_p, τ_i) lorsque la condition initiale est connue pour varier en raison des occurrences de saturation, nous considérons uniquement les

sous-vecteurs d'ensembles pseudo-optimaux de paramètres (k_p, τ_i), c'est-à-dire $\tilde{\theta}_s^{(l,j)^*} \in B$. La fonction de coût globale, Ω_s, pour les données correspondant au $s^{\text{ème}}$ intervalle entre saturations (en considérant toutes les valeurs de l'indice de taux de décalage) est construite en prenant l'ensemble des ensembles pseudo-optimaux de paramètres $\{\tilde{\theta}_s^{(l,0)^*}, \tilde{\theta}_s^{(l,1)^*} \dots \tilde{\theta}_s^{(l,J)^*}\}$.

Étant donné que l'estimation par noyau est connue pour fournir une bonne approximation de la fonction de densité de probabilité associée à un processus aléatoire à partir d'un ensemble d'observations [112], [113], nous utilisons ce formalisme pour construire la fonction de densité multivariée Ω_s. Nous en dérivons ensuite un vecteur bidimensionnel contenant un ensemble pseudo-optimal de paramètres pour l'instant de la $s^{\text{ème}}$ saturation, soit $X_s^{(l,*)} = (X_{s,i}^{(l,*)})_{i\in\{p,\tau\}}$, en maximisant Ω_s comme suit Ici, $X_s^{(l,*)}$ est le vecteur bidimensionnel $(X_{s,p}^{(l,*)}, X_{s,\tau}^{(l,*)})$ regroupant, pour la $s^{\text{ème}}$ saturation et le niveau d'évaluation l, les estimés retenus du gain proportionnel ($i = p$) et du temps de réinitialisation ($i = \tau$). Autrement dit, $X_{s,i}^{(l,*)}$ désigne la i-ème composante ($i \in \{p, \tau\}$) de cet ensemble pseudo-optimal :

$$X_s^{(l,*)} = \arg\max(\underbrace{\frac{1}{J}\sum_{j=0}^{J}\left(\sqrt{|\widehat{H}|}\right)K\{\widehat{H}^{-1}(X_s^{(l)} - \tilde{\theta}_s^{(l,j)^*})\}}_{\Omega_s}), \tag{3.17}$$

où $K(.)$ est la fonction noyau multivariée définie comme gaussienne et $\widehat{H} = J^{-1/6}M^{1/2}$ dans $\mathbb{R}^{2\times 2}$, une matrice de lissage symétrique définie positive, avec matrice de covariance diagonale $M = \text{diag}(\sigma_p^2, \sigma_\tau^2)$. Notons que σ_p et σ_τ sont respectivement les écarts-types des gains proportionnels et intégrateurs pseudo-optimaux observés. En tenant compte de ces conditions, $\widehat{H}$ est dérivée de la règle de Scott [114] en minimisant l'erreur quadratique intégrée moyenne (*mean integrated squared error*).

De même, une fonction de coût globale Ξ_l pour l'ensemble des S intervalles entre saturations est construite pour être maximisée afin de définir le prochain intervalle borné de recherche. En considérant l'ensemble des observations $\{X_0^{(l,*)}, X_1^{(l,*)} \dots X_S^{(l,*)}\}$, et la matrice de lissage $\widehat{H} = S^{-1/6}M^{1/2}$, nous obtenons l'ensemble pseudo-optimal de paramètres $Y^{(l,*)} = (Y_i^{(l,*)})_{i\in\{p,\tau\}}$ au $l^{\text{ème}}$ niveau d'évaluation comme suit :

$$Y^{(l,*)} = \arg\max(\underbrace{\frac{1}{S}\sum_{s=0}^{S}\left(\sqrt{|\widehat{H}|}\right)K\{\widehat{H}^{-1}(Y^{(l)} - X_s^{(l,*)})\}}_{\Xi_l}). \tag{3.18}$$

e) Mise à jour des méta-paramètres : Les valeurs rationnelles supérieures et inférieures du gain proportionnel ($K_{\max}^{(l)}$, $K_{\min}^{(l)}$) et du temps de réinitialisation de l'intégrateur ($T_{\max}^{(l)}, T_{\min}^{(l)}$) sont mises à jour sur la base de (3.18), avec $\gamma \in (0,1]$ comme facteur de modulation de la zone de recherche, c.-à-d.,

$$K_{\max}^{(l)} = \max\{Y_p^{(l,*)}, \tilde{Y}_p^{(l)}\}\gamma + \underbrace{\min\{Y_p^{(l,*)}, \tilde{Y}_p^{(l)}\}}_{K_{\min}^{(l)}}, \tag{3.19}$$

$$T_{\max}^{(l)} = \max\{Y_\tau^{(l,*)}, \tilde{Y}_\tau^{(l)}\}\gamma + \underbrace{\min\{Y_\tau^{(l,*)}, \tilde{Y}_\tau^{(l)}\}}_{T_{\min}^{(l)}}. \tag{3.20}$$

Ici, $\tilde{Y}^{(l)}$ correspond au vecteur de paramètres obtenu en minimisant Ξ_l.

De plus, les taux relatifs de décalage $\delta_{i|i\in\{p,\tau\}}^{(l)}$ et l'indice de taux de décalage J avec un facteur de proportionnalité α sont également mis à jour, c.-à-d.,

$$\delta^{(l)}_{i|i\in\{p,\tau\}} = \frac{|Y_i^{(l,*)} - \tilde{Y}_i^{(l)}|}{\alpha}, \tag{3.21}$$

$$J = \alpha \left(\frac{K^{(l)}_{\max} + \min\{Y_i^{(l,*)}, \tilde{Y}_i^{(l)}\}}{\max\{Y_i^{(l,*)}, \tilde{Y}_i^{(l)}\}} - 1 \right). \tag{3.22}$$

Le critère d'arrêt pour la mise à jour des méta-paramètres dans l'algorithme S-SS peut être défini comme suit :

$$\lim_{l\to\infty}(K^{(l)}_{\min}/K^{(l)}_{\max}) = \varepsilon, \quad \lim_{l\to\infty}(T^{(l)}_{\min}/T^{(l)}_{\max}) = \varepsilon, \tag{3.23}$$

où $\varepsilon \approx 1$. Lorsque (3.23) n'est pas vérifié, et sur la base de (3.8), le sous-espace de recherche B est mis à jour. Le pseudo-code de la méthode proposée de recherche dans un espace réduit (S-SS) est donné ci-dessous :

Algorithme 2 Pseudo-code de la méthode S-SS

Initialiser les méta-paramètres à $l = 0$
Tant que le critère d'arrêt (3.23) n'est pas atteint **faire**
    Pour $s \leq S$ **faire**
        Appliquer l'Algorithme 1
        Construire et résoudre la fonction de coût globale, Eq. (3.17)
    Fin Pour
    Sortie : $\{X_0^{(l,*)}, X_1^{(l,*)} \dots X_S^{(l,*)}\}$
    Construire et résoudre la fonction de coût globale, Eq. (3.18)
    Mettre à jour les méta-paramètres : (3.19), (3.20), (3.21), (3.22)
    Vérifier le critère d'arrêt (3.23)
    $l \leftarrow l + 1$
Fin Tant que
Sorties : $\theta^{(l,j)^*}$

3.2.3 Suivi de la dynamique du terme intégrateur

L'efficacité de la méthode proposée de recherche dans un espace réduit (S-SS) est testée à travers le suivi de la dynamique de l'intégrateur pour une validation expérimentale supplémentaire. En effet, la partie intégrateur du régulateur est une variable latente dont les mesures sont inaccessibles, ce qui rend sa logique de mise à jour inconnue. Ainsi, nous développons un mécanisme pour reconstruire sa dynamique, en considérant que les occurrences de régime permanent révèlent les valeurs de la partie intégrateur, lorsque la partie proportionnelle s'annule. La stratégie développée, basée sur l'approche de programmation convexe, vise à retrouver les paramètres du régulateur en estimant sa dynamique interne, ce qui assure l'efficacité et l'optimalité globale de la méthode proposée [115]. Le comportement du thermostat (3.10) avec ses conditions de commutation correspondantes est pris en compte pour la déduction de la fonction objectif.

Par conséquent, nous considérons des conditions logiques entre variables afin d'assurer l'identification d'un modèle interprétable et d'augmenter la fidélité du modèle. Les conditions logiques impliquent que certaines variables ne deviennent actives que si d'autres sont désactivées [116]. Ainsi, la non-séparabilité de la fonction objectif est maintenue afin d'éviter une estimation erronée des paramètres. Pour modéliser les conditions logiques (3.10), nous choisissons d'induire de la *sparsité* dans le modèle en utilisant des variables indicatrices [117], tout en veillant à ce que la formulation résultante de la fonction objectif reste traitable pour l'optimisation convexe.

Pour désagréger la sortie du régulateur (voir Fig. 3.7 comme illustration), considérons p, e et I comme étant respectivement les vecteurs des valeurs de sortie du régulateur, des valeurs d'erreur et des valeurs du terme intégrateur. Le vecteur d contient toutes les valeurs en régime permanent, et le vecteur a contient les mêmes valeurs que d mais décalées avec

un certain retard. De plus, les vecteurs w, v, x, et h contiennent respectivement les valeurs de saturation, les valeurs de l'intégrateur plus la dernière valeur enregistrée en régime permanent, l'action proportionnelle et les valeurs mises à jour de l'action de l'intégrateur aux instants post-saturation.

Cette désagrégation de la sortie du régulateur est prise en compte afin d'identifier les paramètres mis à jour du régulateur par l'approche S-SS proposée. Simultanément, nous découvrons la logique de mise à jour de l'action de l'intégrateur après saturation. Considérons un ensemble $Q \subseteq \{0,1\}^q$ et $(z_1, z_2, z_3) \in Q$ tel que

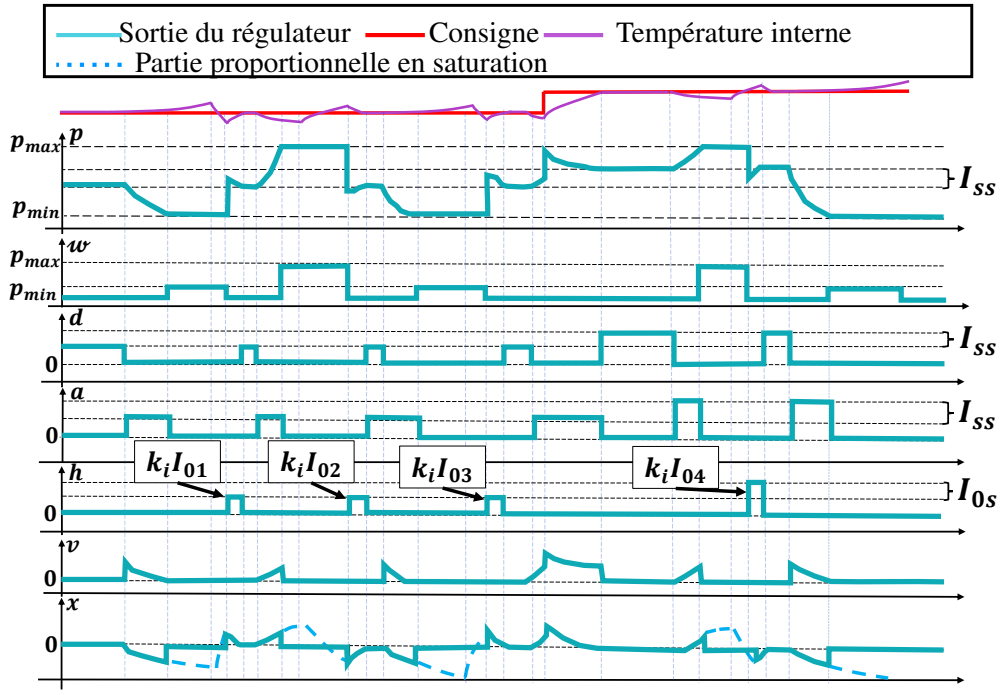


Figure 3.7 Sortie désagrégée du régulateur.

- $Z_{1Q} = \{(z_1, d, x, e, k_p) \in Q \times \mathbb{R}^{3q} \times \mathbb{R} \mid x = \bar{z}_1 k_p e, d_i (1 - z_{1i}) = 0, x_i (1 - \bar{z}_{1i}) = 0, \forall i \in [q]\}$
- $Z_{2Q} = \{(z_2, a, h, I, v, k_i) \in Q \times \mathbb{R}^{4q} \times \mathbb{R} \mid v = \bar{z}_2 k_i I + a, h_i (1 - z_{2i}) = 0, v_i (1 - \bar{z}_{2i}) = 0, \forall i \in [q]\}$
- $Z_{3Q} = \{(z_3, w, p) \in Q \times \mathbb{R}^{2q} \mid p_{\max} = z_3 p, w_i (1 - z_{3i}) = 0, \forall i \in [q]\}$

Alors, une fonction objectif convexe [118] $f : \mathbb{R} \to \mathbb{R}$ peut être écrite comme suit :

$$f(p_i, \hat{p}_i) = p_i - \hat{p}_i; \quad \forall i \in \{1, \dots q\}, \tag{3.24}$$

où $\hat{p} \in Z_{1Q} \cup Z_{2Q} \cup Z_{3Q}$ tel que $\hat{p} = w + v + x + h$. Dans les ensembles Z_{jQ}, les vecteurs z_j avec $j = \{1,2,3\}$ indiquent le comportement de la sortie du régulateur. Par exemple, dans Z_{1Q}, on a : $(x_i \neq 0) \Leftrightarrow (z_{1i} = 0 \quad \text{et} \quad \bar{z}_{1i} = 1) \Leftrightarrow (d_i = 0)$. En effet, lorsque la valeur de x est différente de 0, la variable d prend la valeur 0. Ainsi, avec le modèle linéaire *sparse* qui est deduit c.-à-d., $\hat{p}$, les paramètres du régulateur θ^* peuvent être estimés via un problème d'optimisation avec un ensemble donné de n observations parmi q (i.e., $\{p_i, \hat{p}_i\}_{i=1}^{n}$),

$$\begin{aligned} \theta^* &= \min_{h,k_p,k_i} \left\| \sum_{i=1}^{n} f(p_i, \hat{p}_i) \right\|_2 \\ \text{s.c. : } & s_i(1 - z_{1i}) = 0, h_i(1 - z_{2i}) = 0, w_i(1 - z_{3i}) = 0, \\ & (z_1, z_2, z_3) \in Q \subseteq \{0,1\}^q. \end{aligned} \tag{3.25}$$

Puisque les mesures de l'erreur et de la sortie du régulateur sont disponibles via les capteurs, lorsque (3.25) est considéré, les variables inconnues à estimer sont k_p, $k_i = (k_p/\tau_i)$ et la valeur mise à jour de l'intégrateur aux instants post-saturation. Elle est contenue dans la variable estimée h.

3.3 Prédiction du potentiel de réponse à la demande

Cette partie vise à : 1) Exploiter la disponibilité de données réelles mesurées à partir de thermostats communicants à tension secteur (*Line Voltage Communicating Thermostats*, LVCTs) qui contrôlent les températures à l'intérieur d'une maison, afin d'extraire les profils des *sous-charges* dans chaque pièce de la maison et de reconstruire le modèle

thermique complet de la maison. 2) Proposer un cadre de prédiction en temps réel de l'état (thermique) de la maison, où des modèles de prédiction des charges résiduelles sont utilisés pour ajuster l'état thermique et fournir une prédiction du potentiel de réponse à la demande (*Demand Response*, DR). Cela permettra une meilleure intégration des stratégies de contrôle.

La méthode de récupération des profils de charges résiduelles et d'établissement d'un modèle plus complet de la maison consiste à:

a) Considérer dans un premier temps un modèle de type réseau RC (modèle d'états ou de températures) qui ne prend pas en compte les charges résiduelles et, sur cette base, identifier ses paramètres. Conserver la même structure de modèle et définir un modèle de pseudo-états (pseudo-températures) avec les paramètres identifiés comme entrée. Le modèle repose sur des variables mesurées pour prédire les valeurs de pseudo-états.

b) Considérer un modèle de correction qui agit comme un observateur des charges résiduelles. Il prend comme entrée la différence entre les états mesurés et les pseudo-états.

c) Définir une fonction de distance entre les états mesurés et le modèle thermo-thermostatique de la maison (qui comprend le modèle du thermostat). Les consignes des thermostats et les sorties du modèle de correction servent d'entrées au modèle thermo-thermostatique.

d) Enfin, la fonction de distance est minimisée afin de retrouver les profils de charges résiduelles et les facteurs de pondération associés, permettant ainsi la reconstruction complète du modèle thermique de la maison.

Des modèles de prédiction pour les charges résiduelles estimées sont établis. Ils servent

à la prédiction en temps réel de l'état de la maison, où leurs sorties sont ajustées en continu à mesure que de nouvelles données sont acquises et que les valeurs des charges résiduelles sont estimées, ce qui aide à améliorer la prédictibilité de l'état thermique de la maison et de sa consommation énergétique. En outre, cela permet une prédiction du potentiel de réponse à la demande (*Demand Response*, DR). Une méthode basée sur une heuristique est proposée à cet effet. Elle repose sur une modulation du rapport cyclique afin d'identifier la flexibilité potentielle que la maison peut offrir. Des métriques d'évaluation de cette flexibilité sont également proposées. Contrairement aux études précédentes, nous avons non seulement construit un modèle compréhensible et interprétable, mais aussi fourni une méthode pour effectuer des prédictions à court terme des températures internes et des besoins de chauffage sans omettre les effets provoqués par les charges résiduelles non linéaires, qui intègrent possiblement les habitudes de consommation au niveau du ménage.

Ce cadre est important pour l'application d'un programme DR au niveau des ménages individuels, où la consommation d'électricité présente une forte variabilité en raison du comportement des usagers. Un ensemble d'études utilisant différentes techniques et visant à traiter ces problématiques en intégrant les habitudes des utilisateurs ont été menées [119–123]. Certaines d'entre elles ([119, 120]) ont abordé le problème en utilisant la mesure non intrusive des charges (NILM). Elles ont proposé des méthodes pour planifier l'utilisation d'appareils flexibles en fonction des habitudes des usagers, à partir des informations de consommation récupérées par NILM. Cependant, aucune des études ci-dessus n'a apporté d'éclairage sur la façon dont la demande de chauffage pourrait être affectée par les *sous-charges*, qui comptent parmi les principaux facteurs influençant les propriétés thermiques d'une maison. Notre méthode traite cette problématique en permettant la récupération des charges résiduelles (ou *sous-charges*) en se basant uniquement sur les mesures provenant des capteurs intégrés au thermostat. En ce sens,

elle promeut également une solution économique pour la mesure non intrusive des charges thermiques. Pour résumer, nous explorons dans cette section :

- Une approche de modélisation simple, fondée sur la physique, qui permet de retrouver la dynamique des charges résiduelles au cours du temps.
- Une approche économique pour la mesure non intrusive des charges thermiques (charges résiduelles ou *sous-charges*), car elle repose uniquement sur les données des capteurs intégrés aux thermostats préinstallés.
- Une prédiction précise des températures internes et des besoins de chauffage (au moins sur un horizon court).
- Un cadre qui évalue l'impact des charges résiduelles sur les besoins de chauffage au niveau résidentiel, ce qui est essentiel pour l'estimation du potentiel de réponse à la demande (notamment en temps réel).
- Un cadre d'implémentation d'un programme DR où la prédiction et l'évaluation du potentiel de réponse à la demande sont rendues possibles par la mesure et la prédiction non intrusive des *sous-charges* thermiques ou charges résiduelles.

Le travail est organisé comme suit : la section 3.3.1 présente la procédure de modélisation et d'identification ; la section 3.3.2 détaille le cadre d'implémentation d'un programme DR, en particulier la procédure de prédiction et d'évaluation du potentiel de réponse à la demande.

3.3.1 Modélisation et identification

Nous décrivons ici la structure du modèle RC et présentons les méthodes permettant d'identifier ses paramètres et de reconstituer les profils des charges résiduelles.

3.3.1.1 Structure du modèle RC

Le modèle RC est retenu ici parce qu'il établit le meilleur compromis entre *simplicité structurelle* et *précision* de modélisation : contrairement à un modèle purement « data-driven », il reste physiquement interprétable (chaque résistance et capacité a un sens thermique) et exige nettement moins de données d'entraînement, tout en demeurant suffisamment fidèle pour le contrôle. Le prix de cette simplicité est une capacité limitée à capturer les non-linéarités; c'est précisément ce que vient compenser la prise en compte explicite des charges résiduelles introduite à la section suivante. Ce positionnement (cf. tableau 2-2) justifie le choix d'un modèle RC enrichi plutôt que d'un modèle boîte noire ou d'un PiNN, plus coûteux et moins interprétables.

Un réseau RC est utilisé pour modéliser la dynamique thermique d'une maison, où chaque température d'une pièce donnée est considérée comme un nœud du réseau. Les nœuds sont régulés par des thermostats intelligents et sont interconnectés par des résistances et des capacités. En s'appuyant sur les travaux de [50, 58], la dynamique thermique d'un nœud spécifique n dans le réseau peut être décrite par l'équation différentielle ordinaire (EDO) suivante :

$$C_n \frac{dT_n}{d\mathtt{t}} = \frac{T_a - T_n}{R_{a,n}} + \left(\sum_{i \in \mathbb{I}_n} \frac{T_i - T_n}{R_{i,n}} \right) + \left(\sum_{j \in \mathbb{J}_n} F_j \phi_j \right) + \left(\sum_{m \in \mathbb{M}_n} G_m \phi_m^r \right) \tag{3.26}$$

Où T_n est la température du nœud n et C_n représente sa capacité thermique ; T_a correspond à la température ambiante, avec $R_{a,n}$ la résistance thermique entre l'extérieur et le nœud n ; T_i est la température du nœud i et $R_{i,n}$ désigne la résistance entre les nœuds n et i. Nous avons $\mathbb{I}_n \subset \{\mathbb{N}^* \setminus n\}$ et $\mathbb{J}_n, \mathbb{M}_n \subset \mathbb{N}^*$ correspondant respectivement aux ensembles d'indices des nœuds du réseau, des flux thermiques directs et des charges

résiduelles influençant le nœud n. Par $\mathbb{N}^*$ et $\{\mathbb{N}^* \setminus n\}$, nous désignons les ensembles de nombres naturels excluant zéro et excluant zéro et n, respectivement. Le flux thermique direct fourni par le j-ième chauffage et influençant le nœud n est noté ϕ_j avec un facteur de pondération F_j. Le flux thermique provenant de la m-ième charge résiduelle est noté ϕ_m^r avec un facteur de pondération G_m ; T_n est la sortie du nœud du réseau, tandis que T_a, ϕ_j et ϕ_m^r en sont les entrées. Les facteurs F_j et G_m sont sans dimension. Pour simplifier l'approche d'identification, une hypothèse est faite concernant la surface $[\mathrm{m}^2]$ exposée au rayonnement solaire $[\mathrm{W}/\mathrm{m}^2]$, de sorte que le flux thermique qui y est associé, $\phi_m^r = \text{surface area} \times \text{irradiance}$ soit exprimé en termes de puissance $[\mathrm{W}]$.

Considérons $\phi_n = \sum_{j\in\mathbb{J}_n} \phi_j$ et $\phi_n^r = \sum_{m\in\mathbb{M}_n} \phi_m^r$, représentant respectivement le flux thermique direct global (*Global Direct Heat Flux*, GDHF) et la charge résiduelle globale (*Global Residual Load*, GRL) agissant au nœud n. Ainsi, ils correspondent à l'agrégation des flux thermiques directs et des charges résiduelles agissant sur ce nœud. Nous définissons $F_n \neq \sum_{j\in\mathbb{J}_n} F_j$ et $G_n \neq \sum_{m\in\mathbb{M}_n} G_m$ comme les facteurs de pondération associés respectivement à ϕ_n et ϕ_n^r. Nous pouvons alors réécrire l'équation 3.26 de la manière suivante :

$$C_n \frac{dT_n}{d\mathtt{t}} = \frac{T_a - T_n}{R_{a,n}} + \left(\sum_{i\in\mathbb{I}_n} \frac{T_i - T_n}{R_{i,n}} \right) + F_n\phi_n + G_n\phi_n^r \tag{3.27}$$

Dans (3.27), C_n, $R_{a,n}$, $R_{i,n}$, F_n et G_n sont des paramètres incertains du modèle à identifier. En considérant un ensemble d'équations différentielles ordinaires (EDO), où chaque EDO exprime la dynamique thermique d'un nœud du réseau conformément à (3.27), nous définissons la dynamique thermique d'une maison à travers l'équation d'état linéaire suivante :

$$\dot{x} = A(\theta_1)x + B(\theta_2)u + C(\theta_3)T_a \tag{3.28}$$

Le vecteur d'état $x \in \mathbb{R}^{n_x \times 1}$ regroupe les températures nodales ; sa dérivée temporelle est notée $\dot{x}$. L'entrée du système (c.-à-d. la maison) est notée $u \in \mathbb{R}^{n_u \times 1}$ avec $u = \left[\bar{u}^T, u^{rT}\right]^T$; $A \in \mathbb{R}^{n_x \times n_x}$, $B \in \mathbb{R}^{n_x \times n_u}$ et $C \in \mathbb{R}^{n_x \times 1}$ sont respectivement les matrices d'état et d'entrée constituées par les paramètres du modèle, à savoir : les C_n, $R_{a,n}$, $R_{i,n}$, F_n et G_n. Plus explicitement, θ_1, θ_2 et θ_3 sont des vecteurs de paramètres qui définissent respectivement A, B et C. Avec θ_1, θ_2 et θ_3 respectivement constitués des ensembles de paramètres $\{C_n\text{'s}, R_{a,n}\text{'s}, R_{i,n}\text{'s}\}$, $\{F_n\text{'s}, G_n\text{'s}, C_n\text{'s}\}$ et $\{C_n\text{'s}, R_{a,n}\text{'s}\}$.

Nous notons $\bar{u} \in \mathbb{R}^{n_x \times 1}$ et $u^r \in \mathbb{R}^{n_x \times 1}$ les vecteurs d'entrées liés respectivement au flux thermique direct global (GDHF) et aux charges résiduelles globales (GRLs). Dans le cas où les effets des GRLs sont négligeables, absents ou non pris en compte, nous considérons, à la place de (3.28), l'équation d'état suivante :

$$\dot{\bar{x}} = A(\theta_1)\bar{x} + \bar{B}(\bar{\theta}_2)\bar{u} + C(\theta_3)T_a \tag{3.29}$$

Où $\bar{x} \in \mathbb{R}^{n_x \times 1}$ est un vecteur d'état regroupant les températures nodales lorsque le système est exempt des effets des GRLs, avec sa dérivée temporelle notée $\dot{\bar{x}}$. Le vecteur $\bar{\theta}_2$ contient les paramètres constituant la matrice $\bar{B} \in \mathbb{R}^{n_x \times n_x}$. Avec $\bar{\theta}_2$ constitué par l'ensemble des paramètres $\{F_n's, C_n's\}$

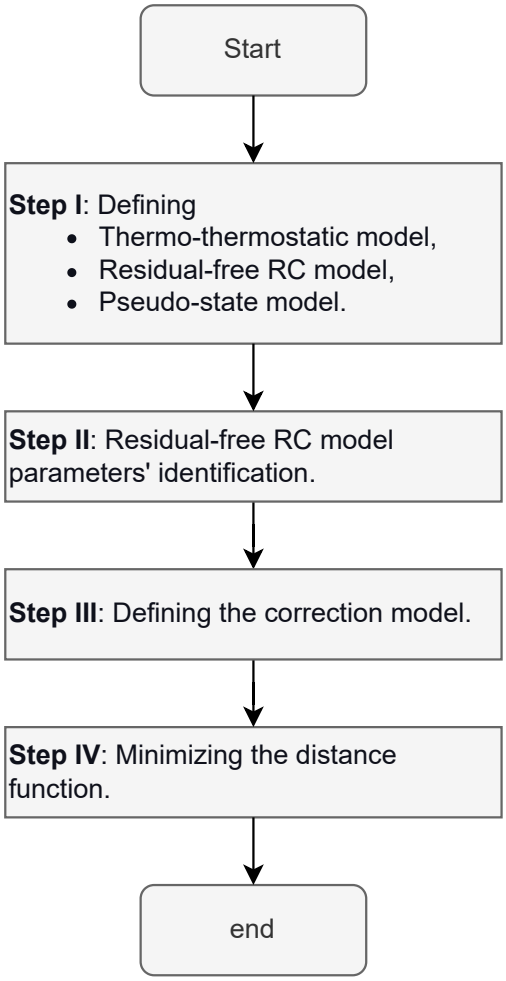


Figure 3.8 Procédure d'identification.

3.3.1.2 Identification des paramètres du modèle et reconstitution des profils de charges résiduelles

La modélisation des charges résiduelles constitue l'une des contributions distinctives de ce chapitre. Leur rôle est double : sur le plan de la précision, elles absorbent la part de la dynamique thermique (gains des occupants, ensoleillement, pertes) que le modèle

RC seul ne peut expliquer, évitant ainsi de la confondre avec un bruit blanc ; sur le plan de la réponse à la demande, leur estimation et leur prédiction en temps réel conditionnent directement la qualité de la prédiction du potentiel DR et donc la pertinence des consignes générées. C'est cette valorisation explicite des charges résiduelles, positives et négatives, qui distingue l'approche proposée des méthodes NITLM classiques (cf. tableau 2-3).

La procédure d'identification des paramètres du modèle de la maison et de la reconstitution des profils de charges résiduelles s'effectue en quatre étapes principales, comme illustré à la Fig. 3.8. Les détails de chaque étape sont donnés ci-dessous :

Étape I : Considérons le vecteur de paramètres qui définit les matrices A, B et C de (3.28) comme étant θ et le vecteur de paramètres qui définit les matrices A, $\bar{B}$ et C de (3.29) comme étant $\bar{\theta}$. Typiquement, θ et $\bar{\theta}$ sont formés par les ensembles $\{C_n's, R_{a,n}'s, R_{i,n}'s, F_n's, G_n's\}$ et $\{C_n's, R_{a,n}'s, R_{i,n}'s, F_n's\}$ respectivement . Nous obtenons la version en temps discret de l'équation (3.28) en utilisant la méthode de discrétisation d'Euler avec un pas d'échantillonnage Δt. En utilisant cette version discrète et étant donné le modèle du thermostat décrit dans la référence [13], nous déduisons le modèle d'état en temps discret de la maison (modèle thermo-thermostatique de la maison) comme suit :

$$\bar{u}_t = C_d\left(x_t, \xi_t, D_t\right) \tag{3.30a}$$

$$u_t = Concat\left(\bar{u}_t, u_t^r\right) \tag{3.30b}$$

$$x_{t+1} = f_d\left(x_t, u_t, T_{a,t}, \theta\right) \tag{3.30c}$$

$$y_t = h_d\left(x_t, \kappa_t\right) \tag{3.30d}$$

L'équation (3.30a) correspond à la fonction des thermostats $C_d(\cdot)$, dont les entrées sont l'état (températures) et le vecteur de consignes de température, x_t et ξ_t, respectivement ; $D_t \in \mathbb{R}^{n_x \times 1}$ est aussi une entrée de l'équation (3.30a) et correspond au vecteur des rapports cycliques, par défaut $D_t = D_{max}\ \forall t$ (avec $D_{max,1} = \cdots D_{max,n_x} = 100\%$). Nous avons, $\xi_t \in \mathbb{R}^{n_x \times 1}$ et il est supposé que $\xi_{t,n} = \xi_{t,j}, \forall j \in \mathbb{J}_n$, $\forall n \in \{1, \cdots n_x\}$ ($\mathbb{J}_n \subset \mathbb{N}^*$, ensemble des indices du flux thermique direct). L'équation (3.30b) représente la concaténation des vecteurs $\bar{u}_t$ et u_t^r pour obtenir le vecteur d'entrée u_t. Dans (3.30c), $f_d(\cdot)$ est la fonction d'état. L'équation (3.30d) exprime la fonction de mesure $h_d(\cdot)$, où y_t correspond à l'état bruité mesuré et κ_t est un bruit de mésurage inconnu. L'état bruité mesuré, $\bar{y}_t$, lorsque les effets des charges résiduelles globales sont négligeables ou absents (correspond à *residual-free RC model* ou modèle RC sans résiduel), est donné par les relations suivantes :

$$\bar{x}_{t+1} = f_d\left(\bar{x}_t, \bar{u}_t, T_{a,t}, \bar{\theta}\right) \tag{3.31a}$$

$$\bar{y}_t \quad = h_d\left(\bar{x}_t, \kappa_t\right) \tag{3.31b}$$

Lorsque les effets des charges résiduelles globales ne sont pas pris en compte (qu'elles existent, soient négligeables ou absentes), nous considérons un pseudo-vecteur d'état $\tilde{\bar{x}}_t$ (correspondant à *pseudo-state model*) dont la dynamique est donnée par la relation suivante :

$$\tilde{\bar{x}}_{t+1} = f_d\left(\tilde{\bar{x}}_t, \bar{u}_t^m, T_{a,t}^m, \bar{\theta}\right) \tag{3.32}$$

Nous notons par $\bar{u}_t^m$ et $T_{a,t}^m$, respectivement, le vecteur des charges de chauffage observées

et la valeur de la température ambiante.

Étape II : Nous identifions ici les paramètres du modèle RC sans résiduel (*Residual-free RC model*). Supposons maintenant qu'il existe S séquences de périodes $[\underline{T}_{\mathrm{s}}, \overline{T}_{\mathrm{s}}]$ dans une période $[0, T]$ où les effets des charges résiduelles globales sont négligeables ou absents, alors, suivant (3.31), on a : $\bar{y}_t \approx y_t$. De même, pour le vecteur des états observés (températures), nous avons $\bar{y}_t^m \approx y_t^m$. Nous pouvons considérer :

$$\bar{y}_{\underline{T}_{\mathrm{s}}:\overline{T}_{\mathrm{s}}} \triangleq \bar{y}_{\underline{T}_{\mathrm{s}}:\overline{T}_{\mathrm{s}}}(\bar{\theta}) \quad \text{pour} \quad \mathrm{s} = 1, 2, \ldots, S \tag{3.33}$$

Où les éléments du vecteur $\bar{\theta}$ sont supposés constants et prennent leurs valeurs dans un ensemble admissible Θ tel que $\bar{\theta} \in \Theta \subset \mathbb{R}^{n_{\bar{\theta}} \times 1}$. Nous cherchons à trouver $\bar{\theta}^*$, qui minimise une fonction de dissimilarité $\Gamma(\cdot)$ entre les sorties mesurées du système réel $\bar{y}^m_{\underline{T}_{\mathrm{s}}:\overline{T}_{\mathrm{s}}}$ et les sorties $\bar{y}_{\underline{T}_{\mathrm{s}}:\overline{T}_{\mathrm{s}}}(\bar{\theta})$ du modèle (3.31). En minimisant la fonction coût de calibration (somme des erreurs quadratiques), qui correspond à la somme de toutes les fonctions de dissimilarité S, on a :

$$\bar{\theta}^* = \underset{\bar{\theta} \in \Theta}{\arg\min} \sum_{\mathrm{s}=1}^{S} \Gamma \left(\bar{y}^m_{\underline{T}_{\mathrm{s}}:\overline{T}_{\mathrm{s}}}, \bar{y}_{\underline{T}_{\mathrm{s}}:\overline{T}_{\mathrm{s}}}(\bar{\theta}) \right) \tag{3.34}$$

Étape III : Le vecteur de paramètres (θ) du modèle thermo-thermostatique de la maison (3.30) peut alors s'écrire $\theta = [\bar{\theta}^*, G_1 \cdots G_{n_x}]$, où $G_1 \cdots G_{n_x}$ sont des coefficients de pondération des charges résiduelles globales. Ces charges ne sont pas observables et doivent être reconstruites via un observateur dédié (modèle de correction ou *correction model*) défini comme suit :

$$\tilde{e}_{t+1} = y^m_{t+1} - \tilde{\bar{x}}_{t+1} \tag{3.35a}$$

$$\tilde{u}^r_t \quad = g_d\left(\tilde{e}_{t+1}, \tilde{e}_t, \tilde{\theta}\right) \tag{3.35b}$$

Où $\tilde{e}_t$ est la différence entre l'état bruité observé du système réel, c.-à-d. y^m_t, et le vecteur de pseudo-état, c.-à-d. $\tilde{\bar{x}}_t$ (3.32). Nous avons $\tilde{u}^r_t$ correspondant au vecteur estimé des charges résiduelles globales. Nous notons par $\tilde{\theta} = [\theta^*_1, G_1 \cdots G_{n_x}]$ un vecteur de paramètres résultant de l'opération de soustraction entre l'expression de $\tilde{\bar{x}}_{t+1}$ (équation 3.32 avec $\bar{\theta} \leftarrow \bar{\theta}^*$) et une expression de y^m_{t+1}. En effet, nous pouvons exprimer y^m_{t+1} à travers la fonction $f_d(\cdot)$ tel que

$$y^m_{t+1} := f_d\left(y^m_t, u^m_t, T^m_{a,t}, \theta\right),$$

avec $u^m_t := \left[\bar{u}^{mT}_t, u^{rT}_t\right]^T$. Ceci suggère que l'opération de soustraction entre l'expression de y^m_{t+1} et celle de $\tilde{\bar{x}}_{t+1}$ conduit à l'annulation des termes $\bar{u}^m_t$ et $T^m_{a,t}$, ainsi que des paramètres $F^{*\prime}_n s$ associés à $\bar{u}^m_t$. Par conséquent, les paramètres restants non annulés forment un vecteur réduit de paramètres $\tilde{\theta}$, qui consiste en l'ensemble $\{C^{*\prime}_n s, R^{*}_{a,n}{}^{\prime} s, R^{*}_{t,n}{}^{\prime} s, G_n{}^{\prime} s\}$. À partir de cette opération de soustraction, nous pourrions facilement déduire l'expression de $\tilde{u}^r_t$ définie par la fonction $g_d(\cdot)$. Étant donné que les paramètres de l'ensemble constituant $\tilde{\theta}$ sont non nuls, cela constitue une condition nécessaire et suffisante pour que la fonction « inverse » $g_d(\cdot)$ soit mathématiquement valide. À partir de $\bar{u}^m_t$, $T^m_{a,t}$ et $\bar{\theta}^*$, les valeurs de $\tilde{\bar{x}}_{t+1}$ peuvent être calculées à l'aide de (3.32). Étant donné la disponibilité des valeurs observées y^m_{t+1} et du vecteur des paramètres estimés $\theta^*_1 = \bar{\theta}^* \setminus \{F^{*\prime}_n s\}$, nous pouvons retrouver, à travers le modèle de correction dans (3.35) et sur une période de temps $[0, T]$, les valeurs estimées du vecteur des charges résiduelles globales $\tilde{u}^r_t$. Toutefois, une estimation de $\{G_n{}^{\prime} s\}$ afin d'obtenir les meilleures estimations $\{G^{*\prime}_n s\}$ est indispensable et

est présentée à l'étape suivante. Dans la suite, il sera considéré pour simplification :

$$u_t := \left[\bar{u}_t^T, \tilde{u}_t^{rT}\right]^T \equiv \left[\bar{u}_t^T, u_t^{rT}\right]^T. \tag{3.36}$$

Avec $\tilde{u}_t^r$ le vecteur estimé des charges résiduelles globales, considéré équivalent au vecteur réel, c'est-à-dire u_t^r. Nous noterons également $\hat{u}_t^r$ comme un vecteur prédit des charges résiduelles.

Étape IV : En considérant $G \in \Theta_G \subset \mathbb{R}^{n_x \times 1}$, nous cherchons maintenant à trouver la meilleure estimation G^*. Elle peut être obtenue en minimisant une fonction coût de calibration (*distance function*) $\Gamma\left(y_{0:T}^m, y_{0:T}(\bar{\theta}^*, G)\right)$, où $y_{0:T}(\bar{\theta}^*, G)$ est considéré comme les sorties mesurées du modèle thermo-thermostatique (3.30) sur une période $[0, T]$. Les valeurs du vecteur des consignes, i.e. ξ_t, sur cette période sont supposées connues. Ainsi, G est donné par :

$$G^* = \underset{G \in \Theta_G}{\arg\min} \Gamma\left(y_{0:T}^m, y_{0:T}(\bar{\theta}^*, G)\right) \text{ s.c : Équation 3.35,} \tag{3.37}$$

On obtient alors $\theta^* = [\bar{\theta}^*, G_1^* \cdots G_{n_x}^*]$. En parallèle, nous avons reconstitué les profils de charges résiduelles. Pour son efficacité à trouver des optima globaux de fonctions coûteuses à évaluer, nous utilisons l'optimisation Bayésienne (BO) pour résoudre 3.34 et 3.37 via la fonction d'acquisition *Expected Improvement* (EI) [124], étant donnée une définition appropriée des ensembles de bornes supérieures et inférieures sur les paramètres (soit Θ et Θ_G). Le choix de l'optimisation Bayésienne est essentiellement justifié par la nature du modèle dans 5, ce qui conduit à un problème d'optimisation non convexe. Il est connu que de tels problèmes sont plus facilement traités avec l'optimisation Bayésienne

qu'avec les méthodes classiques basées sur le gradient, comme mentionné dans [124]. On peut aussi rappeler la nature exploratoire de l'optimisation Bayésienne tel que nous l'avons mentionné plus haut [109].

En résumé, nous estimons d'abord $\bar{\theta}^*$, qui correspond à un vecteur contenant les paramètres du système lorsque les effets des charges résiduelles sont négligeables ou absents (3.31). Ensuite, nous nous appuyons sur un observateur défini en 3.35 et utilisons $\bar{\theta}^*$ comme information a priori pour résoudre le problème d'optimisation défini en 3.37. Nous obtenons alors $G^* = [G_1^* \cdots G_{n_x}^*]$ tout en réconstituant les profils de charges résiduelles globales sur la période $[0:T]$: $\tilde{u}_{0:T}^r = \left[\tilde{\phi}_{1,0:T}^r, \tilde{\phi}_{2,0:T}^r, \cdots \tilde{\phi}_{n_x,0:T}^r\right]^T$.

3.3.2 Procédure de prédiction du potentiel de réponse à la demande

La procédure décrite ci-dessous s'inscrit dans un cadre de type contrôle prédictif : les modèles identifiés aux étapes précédentes (thermostats, modèle RC, modèle de charges résiduelles) ne sont pas exploités isolément mais alimentent directement la formulation du problème d'optimisation prédictif. Le modèle thermo-thermostatique fournit la dynamique interne (contrainte d'état), le modèle de charges résiduelles fournit les perturbations prédites, et l'horizon de prédiction est glissé dans le temps. Cette articulation explicite assure l'enchaînement cohérent *identification* $\rightarrow$ *estimation* $\rightarrow$ *contrôle* qui structure la thèse.

Avant de présenter la procédure, il est nécessaire de définir un modèle pour prédire les charges résiduelles globales (GRLs). Le choix s'est porté sur un modèle autorégressif (AR) en raison de sa simplicité. Il convient de noter que, bien que cette étude ne se concentre pas explicitement sur le développement d'un modèle prédictif pour les charges résiduelles globales, le choix du modèle AR est suffisant pour évaluer l'impact de la prise

en compte de ces charges sur la prédiction de la température et de la consommation d'énergie (ou de puissance) dans un bâtiment résidentiel. Le modèle de prédiction autorégressif est défini comme suit :

$$\hat{u}_t^r = F\left(\hat{\mathbf{u}}_t^r, \theta^r\right) \tag{3.38a}$$

$$\hat{\mathbf{u}}_{t+1}^r = \mu\left(\hat{\mathbf{u}}_t^r, \hat{u}_t^r\right) \tag{3.38b}$$

Où $\hat{u}_t^r \in \mathbb{R}^{n_x \times 1}$ correspond à une valeur prédite du vecteur des charges résiduelles via la fonction $F(\cdot)$; $\hat{\mathbf{u}}_t^r = \hat{u}_{t-p:t-1}^r$ contient les p valeurs du vecteur prédit de charges résiduelles, le modèle AR étant d'ordre p. De plus, θ^r contient les paramètres du modèle. La fonction $\mu(\cdot)$ met à jour $\hat{\mathbf{u}}_t^r$ avec le vecteur prédit $\hat{u}_t^r$.

La procédure de prédiction consiste à utiliser les modèles définis en (3.30), (3.32) et (3.35) conjointement avec le modèle prédictif des GRLs basé sur les équations (3.38) pour suivre l'évolution des températures, de la demande de chauffage et évaluer le potentiel de réponse à la demande (DR) au sein de la maison. Nous supposerons que le potentiel DR fait référence à la flexibilité potentielle que la maison peut offrir, tandis que la flexibilité désignera la flexibilité effective de la maison lorsque des actions de contrôle optimales sont appliquées dans un contexte de DR. Le cadre d'implémentation d'un programme DR proposé, qui contient la procédure de prédiction du potentiel DR, est illustré à la Fig. 3.9. L'étape de coordination est en dehors du champ de la présente étude. Une explication de chaque étape est donnée ci-dessous :

Étape 1 : Le cadre repose sur un contrôleur prédictif . Définissons d'abord un horizon de prédiction N, un horizon de contrôle (ou de mise à jour) N_c ($N_c \leq N$), et un pas de

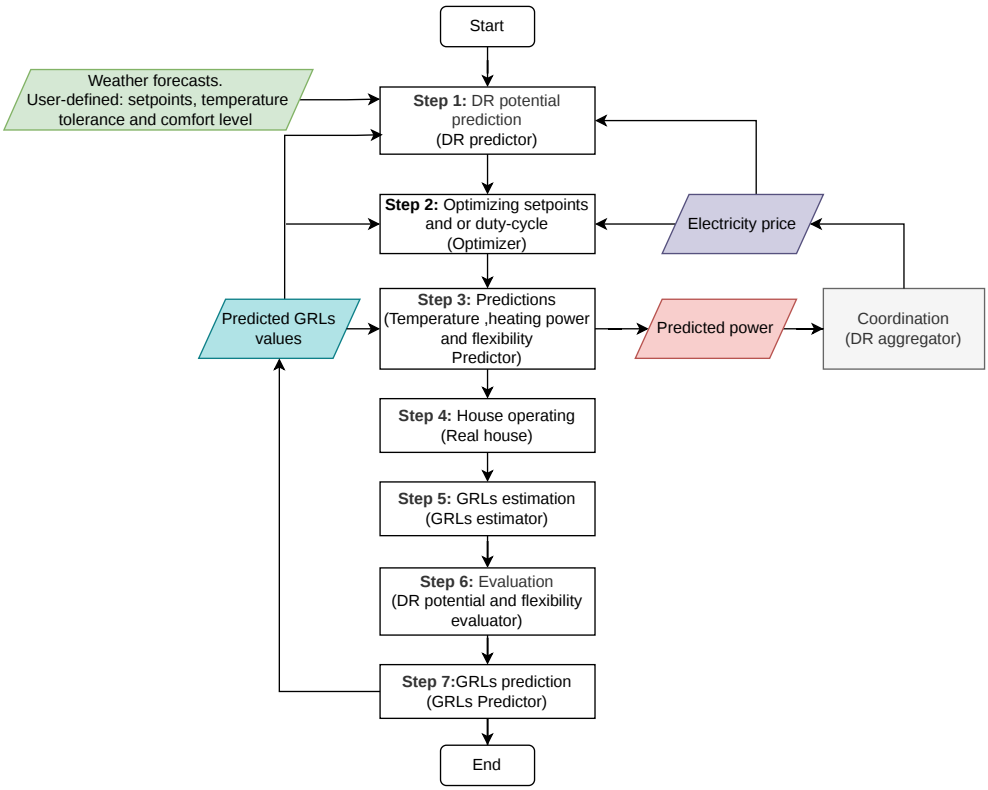


Figure 3.9 Cadre d'implémentation d'un programme DR.

prédiction k. Nous considérons $N_c = N$. Le choix $N_c = N$ (horizon de contrôle égal à l'horizon de prédiction) signifie que l'ensemble du plan de consignes calculé sur l'horizon de prédiction est appliqué avant toute remise à jour. Ce choix est retenu ici pour deux raisons : il réduit la charge de calcul (une seule optimisation par fenêtre plutôt qu'une résolution glissée à chaque pas), et il s'accorde avec la dynamique thermique lente du bâtiment, pour laquelle un réajustement à chaque pas n'apporte qu'un gain marginal. Le cadre reste néanmoins valable pour $N_c < N$ (contrôle à horizon glissant), au prix d'un coût de calcul accru. L'*étape 1* est subdivisée en plusieurs sous-étapes ;

Étape 1.1 : Nous utilisons une heuristique simple pour prédire le potentiel DR. L'approche étudiée repose sur l'ajustement du rapport cyclique. Ainsi, la prédiction du

potentiel DR consiste à prédire les températures et demandes de chauffage possibles, respectivement $\hat{y}_t^p$ et $\hat{\bar{u}}_t^p$, pouvant mener à une consommation économique et respectueuse du confort lors d'un événement DR. Ensuite, des métriques dédiées sont utilisées pour évaluer le potentiel DR. Ces températures et demandes de chauffage possibles sont obtenues à l'aide de la modulation du rapport cyclique sur la base d'une heuristique.

Supposons que l'utilisateur choisisse une plage de tolérance de température $\pm\delta y$ et un facteur de confort φ. Selon la valeur du facteur de confort (φ), nous définissons la plage de tolérance de température effective comme suit :

$$\pm\Delta y = \pm\frac{\delta y}{\sqrt{\varphi}}$$

Ainsi, un besoin élevé de confort implique $\varphi \approx 1 \Rightarrow \Delta y \approx \delta y$. On suppose également que la séquence de prix de l'électricité sur l'horizon de contrôle, c'est-à-dire $\bar{\pi}_{kN_c} \cdots \bar{\pi}_{(k+1)N_c-1}$, est connue (avec $\bar{\pi}_t \in \mathbb{R}^{1\times n_x}$ et $\bar{\pi}_{t,1} = \cdots = \bar{\pi}_{t,n_x}$). Nous considérons $\bar{\pi}_{min} \in \mathbb{R}^{1\times n_x}$ ($\bar{\pi}_{min,1} = \cdots = \bar{\pi}_{min,n_x}$) comme la valeur de prix bas et $r_t \in \mathbb{R}^{n_x\times 1}$ comme la consigne de température définie par l'utilisateur (ou consigne de référence). Définissons maintenant quelques conditions comme suit :

$$\begin{aligned}
C_{1,t,n} &= \mathbf{1}_{\left\{r_{t,n}-\Delta y \le \hat{y}^p_{t,n} \le r_{t,n}+\Delta y \wedge \bar{\pi}_{t,n} > \bar{\pi}_{\min,n}\right\}} \\
C_{2,t,n} &= \mathbf{1}_{\left\{r_{t,n}-\Delta y \le \hat{y}^p_{t,n} \le r_{t,n}+\Delta y \wedge \bar{\pi}_{t,n} = \bar{\pi}_{\min,n}\right\}} \\
C_{3,t,n} &= \mathbf{1}_{\left\{\hat{y}^p_{t,n} < r_{t,n}-\Delta y\right\}} \\
C_{4,t,n} &= \mathbf{1}_{\left\{\hat{y}^p_{t,n} > r_{t,n}+\Delta y\right\}}
\end{aligned} \tag{3.39}$$

Nous définissons aussi :

$$B_{t,n} = D_{\min,n} \times C_{1,t,n} + D_{\max,n} \times C_{2,t,n} + D_{\max,n} \times C_{3,t,n} + D_{\min,n} \times C_{4,t,n} \tag{3.40}$$

Cela signifie que $B_{t,n}$ prend les valeurs $D_{min,n}$ ou $D_{max,n}$ selon que la condition $C_{1,t,n}$ ou $C_{3,t,n}$, respectivement $C_{2,t,n}$ ou $C_{4,t,n}$, est réalisée. Ici, $D_{min,n}$ et $D_{max,n}$ représentent respectivement les valeurs minimale et maximale du rapport cyclique pour le thermostat n (correspondant au noeud n). Les conditions $C_{1,t,n}$, $C_{2,t,n}$, $C_{3,t,n}$ et $C_{4,t,n}$ signifient respectivement : nous sommes dans un événement DR et la température intérieure au noeud n est dans la limite de tolérance définie par l'utilisateur, nous ne sommes pas dans un événement DR et la température intérieure au noeud n est dans la limite de tolérance, la température intérieure au noeud n est en dessous de la borne inférieure de tolérance, la température intérieure au noeud n est au-dessus de la borne supérieure de tolérance. Nous considérerons $B_t = [B_{t,1}, \cdots B_{t,n_x}]^T$, $D_{\min} = [D_{\min,1}, \cdots, D_{\min,n_x}]^T$ et $D_{\max} = [D_{\max,1}, \cdots, D_{\max,n_x}]^T$. Les éléments de chacun des vecteurs $D_{\min}$ et $D_{\max}$ sont supposés égaux.

Étant donné une prédiction des charges résiduelles globales ($\hat{u}_t^r$) et de la température ambiante ($\hat{T}_{a,t}$), nous pouvons définir l'heuristique pour la prédiction du potentiel DR comme suit ($t \in \mathbb{N}_{kN_c}^{(k+1)N_c-1}$):

$$
\begin{aligned}
D_t^p &= B_t \\
\hat{\tilde{u}}_t^p &= C_d\left(\hat{x}_t^p, r_t, D_t^p\right) \\
\hat{u}_t^p &= Concat\left(\hat{\tilde{u}}^p, \hat{u}_t^r\right) \\
\hat{x}_{t+1}^p &= f_d\left(\hat{x}_t^p, \hat{u}_t^p, \hat{T}_{a,t}, \theta^*\right) \\
\hat{y}_t^p &= h_d(\hat{x}_t^p, \kappa_t)
\end{aligned}
\tag{3.41}
$$

Étape 1.2 : Étant donné une prédiction des charges résiduelles globales ($\hat{u}_t^r$), de la température ambiante prédite ($\hat{T}_{a,t}$) et une séquence de consignes de température de référence définies par l'utilisateur (r_t), nous prédisons les températures et demandes de chauffage de référence respectivement $\hat{y}_t^{ref}$ et $\hat{\tilde{u}}_t^{ref}$ en nous appuyant sur l'équation 3.30, avec $\xi_t \leftarrow r_t$, $D_t \leftarrow D_{max}$, $u_t^r \leftarrow \hat{u}_t^r$, $T_{a,t} \leftarrow \hat{T}_{a,t}$, $\theta \leftarrow \theta^*$, $\kappa_t \leftarrow 0$ et $t \in \mathbb{N}_{kN_c}^{(k+1)N_c-1}$.

Étape 1.3 : Avec $\hat{y}_t^p$, $\hat{\tilde{u}}_t^p$ obtenus de l'*étape 1.1* et $\hat{y}_t^{ref}$, $\hat{\tilde{u}}_t^{ref}$ obtenus de l'*étape 1.2*, nous pouvons évaluer le potentiel DR à l'aide de certaines métriques. Pour cela, nous définissons : R_t : consigne de température moyenne de référence, $\hat{\bar{Y}}_t^p$: température moyenne potentielle prédite, $\hat{\bar{Y}}_t^{ref}$: température moyenne de référence prédite, $\hat{\bar{U}}_t^p$: demande de chauffage potentielle prédite (agrégée), $\hat{\bar{U}}_t^{ref}$: demande de chauffage de référence prédite (agrégée). Nous considérons aussi $\hat{\bar{E}}_t^p = R_t - \hat{\bar{Y}}_t^p$ et $\hat{\bar{E}}_t^{ref} = R_t - \hat{\bar{Y}}_t^{ref}$ $(t \in \mathbb{N}_{kN_c}^{(k+1)N_c-1})$.

Les facteurs d'intérêt pour évaluer le potentiel DR sont principalement le ratio potentiel de réduction d'énergie prédit (*Energy Reduction Ratio*, ERR prédit) pendant l'événement DR ($\hat{\gamma}_t^p$) et l'efficacité potentielle de confort prédite (*Comfort Efficiency*, CE prédite) ($\hat{\eta}_t^p$). Inspirés de [52, 125], nous proposons leurs définitions comme suit :

$$\hat{\gamma}_t^p = \begin{cases} \max\left(\frac{\hat{U}_t^{ref} - \hat{U}_t^p}{\max\left(\hat{U}_t^{ref}, \varepsilon\right)}, 0\right) & \text{si } \bar{\pi}_t > \bar{\pi}_{\min} \\ 0 & \text{sinon.} \end{cases} \tag{3.42}$$

$$\hat{\eta}_t^p = \left(\frac{\exp\left(\frac{\left|\hat{E}_t^{ref}\right| - \max\left(\left|\hat{E}_t^p\right|, \varepsilon\right)}{\max\left(\left|\hat{E}_t^{ref}\right|, \varepsilon\right)} \right)}{\exp(1)} \right) \times 100. \tag{3.43}$$

avec $0 < \varepsilon \ll 10^{-2}$ une petite valeur strictement positive. Il est à considérer: $\bar{\pi}_t > \bar{\pi}_{\min} \equiv \bar{\pi}_{t,n} > \bar{\pi}_{\min,n}\ \forall n$ (3.42), $n = 1 \cdots n_x$.

Étape 2 : À ce stade, l'optimiseur produit les séquences optimales de consignes $\xi_{kN_c}^* \cdots \xi_{(k+1)N_c-1}^*$ et de rapport cycliques $D_{kN_c}^* \cdots D_{(k+1)N_c-1}^*$ à appliquer aux thermostats de la maison. Nous pouvons distinguer cinq cas possibles :

1. rapport cyclique potentiel (issu de l'heuristique en *Étape 1*) considéré comme optimal : $D_t^* \leftarrow D_t^p \Rightarrow \xi_t^* \leftarrow r_t, \forall t \in \mathbb{N}_{kN_c}^{(k+1)N_c-1}$.
2. Détermination d'une consigne optimale ou d'un rapport cyclique optimal via une fonction objectif dédiée : $\{\xi_t^*\}_{t=kN_c}^{(k+1)N_c} \leftarrow \min \sum_{t=kN_c}^{(k+1)N_c} \rho(\xi_t, D_t)$, $st : \mathbb{C}_t \Rightarrow D_t^* \leftarrow D_{max} \forall t \in \mathbb{N}_{kN_c}^{(k+1)N_c-1}$ ou $\{D_t^*\}_{t=kN_c}^{(k+1)N_c} \leftarrow \min \sum_{t=kN_c}^{(k+1)N_c} \rho(\xi_t, D_t)$, $st : \mathbb{C}_t \Rightarrow \xi_t^* \leftarrow r_t, \forall t \in \mathbb{N}_{kN_c}^{(k+1)N_c-1}$
3. Détermination conjointe de la consigne optimale et du rapport cyclique : $\{\xi_t^*, D_t^*\}_{t=kN_c}^{(k+1)N_c} \leftarrow \min \sum_{t=kN_c}^{(k+1)N_c} \rho(\xi_t, D_t)$, $st : \mathbb{C}_t$
4. Faire correspondre la puissance potentiellement optimale ($\hat{u}_t^p \sim \hat{u}_t^*$) à des consignes

ou des rapport cycliques, par inversion, via une fonction objectif dédiée : $\{\xi_t^*\}_{t=kN_c}^{(k+1)N_c} \leftarrow \min \sum_{t=kN_c}^{(k+1)N_c} \rho(\bar{u}_t, \hat{\bar{u}}_t^*)$, $st : \mathbb{C}_t \Rightarrow D_t^* \leftarrow D_{max} \forall t \in \mathbb{N}_{kN_c}^{(k+1)N_c-1}$ ou $\{D_t^*\}_{t=kN_c}^{(k+1)N_c} \leftarrow \min \sum_{t=kN_c}^{(k+1)N_c} \rho(\bar{u}_t, \hat{\bar{u}}_t^*)$, $st : \mathbb{C}_t \Rightarrow \xi_t^* \leftarrow r_t, \forall t \in \mathbb{N}_{kN_c}^{(k+1)N_c-1}$

5. Faire correspondre de la puissance potentiellement optimale ($\hat{\bar{u}}_t^p \sim \hat{\bar{u}}_t^*$) à des consignes et rapports cycliques, par inversion, via une fonction objectif dédiée : $\{\xi_t^*, D_t^*\}_{t=kN_c}^{(k+1)N_c} \leftarrow \min \sum_{t=kN_c}^{(k+1)N_c} \rho(\bar{u}_t, \hat{\bar{u}}_t^*)$ $st : \mathbb{C}_t$

Où $\mathbb{C}_t$ désigne l'ensemble des contraintes. Les valeurs $\hat{\bar{u}}_t^p$ et D_t^p proviennent de l'*Étape 1* et r_t est la consigne de température définie par l'utilisateur ($t \in \mathbb{N}_{kN_c}^{(k+1)N_c-1}$).

Étape 3 : En utilisant les charges résiduelles globales prédites ($\hat{u}_t^r$), la température ambiante prédite ($\hat{T}_{a,t}$) et les consignes et rapports cycliques optimaux i.e. ξ_t^* et D_t^* issus de l'*Étape 2*, nous obtenons les prédictions des températures de la maison ($\hat{y}_t$) et de la puissance de chauffage ($\hat{\bar{u}}_t$). Les prédictions sont obtenues via l'équation 3.30, avec $\xi_t \leftarrow \xi_t^*$, $D_t \leftarrow D_t^*$, $u_t^r \leftarrow \hat{u}_t^r$, $T_{a,t} \leftarrow \hat{T}_{a,t}$, $\theta \leftarrow \theta^*$, $\kappa_t \leftarrow 0$ et $t \in \mathbb{N}_{kN_c}^{(k+1)N_c-1}$.

Soient $\hat{\bar{Y}}_t$ et $\hat{\bar{U}}_t$ respectivement la température moyenne prédite et la demande de chauffage agrégée de la maison. Nous notons $\hat{\bar{E}}_t = R_t - \hat{\bar{Y}}_t$ l'écart entre la température moyenne prédite et la consigne moyenne. En remplaçant $\hat{\bar{Y}}_t^p$ par $\hat{\bar{Y}}_t$ dans l'équation (3.42) et $\hat{\bar{E}}_t^p$ par $\hat{\bar{E}}_t$ dans l'équation (3.43), nous obtenons $\hat{\gamma}_t$ et $\hat{\eta}_t$, respectivement le ratio de réduction d'énergie prédit et l'efficacité de confort prédite.

La demande de chauffage prédite (agrégée),$\hat{\bar{U}}_t$, est ensuite transmise à l'agrégateur DR pour coordination.

Étape 4 : Les consignes et rapports cycliques optimaux, ξ_t^* et D_t^* issus de l'*Étape 2*, sont appliqués à la maison réelle sur l'horizon de mise à jour N_c. On obtient les mesures des charges de chauffage résultantes ($\bar{u}_t^m$), des températures bruitées (y_t^m), ainsi que les valeurs

de la température ambiante ($T^m_{a,t}$) ($t \in \mathbb{N}_{kN_c}^{(k+1)N_c-1}$).

Étape 5 : Avec les valeurs mesurées $\bar{u}^m_t$, y^m_t et $T^m_{a,t}$ de l'*Étape 4* et en s'appuyant sur les équations (3.32) et (3.35), le vecteur des charges résiduelles ($\tilde{u}^r_t$) est extrait. Nous avons :

$$\begin{aligned} \tilde{\bar{x}}_{t+1} &= f_d\left(\tilde{\bar{x}}_t, \bar{u}^m_t, T^m_{a,t}, \bar{\theta}^*\right) \\ \tilde{e}_{t+1} &= y^m_{t+1} - \tilde{\bar{x}}_{t+1} \\ \tilde{u}^r_t &= g_d\left(\tilde{e}_{t+1}, \tilde{e}_t, \tilde{\theta}^*\right). \end{aligned} \tag{3.44}$$

Avec $t = kN_c \cdots (k+1)N_c - 1$.

Étape 6 : Une fois l'*étape 5* réalisée, les valeurs des charges résiduelles $\tilde{u}^r_t$ sont révélées. Nous pouvons alors évaluer le ratio de réduction potentielle d'énergie (γ^p_t) et l'efficacité de confort potentielle (η^p_t) qui auraient été obtenus. De même, nous pouvons obtenir le ratio de réduction d'énergie effectif (γ_t) et l'efficacité de confort effective (η_t) réalisés.

Soient $\bar{Y}^p_t$, $\bar{Y}^{ref}_t$, $\bar{Y}_t$, $\bar{U}^p_t$, $\bar{U}^{ref}_t$ et $\bar{U}_t$ respectivement : température moyenne potentielle, température moyenne de référence, température moyenne effective, demande de chauffage potentielle (agrégée), demande de chauffage de référence (agrégée) et demande de chauffage effective (agrégée). Nous notons $\bar{E}^p_t = R_t - \bar{Y}^p_t$, $\bar{E}^{ref}_t = R_t - \bar{Y}^{ref}_t$ et $\bar{E}_t = R_t - \bar{Y}_t$ les écarts respectifs entre les températures moyennes potentielle, de référence et effective et la consigne moyenne. En utilisant ces facteurs dans les équations (3.42) et (3.43), nous obtenons γ^p_t, η^p_t, γ_t et η_t ($t \in \mathbb{N}_{kN_c}^{(k+1)N_c-1}$).

Étape 7 : À cette étape, le vecteur $\hat{\mathbf{u}}_t$ contenant les valeurs retardées du vecteur de charges résiduelles prédites est mis à jour avec les valeurs extraites $\tilde{u}^r_t$ à l'*étape 5* des pas de prédiction $k, k-1, \cdots, k-q$, selon la valeur du retard p ($q \leq k$). On a donc : $\hat{\mathbf{u}}^r_t := \tilde{u}^r_{t-p:t-1}$

à $t = (k+1)N_c$. Nous sommes donc au pas de prédiction $k+1$. Considérons alors $k \leftarrow k+1$ et prédisons le vecteur de charges résiduelles i.e. $\hat{u}_t^r$ sur l'horizon de contrôle courant en utilisant le $\hat{\mathbf{u}}_t^r$ mis à jour dans l'équation (3.38), avec $t = kN_c \cdots (k+1)N_c - 1$.

Les *Étapes 1, 2, 3* peuvent désormais être alimentées par les valeurs prédites des charges résiduelles globales et le processus recommence.

Dans cette partie, nous nous concentrons sur la prédiction du potentiel DR et de la flexibilité, afin de les évaluer. Ainsi, le cas 1 énuméré à l'*Étape 2* sera considéré, car il permet d'évaluer effectivement l'heuristique proposée à l'*Étape 1*. Les cas orientés optimisation, c-à-d, $2, 3, 4$ et 5, ne sont pas couverts dans cette section.

3.4 Algorithme de contrôle des charges de chauffage basé sur une optimisation inverse

L'optimisation inverse constitue, en réalité, une solution pratique pour relever le défi de conversion d'un profil de puissance, adaptée aux besoins de flexibilité poursuivis par l'agrégateur, en confort thermique qui sied au client. En ce sens, elle peut aider à trouver un compromis entre les objectifs antagonistes qui engagent les deux parties. La question principale à laquelle il faut répondre dans ce contexte est la suivante : quel est le changement minimal des paramètres contrôlables (consignes des thermostats ou rapports cycliques) qui permettrait de préserver les préférences thermiques de l'utilisateur tout en offrant une flexibilité au réseau ?

Pour répondre à cette question, et conformément à ce que nous avons énoncé dans notre étude précédente [13], nous proposons un contrôleur de haut niveau qui exploite les informations relatives aux tarifs de l'électricité et aux préférences de confort des différentes pièces d'une maison afin de générer, en conséquence, un planning de consignes

et/ou de rapport cycliques à transmettre au thermostat de chaque zone chauffée. La puissance du système de chauffage n'est pas modulée directement, mais via la consigne (avec un degré de liberté supplémentaire lorsqu'il est permis de moduler également les rapports cycliques maximaux autorisés).

Nous proposons deux approches qui s'appuient sur la disponibilité de l'estimation et de la prédiction en temps réel des charges résiduelles et des états de la maison pour permettre un meilleur contrôle des charges de chauffage en fonction du prix. Ici, les charges résiduelles sont associées au comportement des occupants, à leurs activités et à d'autres variables stochastiques (par exemple le rayonnement solaire). Une méthode de reconstitution de telles charges a été proposée dans la section précédente. Les objectifs poursuivis par les approches proposées sont de minimiser le coût opérationnel lié aux systèmes de chauffage tout en préservant le confort du client.

Les approches sont mises en œuvre à travers des algorithmes qui ajustent les plannings de consignes et/ou des rapports cycliques sur la base des prédictions des charges résiduelles et des états de la maison (températures), à mesure que les sorties du système sont acquises en temps réel. Le contrôleur de haut niveau peut émuler la dynamique thermique d'une maison via un modèle thermo-thermostatique non linéaire. L'algorithme conçu pour ce contrôleur revient donc à résoudre un problème d'optimisation non linéaire.

Dans la première approche, l'algorithme vise à trouver directement les plannings optimaux de consignes et/ou de rapports cycliques en employant une optimisation basée sur la simulation. Dans la seconde approche, une optimisation biniveau est conduite. Dans un premier temps, une heuristique basée sur la modulation du rapport cyclique produit un profil de consommation potentiellement optimal. Ce profil de puissance reflète également la flexibilité que la maison peut fournir (potentiel de réponse à la demande). L'optimisation

basée sur la simulation déduit ensuite les plannings optimaux de consignes et/ou de rapport cycliques correspondant à la trajectoire de consommation planifiée.

On peut également mentionner que, qu'il s'agisse d'employer l'une ou l'autre approche, la planification heuristique fait toujours partie du processus et contribue à évaluer le potentiel de réponse à la demande via la capacité d'offre, la vérification de faisabilité, voire la fourniture d'un plan de consommation possible à l'agrégateur en amont de la déduction de la stratégie de contrôle. De plus, le comportement de la maison sous les séquences de consignes et/ou de rapport cyclique déduits pourrait être prédit avant l'application effective des actions de contrôle dans la maison réelle. Cela permet de transférer le profil de consommation attendu à l'agrégateur.

Ainsi, cette étude a pour avantage de :

- Permettre la prédiction en temps réel du potentiel de réponse à la demande en tenant compte d'événements stochastiques (comportement de l'utilisateur, rayonnement solaire).

- Produire, dans un contexte de DR, à l'aide d'un algorithme dédié et de manière centralisée, des plannings optimaux de consignes et/ou de rapport cyclique pour chaque zone de la maison tout en considérant : les échanges thermiques entre pièces voisines, la dynamique non linéaire de la maison et les effets des charges résiduelles.

- Faire correspondre le confort de l'utilisateur à son équivalent en puissance, et permettre la quantification en temps réel de la flexibilité de la maison.

La section est organisée comme suit : la Section 3.4.1 est consacrée à l'optimisation basée sur la simulation et à l'optimisation inverse, et la Section 3.4.2 discute du confort et de la flexibilité. L'algorithme permettant la prédiction du potentiel de réponse à la demande et la déduction des actions de contrôle optimales est présenté en Section 3.4.3.

3.4.1 Optimisation basée sur la simulation et optimisation inverse

Le système étudié ici est le modèle thermo-thermostatique d'une maison, qui couple le modèle thermique et le modèle du thermostat. L'établissement de ce modèle a été décrit dans la section précédente. Rappelons les équations qui le constituent :

$$\bar{u}_t = C_d\left(x_t, \xi_t, D_t\right) \tag{3.45a}$$

$$u_t = Concat\left(\bar{u}_t, u_t^r\right) \tag{3.45b}$$

$$x_{t+1} = f_d\left(x_t, u_t, T_{a,t}, \theta^*\right) \tag{3.45c}$$

$$y_t = h_d\left(x_t, \kappa_t\right) \tag{3.45d}$$

Avec $C_d(\cdot)$, $Concat(\cdot)$, $f_d(\cdot)$, $h_d(\cdot)$ représentant respectivement les fonctions thermostat, concaténation (des vecteurs), état et mesure. Les paramètres x_t, ξ_t et D_t sont le vecteur des températures, le vecteur des consignes de température et le vecteur des rapports cycliques (3.45a); par défaut, $D_t = D_{max}\ \forall t$ (avec $D_{max,1} = \cdots D_{max,n_x} = 100\%$). Dans (3.45b), $\bar{u}_t$, u_t^r et u_t sont respectivement le vecteur de puissance de chauffage, le vecteur des charges résiduelles globales (*Global Residual Loads*, GRLs) et le vecteur qui concatène les deux. Nous avons adopté la dénomination charges résiduelles globales, car

elles représentent l'effet agrégé des charges résiduelles agissant dans une pièce donnée de la maison. Nous désignons dans l'équation 3.45d, $T_{a,t}$ comme température ambiante et θ^* vecteur des paramètres du modèle.Dans l'équation 3.45d, y_t correspond à l'état mesuré bruité et κ_t est une erreur de mesurage inconnue (nous supposons $\kappa_t = 0 \ \forall t$). Le modèle thermo-thermostatique peut être considéré comme un modèle de simulation de la maison, car il imite le comportement du système réel (la maison). Il décrit la relation intrinsèque qui relie, par exemple, les variables de décision (consignes et/ou rapport cyclique) à la consommation de puissance du chauffage, capturant ainsi dynamiquement le comportement de la température interne. Intégré dans un processus d'optimisation, le modèle de simulation peut permettre d'atteindre des objectifs spécifiques, tels qu'améliorer l'environnement thermique intérieur ou réduire la consommation d'énergie en optimisant les variables de décision du système. L'intégration de la simulation avec l'optimisation est appelée optimisation basée sur la simulation dans la littérature [126]. Le système décrit par l'équation (3.45) est caractérisé par des dynamiques non linéaires en raison de la nature des comportements des thermostats, qui intègrent des saturations et des stratégies anti-windup dans leur logique, comme nous l'avons déjà mentionné dans [13]. Par conséquent, une fonction objectif conçue pour optimiser le fonctionnement du système conduira à une fonction non convexe ; toute simplification de celle-ci (par exemple, ignorer les effets de saturation) déformerait le cœur du problème [127]. À cet égard, l'optimisation basée sur la simulation apparaît comme un choix approprié, puisqu'elle considère la relation complexe des composants du système qui évoluent dans le temps, permettant une déduction plus réaliste et plus efficace des variables de décision.

Dans une autre configuration, la solution optimale (consommation de puissance optimale) peut être disponible, et l'objectif peut être de reproduire la trajectoire de cette

solution optimale. Le processus d'optimisation qui produit cette solution pourrait être agnostique aux non-linéarités (optimisation convexe), limitant ainsi en partie l'optimalité de la solution. Autrement, une heuristique tenant compte des non-linéarités pourrait constituer un meilleur choix. Le processus consistant à inférer des paramètres ou entrées inconnus d'un modèle (consignes des thermostats et/ou rapport cyclique) d'un problème d'optimisation à partir de la mesure de sa solution optimale est appelé optimisation inverse [86]. Trouver la(les) variable(s) de décision qui correspondent le mieux à la solution optimale pose de nombreux défis. Ils proviennent essentiellement du bruit potentiel dans les données, de l'action du consommateur qui peut *stochastiquement* modifier ses préférences (en changeant les consignes de thermostat), et du décalage entre le processus de production de décision optimale et le fonctionnement ou l'état réel du système (souvent affecté par des effets externes, tels que la météo, les charges thermiques résiduelles, ou encore l'effet de saturation inhérent du contrôleur). Dans cette situation, le même effet (consommation de puissance) ne provient pas nécessairement de la même cause (valeur de consigne), ce qui rend le problème de recherche des paramètres permettant de reconstruire la trajectoire optimale plus difficile. Pour les mêmes raisons que celles évoquées précédemment, l'optimisation basée sur la simulation est appropriée pour relever ces défis.

Au regard de ce qui précède, deux approches candidates émergent pour optimiser le fonctionnement du système. La première consiste à déduire le profil optimal des consignes et/ou du rapport cyclique en minimisant une fonction de coût qui vise à trouver un compromis entre une consommation de puissance (ou d'énergie) modeste et la préservation du confort du client. Cette approche correspond à une déduction directe des consignes et/ou du rapport cyclique. La seconde approche reproduit une consommation de

puissance préoptimisée en déduisant la trajectoire correspondante de consignes et/ou de rapport cyclique. Elle peut ainsi être qualifiée d'approche inverse. La mise en œuvre des algorithmes permettant d'appliquer les deux approches sera décrite ultérieurement. Avant d'aborder la quantification de la flexibilité et du confort, nous allons d'abord discuter sur ces deux aspects, car ils représentent les deux métriques qui nous guideront dans l'évaluation de l'optimalité des solutions proposées.

3.4.2 Quantification du confort et de la flexibilité

La qualité de l'environnement intérieur est un facteur important influençant le bien-être, la santé et le confort des occupants. Il est donc nécessaire de maintenir un environnement thermique confortable dans un bâtiment afin d'assurer une expérience agréable pour les occupants. Cela est d'autant plus important qu'un individu passe en moyenne 90% de son temps dans un environnement intérieur [128]. Les sensibilités des occupants en matière de confort doivent être prises en compte lors de la conception des systèmes d'automatisation pour le contrôle du chauffage [129]. Des modèles de confort thermique basés sur l'équilibre thermique du corps humain ont été proposés dans [130]. Six paramètres différents, à savoir : la température de l'air intérieur, la température moyenne radiante, la vitesse de l'air, l'humidité, l'activité et l'habillement, sont utilisés pour calculer un indice PMV (Predicted Mean Vote) comme mesure du confort. Cependant, comme souligné dans [131–135], la complexité de la mesure du PMV tient à la difficulté d'évaluer les valeurs exactes des variables d'entrée du modèle et à la difficulté de les contrôler en temps réel [136]. Pour cette raison, nous restreignons dans notre cas l'évaluation du confort thermique à la capacité du système de contrôle à maintenir la température à un certain niveau, qui peut représenter le niveau de confort perçu par l'occupant. Cette perception du confort peut être très subjective et varier d'un

occupant à un autre. En effet, le confort thermique est défini par l'ASHRAE [137] comme « l'état d'esprit exprimant une satisfaction vis-à-vis de l'environnement thermique et évalué par un jugement subjectif. » Nous adoptons donc le même concept qu'utilisé dans [85], en considérant une plage de températures dans laquelle la température intérieure doit se situer pour être considérée comme respectant les préférences de confort de l'occupant. Finalement, il revient à l'occupant de définir cette plage de température, ce qui influence inversement la flexibilité qu'il souhaite offrir au réseau.

La flexibilité, ou flexibilité énergétique, d'un bâtiment, selon l'IEA EBC Annex 67 [138], est définie comme la capacité à gérer sa demande et sa consommation (et ou production) en fonction des conditions climatiques locales, des besoins des utilisateurs et des exigences du réseau énergétique. Elle permet sa participation à un programme de réponse à la demande en réduisant sa consommation d'énergie lorsque le réseau le demande, pour écrêter les pics de charge ou combler les creux. Puisque notre étude concerne la flexibilité des systèmes de chauffage, il convient de mentionner les deux façons de la fournir, comme postulé dans [85]. La première consiste à doter le système de chauffage d'un *buffer* thermique (par exemple, de l'eau) pour stocker la chaleur. La seconde repose sur l'inertie thermique du bâtiment, qui constitue un stockage thermique passif. Différentes méthodologies de quantification de la flexibilité énergétique ont été proposées dans la littérature. Toutefois, ayant des finalités différentes, trois facteurs clés de la flexibilité énergétique émergent [139] : 1) la durée pendant laquelle l'énergie et la puissance peuvent être décalées ou modulées, 2) la quantité d'énergie ou de puissance qui peut être décalée ou modulée, 3) le coût ou la perte d'efficacité associés au niveau du bâtiment, résultant de l'activation de cette flexibilité. Ces facteurs clés nous guideront dans l'évaluation de la flexibilité fournie lors de l'utilisation des stratégies d'optimisation

proposées.

Il existe de nombreuses études portant sur le potentiel de réponse à la demande, la prédiction et l'évaluation de la flexibilité. Elles ont défini différents indicateurs pour quantifier le confort et la flexibilité. Principalement, ces indicateurs mesurent la quantité de charges modulables par rapport aux conditions de fonctionnement normal, ainsi que la durée pendant les événements DR où le confort est maintenu [52, 125, 140, 141]. Nous définissons deux indicateurs pour quantifier la flexibilité et le confort dans un contexte DR. Le premier est le taux de réduction d'énergie (*Energy Reduction Ratio*, ERR), qui évalue la quantité de puissance réduite lors des événements DR. Le second est appelé Efficacité du Confort (*Comfort Efficiency*, CE) et est mesuré en pourcentage. Il reflète la capacité à atteindre le régime permanent (température intérieure = température de consigne) lorsque le contrôle orienté DR est appliqué. L'expression de chacun des indicateurs est définie comme suit (voir section précédente) :

$$\gamma_t = \begin{cases} \max\left(\frac{\bar{U}_t^{ref} - \bar{U}_t}{\max\left(\bar{U}_t^{ref}, \varepsilon\right)}, 0\right) & \text{si } \bar{\pi}_t > \bar{\pi}_{\min} \\ 0 & \text{sinon} \end{cases} \tag{3.46}$$

$$\eta_t = \left(\frac{\exp\left(\frac{\left|\bar{E}_t^{ref}\right| - \max(|\bar{E}_t|, \varepsilon)}{\max\left(\left|\bar{E}_t^{ref}\right|, \varepsilon\right)} \right)}{\exp(1)} \right) \times 100 \tag{3.47}$$

Où $\bar{U}_t^{ref}$ et $\bar{U}_t$ représentent respectivement la demande de chauffage de la maison en

condition de fonctionnement normal et sa demande de chauffage après application du contrôle orienté DR. De même, $\bar{E}_t^{ref}$ et $\bar{E}_t$ correspondent à l'erreur de régulation de la température dans une condition de fonctionnement normale et à celle obtenue lors de l'application du contrôle orienté DR. Nous avons également $0 < \varepsilon \ll 10^{-2}$, étant une petite valeur supérieure à zéro. Il est à considérer: $\bar{\pi}_t > \bar{\pi}_{\min} \equiv \bar{\pi}_{t,n} > \bar{\pi}_{\min,n}\ \forall n$ (3.46), $n = 1 \cdots n_x$.

Justification des métriques: Le choix de ces deux indicateurs répond directement aux trois facteurs clés de la flexibilité énergétique identifiés dans la littérature [139] : la quantité de puissance modulable est capturée par le taux de réduction d'énergie (ERR, γ_t), tandis que le coût/perte d'efficacité pour l'occupant est capturé par l'efficacité de confort (CE, η_t). La forme *exponentielle normalisée* retenue pour η_t (éq. 3.47) pénalise de manière croissante les écarts de régulation, ce qui traduit le caractère non linéaire de la perception du confort ; sa normalisation par $\exp(1)$ borne l'indicateur et le rend comparable d'un cas à l'autre. Ces deux métriques permettent ainsi de quantifier conjointement le compromis flexibilité/confort, au cœur de la problématique de réponse à la demande.

3.4.3 L'algorithme de contrôle

Nous nous positionnons dans un cadre d'implémentation d'un programme DR, tel qu'illustré à la section 3.3.2 (voir figure 3.10). Les approches candidates évoquées (directe et inverse) pour optimiser le fonctionnement du système consistent à suivre les différentes étapes illustrées par la figure 3.10. Nous mettrons en évidence les principales différences entre les deux approches à l'*Étape 2*. Les *Étapes 1* et *4 à 7* ont déja été détaillées dans la section 3.3.2 . L'étape de coordination n'est pas traitée ici. Nous nous concentrerons sur l'*Étape 2*, qui détaille l'ossature de l'algorithme de contrôle. Notons que nous employons

le modèle thermo-thermostatique décrit dans l'équation (3.45). Par ailleurs, pour le raisonnement qui suit, nous faisons une distinction entre le potentiel DR d'un bâtiment et sa flexibilité. En effet, nous supposons que le potentiel DR d'un bâtiment se réfère à la flexibilité qu'il pourrait fournir dans un contexte DR. La flexibilité de la maison désigne la flexibilité débloquée ou atteinte lorsque des actions de contrôle optimales ont été appliquées.

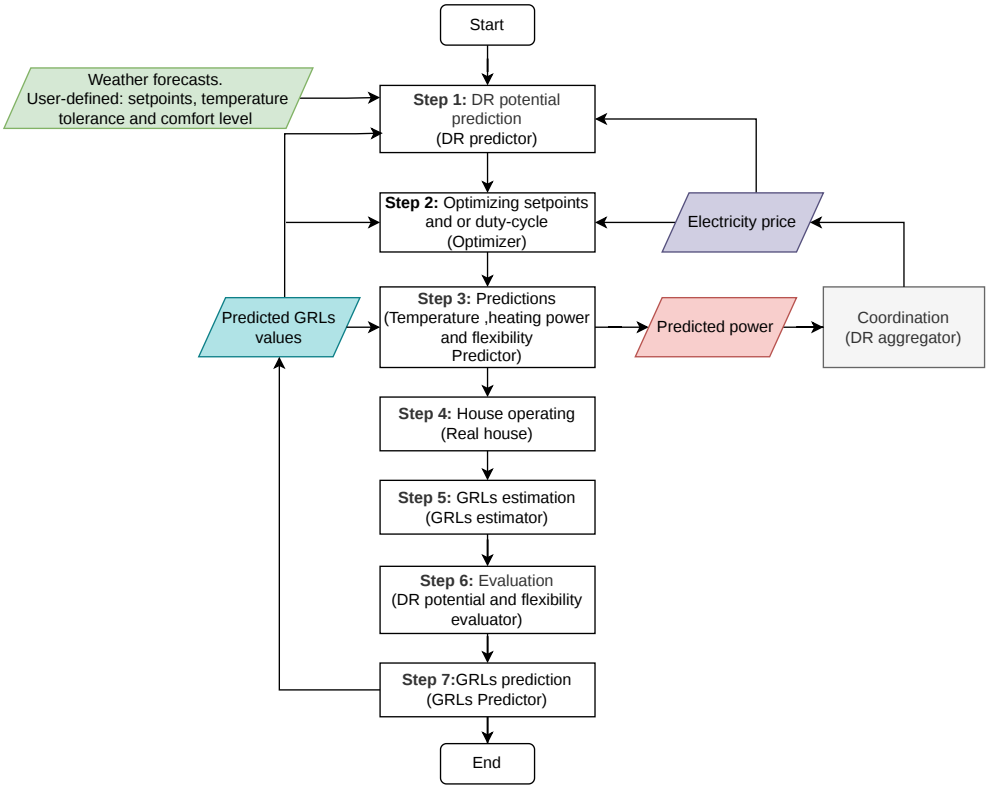


Figure 3.10 Cadre d'implémentation d'un programme DR.

Nous considérons toujours N l'horizon de prédiction, N_c l'horizon de contrôle ($N_c \leq N$) et k une étape de prédiction. On prendra $N_c = N$. (voir la justification de ce choix donnée plus haut : réduction du coût de calcul et adéquation à la dynamique thermique lente

du bâtiment). Soit une séquence de demandes de chauffage potentiellement ”optimale”, c.-à-d. $\hat{\bar{u}}_t^p$ avec $t = kN_c \cdots (k+1)N_c$. Plus de détails sur l'obtention de cette séquence pourront être trouvés dans la section 3.3.2. Ce qui suit détaille le processus de production de décisions optimales effectué à l'*étape* 2 (voir figure 3.10).

Les consignes optimales (ξ_t^*) et les rapports cycliques (D_t^*) sont produits à cette étape. Rappelons les différentes configurations possibles (dans ce qui suit, $\mathbb{C}_t$ est un ensemble de contraintes) :

1. rapport cyclique potentiel (issu de l'heuristique en *Étape 1*) considéré comme optimal : $D_t^* \leftarrow D_t^p \Rightarrow \xi_t^* \leftarrow r_t, \forall t \in \mathbb{N}_{kN_c}^{(k+1)N_c-1}$.
2. Détermination d'une consigne optimale ou d'un rapport cyclique optimal via une fonction objectif dédiée : $\{\xi_t^*\}_{t=kN_c}^{(k+1)N_c} \leftarrow \min \sum_{t=kN_c}^{(k+1)N_c} \rho(\xi_t, D_t), st : \mathbb{C}_t \Rightarrow D_t^* \leftarrow D_{max} \forall t \in \mathbb{N}_{kN_c}^{(k+1)N_c-1}$ ou $\{D_t^*\}_{t=kN_c}^{(k+1)N_c} \leftarrow \min \sum_{t=kN_c}^{(k+1)N_c} \rho(\xi_t, D_t), st : \mathbb{C}_t \Rightarrow \xi_t^* \leftarrow r_t, \forall t \in \mathbb{N}_{kN_c}^{(k+1)N_c-1}$
3. Détermination conjointe de la consigne optimale et du rapport cyclique : $\{\xi_t^*, D_t^*\}_{t=kN_c}^{(k+1)N_c} \leftarrow \min \sum_{t=kN_c}^{(k+1)N_c} \rho(\xi_t, D_t), st : \mathbb{C}_t$
4. Faire correspondre la puissance potentiellement optimale ($\hat{\bar{u}}_t^p \sim \hat{\bar{u}}_t^*$) à des consignes ou des rapport cycliques, par inversion, via une fonction objectif dédiée : $\{\xi_t^*\}_{t=kN_c}^{(k+1)N_c} \leftarrow \min \sum_{t=kN_c}^{(k+1)N_c} \rho(\bar{u}_t, \hat{\bar{u}}_t^*), st : \mathbb{C}_t \Rightarrow D_t^* \leftarrow D_{max} \forall t \in \mathbb{N}_{kN_c}^{(k+1)N_c-1}$ ou $\{D_t^*\}_{t=kN_c}^{(k+1)N_c} \leftarrow \min \sum_{t=kN_c}^{(k+1)N_c} \rho(\bar{u}_t, \hat{\bar{u}}_t^*), st : \mathbb{C}_t \Rightarrow \xi_t^* \leftarrow r_t, \forall t \in \mathbb{N}_{kN_c}^{(k+1)N_c-1}$
5. Faire correspondre de la puissance potentiellement optimale ($\hat{\bar{u}}_t^p \sim \hat{\bar{u}}_t^*$) à des consignes et rapports cycliques, par inversion, via une fonction objectif dédiée : $\{\xi_t^*, D_t^*\}_{t=kN_c}^{(k+1)N_c} \leftarrow \min \sum_{t=kN_c}^{(k+1)N_c} \rho(\bar{u}_t, \hat{\bar{u}}_t^*) \, st : \mathbb{C}_t$

Le Cas 1 est celui mis en avant à la section 3.3.2 , principalement pour la prédiction et l'évaluation du potentiel DR. Même s'il a montré de bons résultats, dans la pratique, une

modulation persistante du rapport cyclique n'est pas recommandée. Pour contourner cela, on peut faire correspondre, par inversion, la consommation de puissance potentiellement optimale issue de l'heuristique (basée sur la modulation du rapport cyclique) avec son équivalent en consigne et/ou rapport cyclique. Cela peut être fait via les cas 4 et 5. Cependant, le cas 4 ne possède pas un degré de liberté complet permettant la reconstruction de la puissance potentiellement optimale ; il peut donc s'avérer inefficace. Bien sûr, le vecteur de charges de chauffage optimal ($\bar{u}_t^*$) utilisé dans les cas 4 et 5 peut être obtenu en résolvant un problème d'optimisation convexe. Toutefois, cette approche peut conduire à une mauvaise évaluation du potentiel DR disponible, notamment en raison de l'abstraction des non-linéarités des thermostats et de la non-considération des charges résiduelles. Pour cette raison, un choix pertinent consiste à tirer parti de l'heuristique utilisée à l'*Étape 1* (voir section 3.3.2), qui considère pleinement le comportement du thermostat dans son processus. C'est pourquoi le vecteur de puissance de chauffage potentiellement "optimal", c.-à-d. $\hat{\bar{u}}_t^p$, peut être considéré comme la puissance de chauffage effectivement optimale à reproduire. C'est pour cela que nous considérons : $\hat{\bar{u}}_t^p \sim \bar{u}_t^*$. Les cas 2 et 3, qui reposent sur une modulation directe de la consigne et/ou du rapport cyclique, paraissent également intéressants. Cependant, afin d'éviter une modulation persistante, une restriction concernant la variation possible des paramètres, en particulier la variation du rapport cyclique, doit être prise en compte dans la conception des contraintes. Au regard de ce qui précède, nous étudierons le cas 2 (configuration de déduction de consigne optimale), le cas 3 et le cas 5. La dénomination suivante sera adoptée :

- "Approche directe et non-adaptative" pour le cas 2 (non-adaptative au sens de la modulation du rapport cyclique).
- "Approche directe et adaptative" pour le cas 3 (adaptative au sens de la modulation du rapport cyclique).

- ”Approche inverse et adaptative” pour le cas 5.

Pour cette raison, nous restreindrons la variation du rapport cyclique (cas adaptatif). L'algorithme de contrôle sera conçu pour trouver le rapport cyclique optimal sur l'horizon de contrôle courant ou étape de mise à jour k. Ainsi, la notation suivante sera adoptée pour les trois cas :

$$\{\xi_t^*, D_k^*\}_{t=kN_c}^{(k+1)N_c} \leftarrow \min \sum_{t=kN_c}^{(k+1)N_c} \rho(\xi_t, D_k),\ st : \mathbb{C}_t$$

Cela implique que $D_t^* = D_k^* \quad \forall t$.

À présent, l'agent de contrôle ou l'optimiseur utilisant un contrôle prédictif cherche à minimiser une fonction objectif globale du système à chaque pas de contrôle k tel que :

$$\min_{\left\{\xi_{kN_c}\cdots\xi_{(k+1)N_c-1;D_k}\right\}} \sum_{t=kN_c}^{(k+1)N_c} \rho\left(\xi_t, D_k\right) \tag{3.48a}$$

$$\text{s.c.} : x_0 = y_t^m, u_0 = u_t^m \tag{3.48b}$$

$$\tau = \left(N_c - 1\right)/n_c \tag{3.48c}$$

$$D_k := b \times D_k + \bar{b} \times D_{max}, D_{k,1} = \cdots = D_{k,n_x}, D_k \in (D_{min}, D_{max}] \tag{3.48d}$$

$$r_{k,min} - \Delta y \preceq S_{i,k} \preceq r_{k,max} + \Delta y, \forall i \in \mathbb{N}_0^{\tau-1} \tag{3.48e}$$

$$\xi_{t+1} = \xi_t := S_{i,k}, \text{ si } kN_c + in_c \leq t \leq kN_c + (i+1)n_c, i \in \mathbb{N}_0^{\tau-1} \tag{3.48f}$$

$$\bar{u}_t = C_d\left(x_t, \xi_t, D_k\right) \tag{3.48g}$$

$$u_t = Concat\left(\bar{u}_t, \hat{u}_t^r\right) \tag{3.48h}$$

$$x_{t+1} = f_d\left(x_t, u_t, \hat{T}_{a,t}, \theta^*\right) \tag{3.48i}$$

$$y_t = h_d(x_t, \kappa_t) \tag{3.48j}$$

$$k := (k+1) \cdot \mathbf{1}_{\{t=(k+1)N_c\}} + 0 \cdot \mathbf{1}_{\{t=N_{24}\}} + k \cdot \mathbf{1}_{\{t\neq(k+1)N_c, t\neq N_{24}\}} \tag{3.48k}$$

La fonction de coût $\rho(\cdot)$ exprimée en (3.48a), selon les approches employées (directe ou inverse), correspond aux relations suivantes :

Approche directe: $\rho\left(\xi_t, D_k\right) := \rho\left(y_t, u_t, r_t\right) = \pi_t u_t + \varphi_t \left(y_t - r_t\right)^T \left(y_t - r_t\right)$

Approche inverse: $\rho\left(\xi_t, D_k\right) := \rho\left(\bar{u}_t, \bar{u}_t^*\right) = \left(\bar{u}_t - \bar{u}_t^*\right)^T \left(\bar{u}_t - \bar{u}_t^*\right)$.

Où $\xi_t \in \mathbb{R}^{n_y \times 1}$, $D_k \in \mathbb{R}^{n_y \times 1}$, $y_t \in \mathbb{R}^{n_y \times 1}$, $u_t \in \mathbb{R}^{n_u \times 1}$, $r_t \in \mathbb{R}^{n_y \times 1}$, $\pi_t \in \mathbb{R}^{1 \times n_u}$ et

$\varphi_t \in \mathbb{R}^{1\times n_y}$, $\bar{u}_t \in \mathbb{R}^{n_{\bar{u}}\times 1}$ et $\bar{u}_t^* \in \mathbb{R}^{n_{\bar{u}}\times 1}$ correspondent respectivement au vecteur des consignes de température, au vecteur des rapports cycliques (au pas de contrôle k), au vecteur des températures, au vecteur des charges de chauffage et résiduelles, au vecteur des températures de référence (définies par l'utilisateur), au vecteur des prix de l'électricité, au vecteur du facteur de confort, au vecteur des charges de chauffage et au vecteur des charges de chauffage optimales. Le vecteur des prix π_t comporte à la fois des valeurs positives et négatives. Les valeurs positives pondèrent les charges de chauffage, tandis que les valeurs négatives pondèrent les charges résiduelles. Notons que $\bar{\pi}_t$ (3.46), qui ne contient que les valeurs positives du prix, est distinct de π_t.

La fonction objectif globale du système est minimisée sous certaines contraintes :

- Équation 3.48b : initialiser le vecteur d'état (x_t) et le vecteur des charges de chauffage et résiduelles (u_t).
- Équation 3.48c : nombre de périodes (de longueur n_c) dans l'horizon de contrôle où la consigne reste constante.
- Équation 3.48d : déterminer si le rapport cyclique au pas de contrôle k prend sa valeur maximale (D_{max}) ou une valeur $D_k \in (D_{min}, D_{max}]$ à déterminer ; b est une variable binaire dont le complément est noté $\bar{b}$. Il est à noter que nous considérons une seule valeur de rapport cylique à déterminer pour tous les thermostats, c-à-d: $D_{k,1} = D_{k,2} = \cdots = D_{k,n_x}$.
- Équation 3.48e : définir la contrainte de bornage pour le vecteur constant $S_{i,k} \in \mathbb{R}^{n_y\times 1}$, où :

$$\Delta y = \frac{\delta y}{\sqrt{\varphi}}$$

δy est la tolérance de température et φ un facteur de confort choisis par l'utilisateur.

Notons que $\varphi_{n,t} = \varphi$, $\forall n \in \{1, \cdots n_y\}$, $\forall t$.

$\pm\Delta y$ est une plage de tolérance reflétant le compromis que l'utilisateur souhaite faire concernant son confort. Les vecteurs $r_{k,min}$ et $r_{k,max}$ sont respectivement les vecteurs des valeurs minimales et maximales de consigne de température sur l'horizon de contrôle N_c. Le symbole $\preceq$ est mis pour traduire une inégalité composante par composante.

- Équation 3.48f : contrainte de blocage pour que la consigne reste constante durant chaque i-ème période parmi τ (définie en 3.48c).
- Équation 3.48g : équation du thermostat donnant les charges de chauffage fournies, en fonction de l'état, des vecteurs de consigne et de la valeur du rapport cyclique.
- Équation 3.48h : fonction de concaténation pour obtenir $u_t = \left[\vec{u}_t^T, \hat{u}_t^{rT}\right]^T$.
- Équations 3.48i et 3.48j : équations du vecteur d'état (x_t) et du vecteur des températures (y_t) respectivement ($\kappa_t = 0\ \forall t$).
- Équation 3.48k : équation de mise à jour de l'indice du pas de contrôle k (k est réinitialisé toutes les 24 heures).

Comme $\xi_t \in \{S_{0,k}, \cdots S_{\tau-1,k}\}\ \forall t \in \{kN_c, \cdots, (k+1)N_c\}$ selon l'équation 3.48f, on a :

$$J(\{S_{0,k}, \cdots S_{\tau-1,k}; D_k\}) \equiv J(\{\xi_{kN_c} \ldots \xi_{(k+1)N_c-1}; D_k\}) = \sum_{t=kN_c}^{(k+1)N_c} \rho\left(\xi_t, D_k\right)$$

Nous pouvons alors réécrire la fonction objectif globale du système 3.48 comme suit :

$$\min_{\{S_{0,k},\cdots S_{\tau-1,k};D_k\}} J(\{S_{0,k},\cdots S_{\tau-1,k};D_k\}) \tag{3.49a}$$

$$\text{s.c. : équations 3.48b à 3.48k} \tag{3.49b}$$

En s'appuyant sur l'optimisation Bayésienne, la fonction d'acquisition *Expected Improvement* (EI) [124] est utilisée pour trouver la séquence optimale de $\{S_{0,k},\cdots S_{\tau-1,k}\}$ et la valeur de D_k (dans le cas $b=1$) qui minimise la fonction $J(\cdot)$,(3.49), au pas k. Ainsi, on peut établir la séquence optimale des consignes ($\xi^*_{kN_c}\cdots\xi^*_{(k+1)N_c-1}$) et le rapport cyclique optimal (D^*_k) à appliquer sur l'horizon de contrôle. Le processus de génération de la séquence est décrit à travers l'algorithme 3 (en considérant $N=N_c$).

Algorithme 3 : Algorithme de contrôle

Entrée: N, N_c, n_c, b,

$\{\hat{u}^r_{kN_c}, \ldots, \hat{u}^r_{(k+1)N_c-1}\}$,

$\{\hat{T}_{a,kN_c}, \ldots, \hat{T}_{a,(k+1)N_c-1}\}$,

$\{r_{kN_c}, \ldots, r_{(k+1)N_c-1}\}$,

$\{\bar{u}^*_{kN_c}, \ldots, \bar{u}^*_{(k+1)N_c-1}\}$, $r_{min,k}$, $r_{max,k}$.

Initialiser le vecteur d'état (x_0) et le vecteur des charges de chauffage et de résidu (u_0) si $k = 0$ (équation 3.48b)

Calculer la valeur de τ (équation 3.48c)

Pour $l = 1$ **to** L **faire**

  Maximiser la fonction d'acquisition *Expected Improvement* de (3.49a) sous contraintes : (3.48d), (3.48e) et obtenir $\{S_{0,k}, \ldots, S_{\tau-1,k}, D_k\}_{l+1}$:

  $EI(\{S_{0,k}, \ldots, S_{\tau-1,k}, D_k\}) := E\Big[\big[\min\{J(\{S_{0,k}, \ldots, S_{\tau-1,k}, D_k\}_\rho)\}_{\rho=0}^{l} - J(\{S_{0,k}, \ldots, S_{\tau-1,k}, D_k\})\big]^+\Big]$

  Pour $i = 0$ **to** $\tau - 1$ **faire** : (3.48f)

    Pour $t = kN_c + in_c$ **to** $kN_c + (i+1)n_c - 1$ **faire**

      $\xi_t := S_{i,k}$, avec $S_{i,k} \in \{S_{0,k}, \ldots, S_{\tau-1,k}, D_k\}_{l+1}$

    Fin Pour

  Fin Pour

  Récupérer la séquence des consignes : $\xi_{kN_c}, \ldots, \xi_{(k+1)N_c-1}$ et D_k

  Étant donné $\hat{u}^r_t$, $\hat{T}_{a,t}$, ξ_t et D_k, calculer $\bar{u}_t$, u_t et y_t pour $t = kN_c, \ldots, (k+1)N_c - 1$ selon 3.48g, 3.48h, 3.48i et 3.48j

  Étant donné r_t, u_t et y_t ou bien $\bar{u}_t$ et $\bar{u}^*_t$ pour $t = kN_c, \ldots, (k+1)N_c - 1$, évaluer la fonction objectif à $l+1$:

  $J(\{S_{0,k}, \ldots, S_{\tau-1,k}, D_k\}_{l+1}) := \sum_{t=kN_c}^{(k+1)N_c} \rho(\xi_t, D_k)$

  Ajouter le point $\big(\{S_{0,k}, \ldots, S_{\tau-1,k}, D_k\}_{l+1}, J(\{S_{0,k}, \ldots, S_{\tau-1,k}, D_k\}_{l+1})\big)$ au jeu de données :

  $D = \big[\{S_{0,k}, \ldots, S_{\tau-1,k}, D_k\}_{0:l}, [J(\{S_{0,k}, \ldots, S_{\tau-1,k}, D_k\}\rho)]_{\rho=0}^{l}\big]$

  Si $l + 1 = L$ **alors**

    $\xi^*_{kN_c}, \ldots, \xi^*_{(k+1)N_c-1} \leftarrow \xi_{kN_c}, \ldots, \xi_{(k+1)N_c-1}$

    $D^*_k \leftarrow D_k$

  Fin Si

Fin Pour

Sortie: $\xi^*_{kN_c}, \ldots, \xi^*_{(k+1)N_c-1}$, D^*_k

Mise à jour: mettre à jour k (équation 3.48k)

La formulation inverse proposée ici se distingue des formulations classiques du contrôle thermique résidentiel, qui déterminent directement une puissance ou une consigne minimisant un coût. À l'inverse, nous partons d'un profil de puissance cible (issu d'une optimisation indépendante ou d'une heuristique) et nous cherchons les consignes de

température (et/ou rapports cycliques) qui, une fois appliquées aux thermostats réels, reconstituent ce profil. Cette inversion est non triviale car la relation consigne $\rightarrow$ puissance passe par la dynamique non linéaire (saturée) du thermostat ; c'est là l'originalité de la contribution.

Chapitre 4 - Évaluation des solutions aux problèmes inverses

4.1 Introduction

L'objectif de ce chapitre est de présenter les résultats relatifs aux différentes solutions proposées pour résoudre les problèmes inverses et permettre une meilleure gestion efficace de la demande en chauffage. Dans un premier temps, il sera présenté l'infrastructure d'acquisition de donnée. Ensuite, les résultats relatifs à l'identification de paramètres uniques pour les thermostats préinstallée dans une maison habitée faisant l'objet de cette étude seront également présentés. Il sera aussi mis en évidence, à travers un cas d'étude, le potentiel qu'on peut tirer en utilisant les modèles des thermostats pour générer les consignes de température. Pour la partie qui concerne la prédiction du potentiel de réponse à la demande, nous présenterons des résultats sur l'établissement d'un modèle thermique et de la reconstitution des profils des charges résiduelles. Seront également présentés les résultats sur la prédiction du potentiel de DR proprement dite. Enfin, l'efficacité de l'algorithme de contrôle des charges de chauffage basé sur une optimisation inverse sera présentée.

4.2 Acquisition des données

L'architecture d'acquisition de données est la même que dans [13]. Huit plinthes électriques, contrôlées par des thermostats communicants à tension de secteur (LVCTs) à l'intérieur de la maison habitée, ont été considérées. Les plinthes électriques de la maison réelle ont des capacités de chauffage allant de 1 kW à 2 kW. Grâce à un protocole de communication dédié et à une passerelle servant de pont, l'échange d'informations entre les thermostats et un serveur central a été rendu possible. Le rôle principal du serveur est de stocker les données et d'envoyer des commandes aux thermostats via la passerelle (voir

figure 4.1.

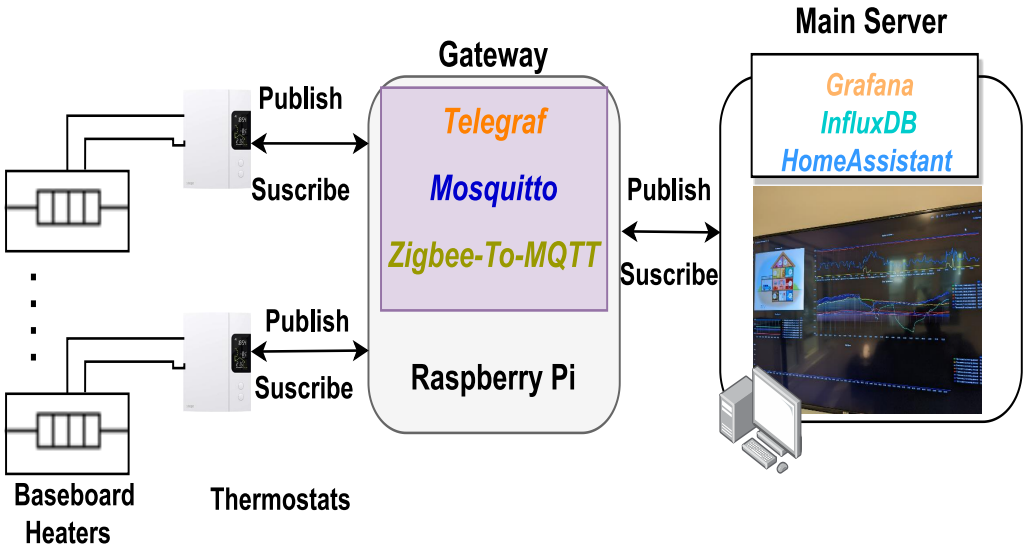


Figure 4.1 Data acquisition architecture.

4.3 Validation de la méthode d'identification des paramètres des thermostats préinstallés

Pour l'implémentation, la méthode proposée *Shrinked-Space Search* (S-SS) a été appliquée pour identifier les paramètres des thermostats à tension de secteur (*Line Voltage Communicating Thermostat*, LVCTs), opérant dans une maison. Les données ont été collectées durant l'hiver, comprenant les consignes appliquées au thermostat, la demande de chauffage et la température intérieure de chaque pièce. La variation de la température intérieure entraîne de nombreuses variations des points de fonctionnement des thermostats afin d'atteindre les consignes souhaitées (voir Fig. 4.2). Un tel comportement fournit un excellent cadre pour tester la méthode *Shrinked-Space Search* (S-SS) proposée, puisque le contrôleur présente différentes dynamiques. Par la suite, la stratégie de suivi du terme intégrateur est effectuée pour découvrir sa logique de mise à jour et démontrer la

convergence des paramètres identifiés avec ceux estimés par la méthode S-SS.

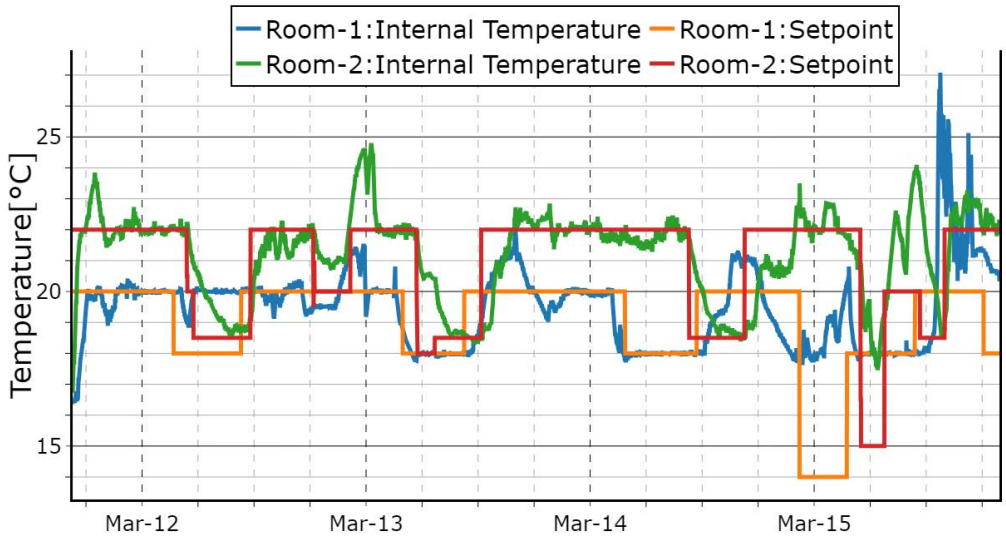


Figure 4.2 Variation persistante de la température intérieure.

4.3.1 Performance de la méthode proposée

L'objectif principal de cette section est de démontrer l'efficacité de la méthode S-SS proposée. Malgré la variabilité des profils due aux différences de confort thermique entre les pièces et aux échanges de chaleur qui influencent la dynamique du contrôleur, cette méthode réduit significativement l'espace de recherche pour les paramètres de réglage de chaque thermostat tout en diminuant l'erreur de précision au cours du processus. La Fig. 4.3 illustre la capacité de l'algorithme de la méthode S-SS à réduire l'erreur d'identification en permettant l'identification des paramètres de réglage. L'erreur absolue moyenne (MAE) est utilisée pour mesurer l'efficacité de la méthode proposée, c'est-à-dire

$$\mathrm{MAE}[\%] = \frac{\sum_{k=1}^{N} |p_t - p_t^o|}{N}, \tag{4.1}$$

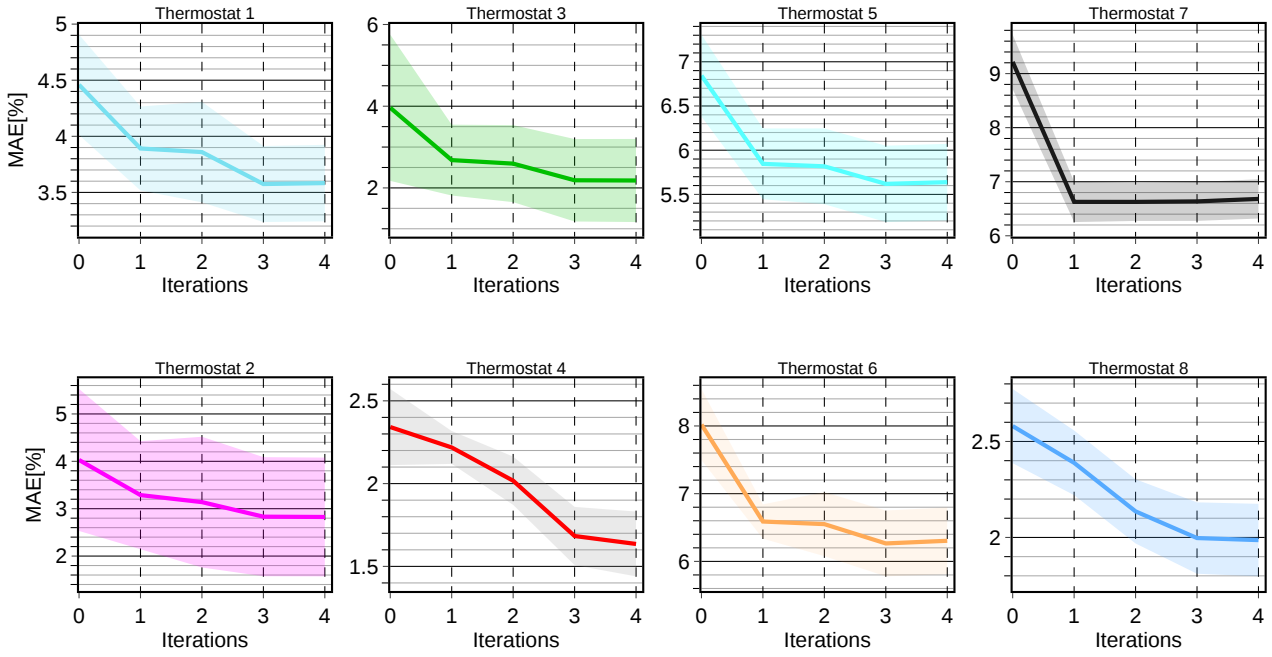


Figure 4.3 Réduction de l'erreur d'estimation.

où N est le nombre de pas de temps et les valeurs p_t^o correspondent à la demande de chauffage (H_d) exprimée en pourcentage de la puissance nominale du chauffage (H_p), c'est-à-dire $p_t^o = (H_{d,t} \times 100)/(H_p)$. L'équation (4.1) exprime l'erreur relative au pourcentage de capacité de chauffage utilisée par un thermostat. Le pourcentage relativement élevé d'erreurs observé pour les thermostats 5 et 7 est imputable aux dimensions des pièces où ces thermostats fonctionnent. Par exemple, nous avons enregistré $366.2 ft^2$ pour la pièce 5 et $288.7 ft^2$ pour la pièce 7, comparé aux autres pièces dont les dimensions varient entre $99 ft^2$ et $244 ft^2$. Par conséquent, ces thermostats ont tendance à consommer davantage pour satisfaire le confort de l'utilisateur, ce qui les maintient la plupart du temps en état de saturation élevé. Cela entraîne moins de données dans la zone linéaire, rendant l'identification un peu plus difficile pour l'algorithme.

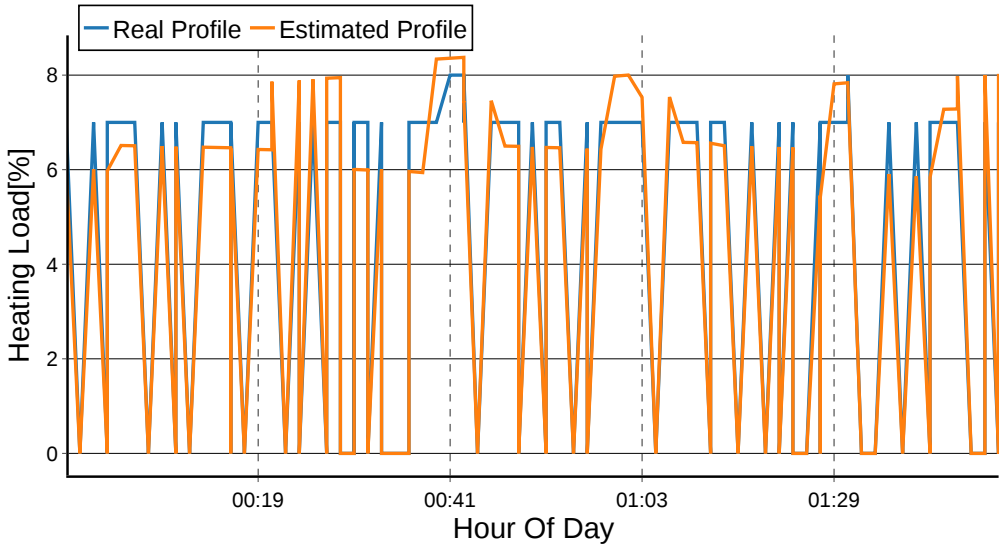


Figure 4.4 Comparaison entre le profil réel et le profil estimé.

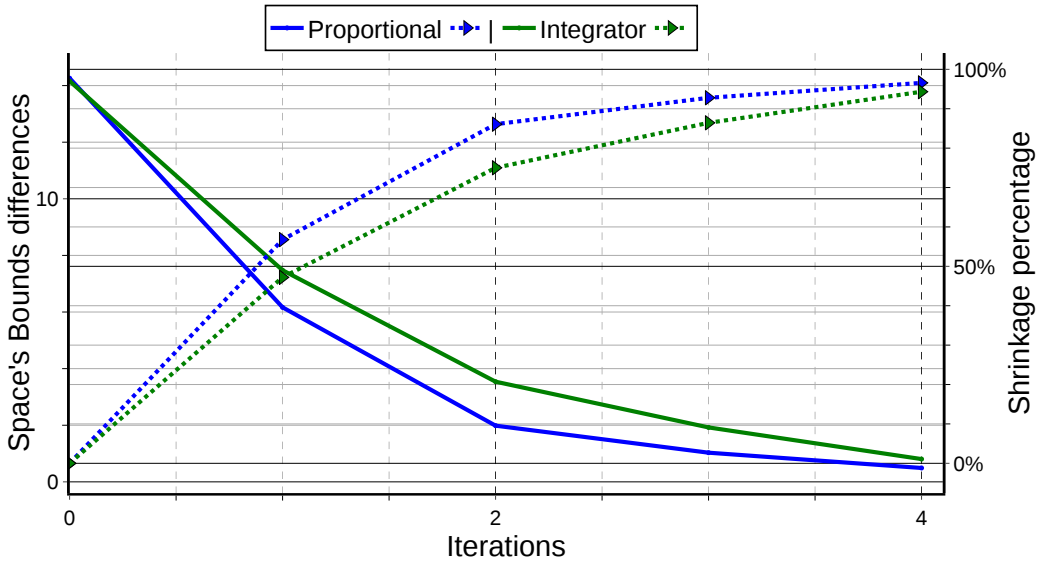


Figure 4.5 Graphique de la différence d'espace de recherche.

De plus, la stratégie de suivi du terme intégrateur permet de découvrir la logique de mise à jour de la partie intégrateur du contrôleur et montre que les paramètres identifiés sont proches de ceux trouvés en utilisant la méthode S-SS basée sur l'inférence statistique

(voir Table 4-1). Ici, σ_{K_p} et σ_{K_i} représentent l'écart-type des gains proportionnels et des gains intégrateurs trouvés à l'aide de la stratégie de suivi intégral, où les conditions initiales sont sujettes à des variations (21 conditions initiales sont utilisées). La Table 4-1 montre que les écarts-types entre les paramètres identifiés pour chaque condition initiale correspondante restent proches de zéro pour le gain proportionnel et autour de 0.2 pour la partie intégrateur. Cela confirme la sensibilité du gain intégrateur aux conditions initiales correspondant à la nouvelle valeur de l'intégrateur après saturation. Néanmoins, cela n'entrave pas l'efficacité de la méthode pour fournir globalement une estimation précise. $\left|\Delta K_p\right|$ et $|\Delta K_i|$ quantifient respectivement la différence des gains proportionnels et des gains intégrateurs obtenus par les deux stratégies différentes. Pour les mêmes raison liées à la sensibilité de la partie intégrateur tel que évoquée précédemment, on observe des valeurs de différences plus stables pour le gain proportionnel que pour le gain intégrateur.

La Fig. 4.4 compare le profil réel de la demande de chauffage pour l'une des plinthes électrique et le profil de demande de chauffage reconstruit (estimé). On peut constater une grande précision dans la reconstruction du profil réel de la demande de chauffage lorsque l'on utilise les paramètres identifiés. La Fig. 4.5 correspond au graphique de la différence entre les bornes de l'espace de recherche. Cela montre la capacité de l'algorithme proposé à réduire l'espace de recherche en diminuant la différence entre les paramètres identifiés pour les données inter-saturation ($K_{\max}^{(l)} - K_{\min}^{(l)}$, $T_{\max}^{(l)} - T_{\min}^{(l)}$) de 96% et 94% respectivement.

En plus de la MAE, la Table 4-2 fournit la performance de la reconstruction de la dynamique des LVCTs en utilisant les paramètres identifiés par la méthode S-SS et la logique de mise à jour du terme intégrateur de la stratégie de suivi, tel que :

$$\text{Performance}[\%] = \left(1 - \frac{\sum_{k=1}^{N} |p_t - p_t^o|}{2\sum_{k=1}^{N} p_t^o}\right) \times 100.$$

Comme on pouvait s'y attendre, les thermostats 5 et 7 présentent une MAE plus élevée et une performance plus faible en raison de la consommation de puissance élevée (thermostat en état de saturation élevé la plupart du temps). À l'inverse, pour le thermostat 6, par exemple, une MAE plus élevée (relativement au niveau de performance affiché) est due à une consommation de puissance faible (thermostat en état de faible saturation la plupart du temps). Cependant, l'algorithme proposé permet d'estimer globalement les paramètres des thermostats avec une performance allant jusqu'à 84% dans le pire des cas et 99% dans le meilleur des cas. L'algorithme *Shrinked-Space Search* retrouve les paramètres du modèle LVCT lorsque la structure de commande est supposée identique à celle d'un contrôleur PI. L'algorithme a convergé vers un optimum suivant une fonction objectif définie. Indépendamment du chauffage et de la sensibilité aux conditions initiales lorsque le contrôleur se sature, l'algorithme a performé avec succès. De plus, le nombre d'itérations nécessaire pour la convergence est raisonnable. Par ailleurs, l'analyse des résultats montre que la persistance de certains contrôleurs à rester en état de saturation n'entrave pas significativement les performances de l'algorithme.

Convergence, complexité et scalabilité (analyse qualitative): Sur le plan de la convergence, l'optimisation bayésienne fait décroître la fonction de dissimilarité à mesure que l'espace de recherche se rétrécit (figure 4.3), et le critère d'arrêt est atteint après un nombre raisonnable d'itérations. Sur le plan de la complexité computationnelle, le coût est dominé par l'ajustement du processus gaussien, dont la complexité croît de manière cubique avec le nombre d'évaluations retenues, et par les simulations du thermostat à chaque évaluation ; le recours à la recherche en espace réduit limite précisément ce

Tableau 4-1 Concordance des paramètres utilisant la stratégie de suivi du terme intégrateur et leur écart par rapport à ceux identifiés par la méthode S-SS

Thermostat	**Écart-type**		$\lvert\Delta K_p\rvert$	$\lvert\Delta K_i\rvert$
	σ_{Kp}	σ_{Ki}		
1	0.0098	0.1446	4.3449	0.3237
2	0.006	0.159	4.3423	0.3186
3	0.0031	0.8163	4.336	0.4077
4	0.0114	0.1927	4.339	0.1654
5	0.0224	0.00012	4.363	0.3977
6	0.0056	0.198	4.352	0.1988
7	0.188	0.1609	4.3	0.2869
8	0.0377	0.1795	4.339	0.1125

Tableau 4-2 Performance dans la reconstruction des profils de demande de chauffage

Thermostat	**MAE[%]**	**performance[%]**
1	3.8913	91.62
2	0.143	99.42
3	0.036	99.75
4	0.477	97
5	7.97	84.12
6	0.227	99.54
7	7.895	87.121
8	1.84	92.191

nombre d'évaluations et conditionne donc le coût global. Enfin, sur le plan de la scalabilité, l'identification est menée indépendamment pour chaque thermostat ; le procédé est donc intrinsèquement parallélisable et passe à l'échelle linéairement avec le nombre de pièces, ce qui le rend applicable à des logements comportant un grand nombre de zones chauffées.

4.3.2 Étude de cas : implémentation d'un programme de DR

La méthode proposée permet de modéliser efficacement les thermostats préinstallés dans les maisons, comme des jumeaux numériques [142], qui jouent le rôle de *clones numériques* pouvant servir à diverses fins, tel que la simulation, les tests, la surveillance et la maintenance. En pratique, elle peut être intégrée dans un agent résidentiel pour apprendre les paramètres des contrôleurs préinstallés en démarrage à froid et permettre de prendre en compte leur dynamique afin de contrôler de manière optimale les charges de chauffage lors de la participation à un programme de DR. En conséquence, nous avons réalisé un programme de DR sur 5 jours, impliquant 14 maisons. Il consiste à mettre en œuvre un (voir Fig. 4.6) pour optimiser la consommation des charges de chauffage dans les maisons résidentielles en utilisant les modèles de thermostats comme contraintes. L'idée principale est qu'en utilisant la dynamique des thermostats et en générant des consignes de température appropriées en réponse aux informations tarifaires, une consommation intelligente des charges de chauffage peut être atteinte. Ce qui implique la création d'un modèle thermo-thermostatique multizone pour 14 maisons, en tenant compte de préférences différentes pour induire une diversité de consommation, la génération de la consommation électrique pour un jour à l'avance (*day-ahead*) basée sur le modèle et les préférences, et la conduite de deux stratégies indirectes de contrôle des charges de chauffage dans un contexte de DR. La première stratégie utilise des heuristiques basées sur la connaissance préalable des périodes de pointe pour ajuster les consignes et réduire la consommation d'énergie [143]. La deuxième stratégie s'appuie sur la méthode proposée pour reconstruire la dynamique des thermostats, les signaux de prix selon les périodes d'utilisation et les préférences des occupants afin de générer des profils de consignes optimaux pour utiliser efficacement les charges de chauffage en réponse aux tarifs.

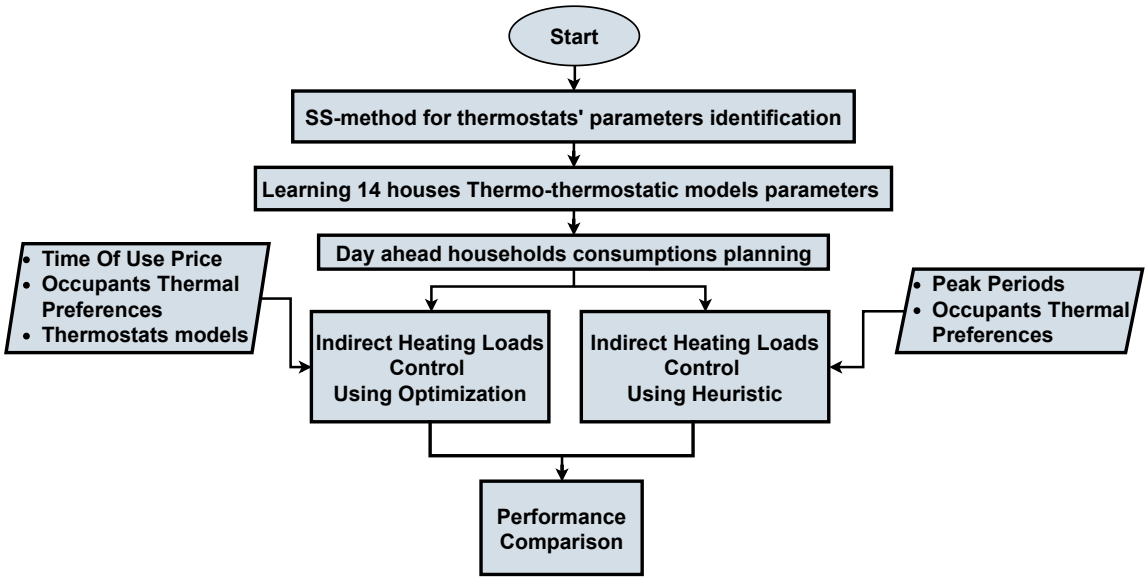


Figure 4.6 DR avec modèles de thermostats établis.

La Fig. 4.7 montre les résulats obtenus dans le cadre du scénario de DR. Dans la Fig. 4.7-(a), la consigne dite ”intelligente” correspond à la consigne générée en utilisant les modèles de thermostats comme contraintes dans un problème d'optimisation. La consigne heuristique correspond à celle générée uniquement à partir de la connaissance des périodes de pointe. La Fig. 4.7-(b) compare les profils de consommation résultants en utilisant les consignes obtenues à partir des deux stratégies. La ligne verte pointillée dans la Fig. 4.7-(a) correspond à la température de référence pour maintenir une courbe aplatie de la consommation électrique (ligne verte pointillée dans la Fig. 4.7-(b)).

Le fait de tirer parti de la dynamique des thermostats pour générer la consigne a permis de répondre à la consommation d'électricité en fonction du prix (courbe turquoise), où les chauffages semblent s'éteindre pendant une période de prix élevé ou consommer moins que dans le cas où des consignes basées sur des heuristiques sont utilisées. Par conséquent, la consigne de température générée permet de contrôler inversement la consommation d'énergie de manière automatisée en préchauffant les maisons en réponse aux tarifs selon

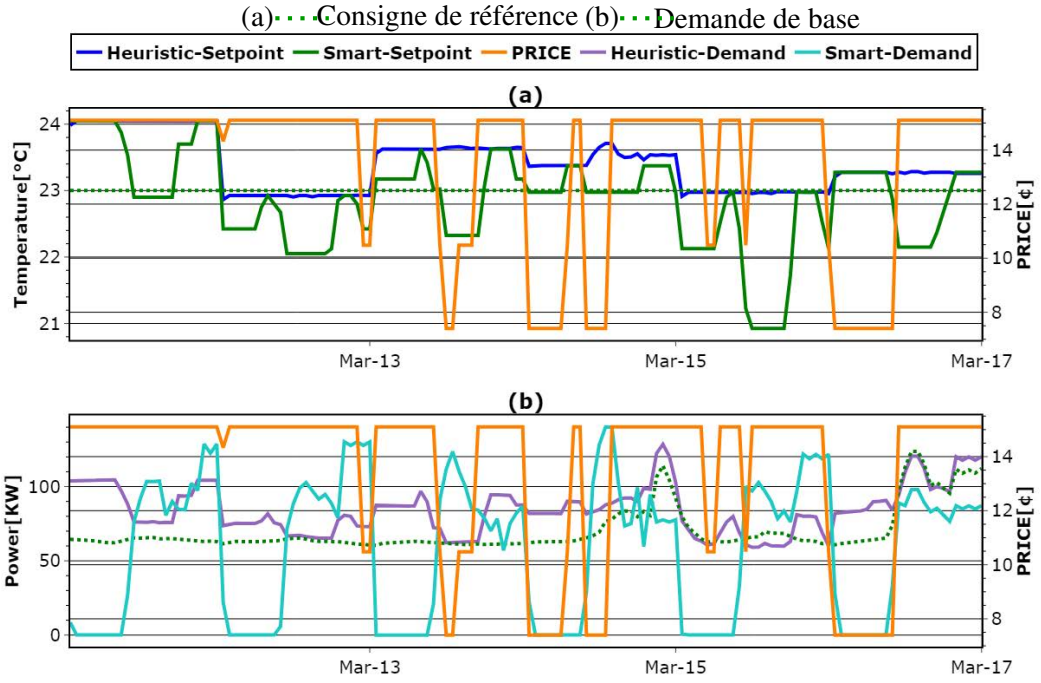


Figure 4.7 Résultat du cadre de DR mis en œuvre.

les périodes d'utilisation. Cela a été possible en intégrant les modèles de thermostats pour disposer de leur flexibilité et d'aboutir à une consommation "intelligente" dans le cadre de DR.

4.4 Validation de la méthode de prédiction du potentiel de réponse à la demande

Nous nous appuyons sur des données collectées durant l'hiver dans une maison habitée pour valider les méthodes proposées. Les données comprennent : les consignes des thermostats, la demande de chauffage et la température intérieure de chaque pièce de la maison. Nous effectuons d'abord l'identification des paramètres et la reconstitution des profils de charges résiduelles. Nous utilisons ensuite les paramètres identifiés de la maison réelle pour générer des données synthétiques de maisons simulées, notamment les températures et les données de demande de chauffage. Nous assurons la diversité des

données simulées en définissant une large gamme de capacités de chauffage, de profils de charges résiduelles et de profils de consignes servant d'entrées à la simulation. Il en résulte une variété de demandes de chauffage et de températures intérieures produites par le même modèle thermique. Avec cette configuration, nous appliquons la procédure d'identification et d'estimation afin d'examiner l'efficacité de la méthode proposée dans la restitution des mêmes paramètres pour l'ensemble des maisons simulées et dans la reconstruction des profils de charges résiduelles qui leur sont associés. Par la suite, la procédure de prédiction du potentiel de demande à la réponse décrite dans la section 3.3.2 est testée sur la maison réelle.

Comme mentionné ci-dessus, une large gamme de capacités de chauffage (puissance nominale des chauffages), de profils de charges résiduelles et de profils de consignes est considérée pour la génération de données des maisons simulées. L'algorithme 4 illustre la procédure de génération des données pour une maison donnée. On note $H_p^{(n)}$ la puissance nominale du chauffage de la n-ième pièce de la maison, qui est générée à partir d'une loi uniforme ayant pour bornes $H_{p,min}$ et $H_{p,max}$, respectivement la capacité minimale et maximale autorisée. Chaque maison simulée est équipée de 8 thermostats communicants à tension de ligne (LVCT), et chaque plinthe a une capacité de chauffage allant de 1 kW à 2,5 kW. Un bruit coloré, d'amplitude ne devant pas dépasser 10% de $H_p^{(n)}$, est ensuite généré sur la période $[0, T]$ au moyen de la fonction $ColoredNoiseFunc(\cdot)$. Cette fonction est conçue pour garantir que le bruit ait des valeurs proches de zéro sur une période spécifique de la journée (ce qui est essentiel pour l'identification des paramètres du modèle RC sans charges résiduelles). La procédure de génération du bruit peut être décrite comme suit:

- Créer un bruit à l'aide de l'algorithme de Voss–McCartney [144].
- Mettre à l'échelle le bruit généré afin qu'il corresponde à la plage cible

$[-10\%H_p^{(n)}; +10\%H_p^{(n)}]$.

- Créer une série temporelle à partir des valeurs du bruit.
- Appliquer un facteur d'échelle aux valeurs comprises entre 0 h 00 et 6 h 00 (données de nuit) afin de réduire l'effet du bruit.

Le bruit coloré généré $\phi^r_{n,0:T}$ représente la charge résiduelle agissant dans la pièce n. La consigne $\xi_{n,t}$ de la pièce n reste constante et égale à ξ_n pendant d pas de temps ; ξ_n est obtenue à partir d'une loi uniforme avec ξ_{min} et ξ_{max} comme valeurs minimale et maximale respectivement. De nouvelles valeurs de ξ_n et d sont proposées à la fin de chaque d pas de temps ; d prend soit la valeur d_{min}, soit la valeur d_{max} en fonction d'une variable binaire β tirée d'une loi de Bernoulli. Précisément, β est une variable aléatoire de Bernoulli de paramètre 0,5, c'est-à-dire $\beta \in \{0,1\}$ avec $\Pr(\beta = 1) = \Pr(\beta = 0) = 0{,}5$. À chaque tirage, $\beta = 1$ sélectionne la durée $d_{\min}$ et $\beta = 0$ sélectionne $d_{\max}$ (cf. l'instruction $d \leftarrow \beta\, d_{\min} + (1-\beta)\, d_{\max}$ de l'algorithme) ; les deux durées sont donc choisies de manière équiprobable. Les charges résiduelles et les profils de consignes générés sur la période $[0,T]$, respectivement $\phi^r_{n,0:T}$ et $\xi_{n,0:T}$ $(n = 1, \cdots n_x)$, sont utilisés pour simuler la maison et obtenir la demande de chauffage correspondante ainsi que la température intérieure en utilisant le modèle thermo-thermostatique défini en (3.30).

L'objectif principal est de présenter les résultats relatifs à l'identification des paramètres du modèle thermique et au recouvrement des charges résiduelles, aussi bien pour les maisons réelles que simulées. Les résultats liés à la prédiction du potentiel de demande à la réponse pour la maison réelle seront également présentés.

Algorithme 4 Procédure de génération de données pour une maison simulée

Pour $n = 1$ to n_x **faire**
  $t \leftarrow 0$
  $H_p^{(n)} \sim Uniform(H_{p,min}, H_{p,max})$
  $\phi^r_{n,0:T} \leftarrow ColoredNoiseFunc(0.1 \cdot H_p^{(n)})$
  Tant que $t < T$ **faire**
    $\xi_n \sim Uniform(\xi_{\min}, \xi_{\max})$
    $\beta \sim Bernoulli(0.5)$
    $d \leftarrow \beta \cdot d_{\min} + (1-\beta) \cdot d_{\max}$
    $d \leftarrow \min(d, T-t)$
    Pour $i = 0$ to $d-1$ **faire**
      $\xi_{n,t+i} \leftarrow \xi_n$
    Fin Pour
    $t \leftarrow t + d$
    $\xi_{\max} \leftarrow \xi_n$
  Fin Tant que
Fin Pour
Simulation de la maison au moyen de (3.30) (avec $\theta = \theta^*$)

4.4.1 Résultats d'identification et de réconstitution des GRLs pour la maison réelle

Sur la base de 3.34, les paramètres du modèle RC sans charges résiduelles ont été identifiés en s'appuyant sur une séquence de données où les charges résiduelles sont supposées etre proches de zéro. Les séquences de nuit sont utilisées en supposant qu'elles sont peu susceptibles d'être *corrompues* par des charges résiduelles. Par la suite, les paramètres identifiés peuvent être utilisés pour retrouver les profils de charges résiduelles et leurs facteurs de pondération associés via les équations (3.35) et (3.37). Pour consolider cette hypothèse, les distributions des charges résiduelles après reconstitution, en considérant différents intervalles de temps, sont présentées à la figure 4.8. Comme on peut l'observer, les valeurs des charges résiduelles entre $[0am : 6am]$ et $[6am : 12am]$ sont plus proches de zéro. Ces observations confirment l'hypothèse du choix des séquences de nuit pour l'identification du modèle RC sans charges résiduelles.

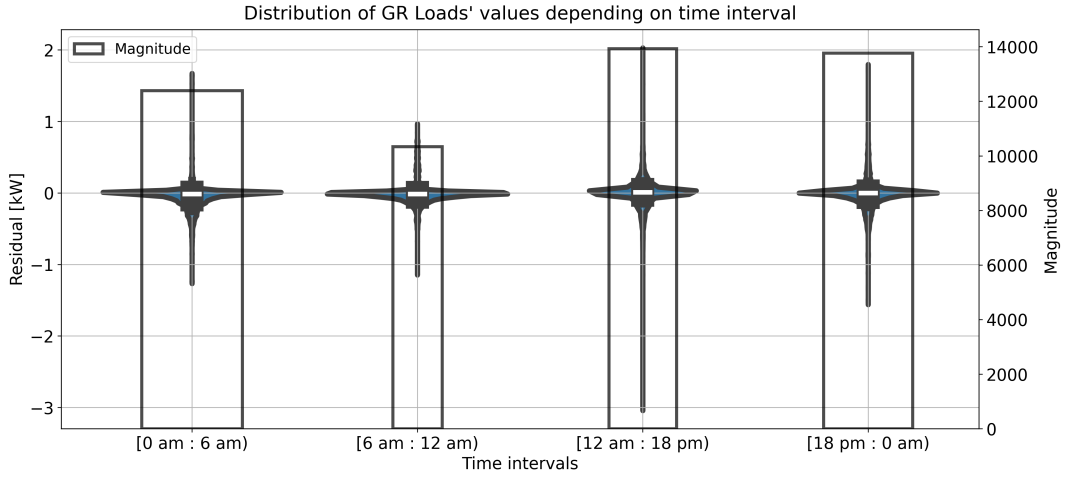


Figure 4.8 Distribution des GR Loads

En ce qui concerne l'identification, les données ont été divisées en séquences d'entraînement et de validation. Dans le tableau 4-3, nous avons présenté les températures moyennes et l'erreur absolue moyenne (MAE) des séquences pour les ensembles d'entraînement et de validation. Dans la plupart des cas, l'erreur MAE apparaît plus faible pour les séquences de validation de puissance que pour les séquences d'entraînement. Cela s'explique par le fait que la demande de chauffage diminue progressivement avec le temps, entraînant une valeur de puissance plus faible. Par conséquent, la MAE est affectée en ce sens. Cependant, pour la température, la MAE relative aux séquences de validation semble être plus élevée dans la plupart des cas que celle des séquences d'entraînement. Pour l'ensemble des données, on observe une MAE qui n'a pas dépassé 0.64°C pour la température et 0.121 kW pour la puissance. On note également une précision allant jusqu'à 98.6% pour la température et jusqu'à 99.31% pour la puissance. Dans le pire des cas, les valeurs de charges résiduelles se situent dans une plage acceptable avec 70% des valeurs comprises dans $\pm 10\% H_p^{(n)}$ de la puissance nominale correspondante. Dans le meilleur des cas, jusqu'à 98.66% de la puissance se situe dans la plage acceptable. Une valeur de MAE égale à 0(*), survient notamment lorsque la puissance est presque nulle.

Tableau 4-3 Résumé des résultats d'identification et de réconstitution des charges résiduelles pour la maison réelle

Pièce	MAE Moyenne (des séquences)				Toutes les données				
	Température [°C]		Puissance [kW]		Température		Puissance		GRLs
	Entrainement	validation	Entrainement	Validation	MAE [°C]	Performance [%]	MAE [kW]	Performance [%]	$[-10\%H_p^{(n)};+10\%H_p^{(n)}]$
1	0.47	0.35	0.058	0.041	0.39	98.05	0.043	95.66	85.16
2	0.18	0.33	0.004	0.005	0.26	98.59	0.007	99.31	96.63
3	0.23	0.29	0.007	0.006	0.25	98.52	0.009	99.27	98.66
4	0.25	0.37	0.025	0.007	0.29	98.24	0.023	98.16	91.28
5	0.93	0.65	0.142	0.133	0.63	96.86	0.121	95.65	78.6
6	0.32	0.43	0.007	0 (*)	0.36	98.35	0.011	99.02	70.35
7	0.63	0.54	0.066	0.039	0.64	97.09	0.101	95.04	81.67
8	0.26	0.27	0.021	0.016	0.26	98.6	0.031	96.94	84.62

La figure 4.9 montre que le modèle établi de la maison est capable de reconstruire la température intérieure moyenne avec une précision de 98.19% (MAE de 2.78 °C). La puissance agrégée de la maison a également été reconstruite avec une précision de 92.44%, correspondant à une MAE de 0.26 kW.

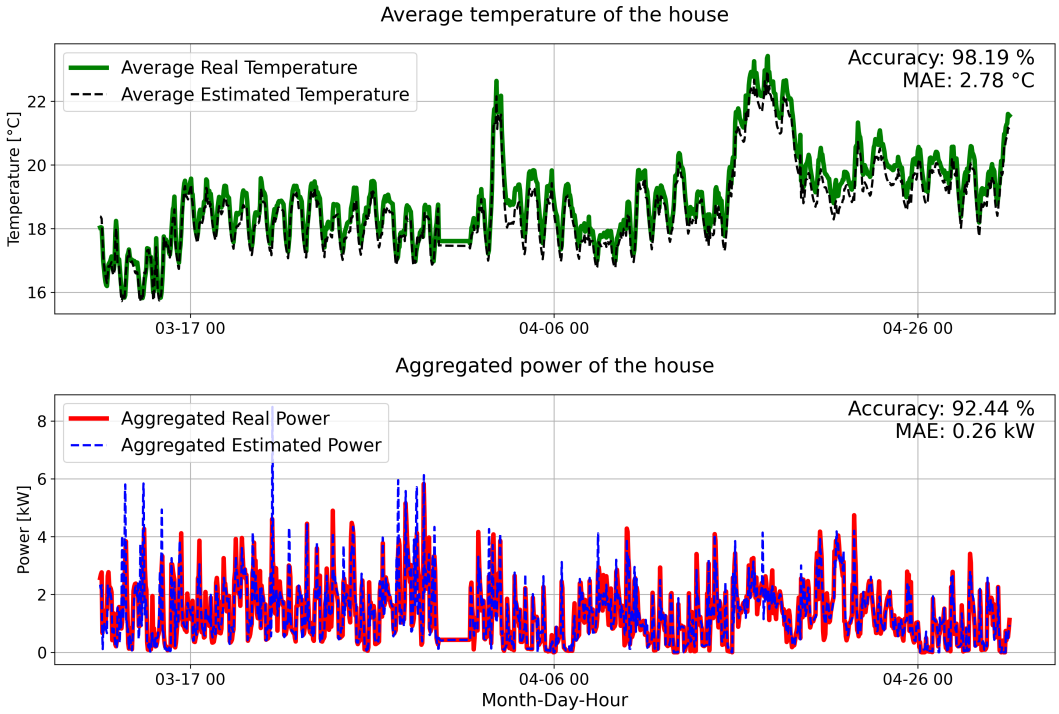


Figure 4.9 Puissance agrégée et température moyenne pour la maison réelle

4.4.2 Résultats d'identification et de réconstitution des GRLs pour les maisons simulées

La figure 4.10 présente la distribution (en termes de percentile) de la température moyenne et de la consigne moyenne des maisons simulées. La distribution de la puissance agrégée des maisons simulées est également présentée. La distribution des capacités de chauffage installées dans les maisons est aussi illustrée.

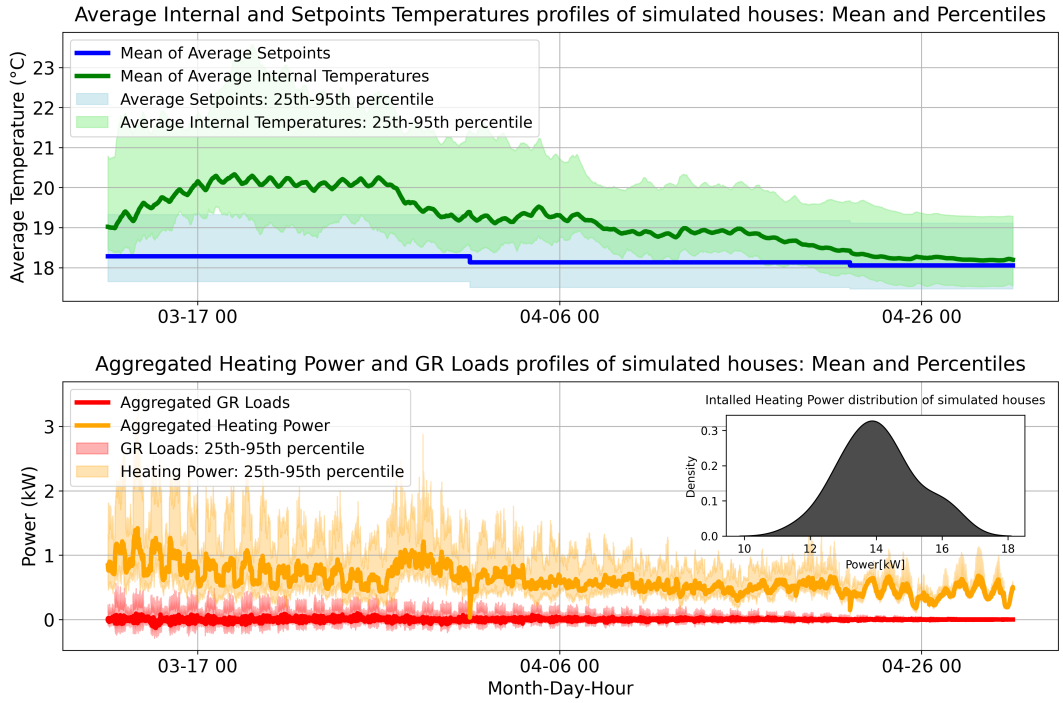


Figure 4.10 Distribution des données des maisons simulées

Comme la diversité des profils de maison est désormais garantie, nous pouvons appliquer la même procédure que pour la maison réelle afin d'identifier le modèle thermique des maisons. Sachant que les profils sont générés à partir des mêmes paramètres, les paramètres identifiés devraient avoir approximativement les mêmes valeurs. Pour cela, une mesure de similarité entre les matrices réelles (notamment les matrices A,B et C de l'équation 3.29) et les matrices identifiées de chaque maison est établie. La figure 4.11 présente le pourcentage moyen de similarité des matrices des maisons simulées avec les matrices réelles. On observe que la procédure d'identification fonctionne assez bien avec une moyenne des pourcentages de similarité de 93%, 78% et 70% respectivement pour les matrices A, B et C.

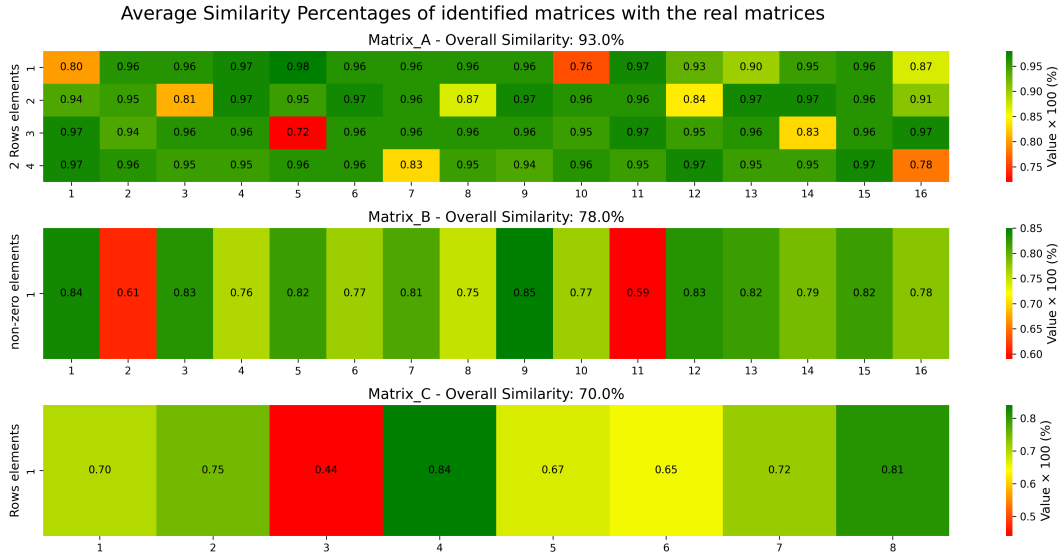


Figure 4.11 Pourcentages moyens de similarité des matrices identifiées avec les matrices réelles

Voir le tableau 4-4 pour le résumé des résultats d'identification et de reconstitution des profils des charges résiduelles des maisons simulées. Nous rapportons les valeurs minimales et maximales des MAEs pour la température et la puissance, tant pour les séquences d'entraînement que de validation. On retrouve également les plages de MAE et de performance (en pourcentage de précision) pour la température, la puissance et les GRLs (charge résiduelles) pour l'ensemble du jeu de données. On peut aussi observer à travers la figure 4.12, la qualité d'estimation de la température intérieure moyenne des maisons (99% de précision et MAE de 2.08 °C). Pour la moyenne de la puissance de chauffage agrégée, nous atteignons 96% de précision, et pour la moyenne des charges résiduelles agrégées, jusqu'à 93.37% de précision. Comme mentionné précédemment, une valeur de MAE égale à 0(*) survient notamment lorsque la puissance est presque nulle.

Tableau 4-4 Résultats d'identification et de reconstitution des profils de charges résiduelles pour les maisons simulées

Pièce	MAE Moyenne (des séquences)				Toutes les données					
	Température [°C]		Power [kW]		Température		Power		GRLs	
	Entrainement	validation	Entrainement	Validation	MAE [°C]	Performance [%]	MAE [kW]	Performance [%]	MAE [kW]	Performance [%]
1	[0.07;0.2]	[0.04;0.18]	[0.008;0.023]	[0.005;0.023]	[0.06;0.19]	[99.12;99.64]	[0.01;0.022]	[92.71;98.94]	[0.01;0.042]	[95.41;98.8]
2	[0.06;0.18]	[0.03;0.15]	[0.002;0.022]	[0.002;0.016]	[0.05;0.15]	[99.21;99.72]	[0.005;0.019]	[91.75;99.26]	[0.003;0.025]	[92.57;99.75]
3	[0.06;0.13]	[0.03;0.12]	[0.003;0.022]	[0(*);0.016]	[0.05;0.12]	[99.41;99.75]	[0.003;0.017]	[96.26;99.37]	[0.002;0.029]	[95.07;99.61]
4	[0.05;0.1]	[0.03;0.08]	[0.002;0.024]	[0(*);0.014]	[0.04;0.08]	[99.54;99.8]	[0.002;0.015]	[96.39;99.71]	[0.002;0.018]	[93.03;99.45]
5	[0.05;0.09]	[0.02;0.06]	[0(*);0.015]	[0(*);0.013]	[0.04;0.07]	[99.61;99.8]	[0.001;0.012]	[93.03;99.69]	[0.004;0.017]	[88.25;99.54]
6	[0.06;0.14]	[0.03;0.13]	[0.005;0.026]	[0.001;0.017]	[0.05;0.12]	[99.39;99.71]	[0.008;0.02]	[91.47;99.0]	[0.008;0.045]	[91.66;99.21]
7	[0.05;0.14]	[0.03;0.09]	[0.001;0.021]	[0(*);0.013]	[0.04;0.11]	[99.41;99.73]	[0.002;0.014]	[95.72;99.63]	[0.002;0.017]	[85.22;99.8]
8	[0.04;0.14]	[0.03;0.08]	[0.004;0.018]	[0.002;0.017]	[0.04;0.1]	[99.37;99.79]	[0.004;0.017]	[95.6;99.26]	[0.004;0.024]	[93.29;99.78]

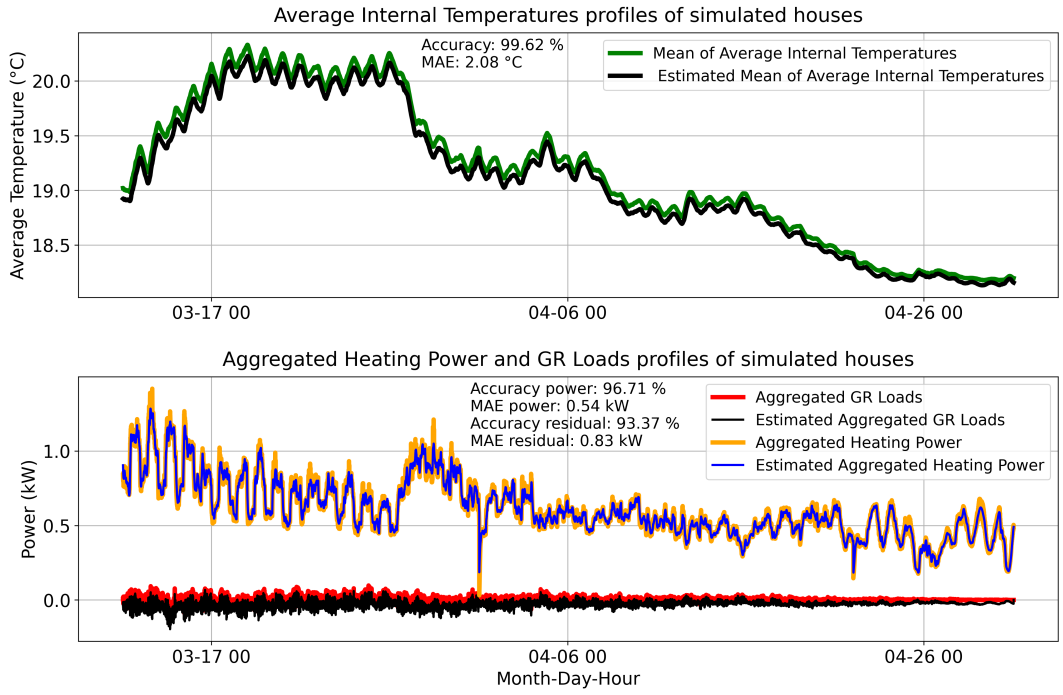


Figure 4.12 Qualité d'estimation de la température, des charges de chauffage et des charges résiduelles

4.4.3 Résultats de la prédiction du potentiel de demande à la réponse pour la maison réelle

Il s'agit des résultats de la procédure de prédiction du potentiel de DR, décrite dans la section 3.3.2. Elle évalue également la prédiction en temps réel de la température et de la demande de chauffage de la maison en s'appuyant sur le modèle thermo-thermostatique établi et sur le modèle autorégressif de prédiction des charges résiduelles. Le tableau suivant donne une description des variables qui feront l'objet de la comparaison.

Tableau 4-5 Variables de comparaison

	Température/Température prédite	**Puissance Chauffage/Puissance Chauffage prédite**	**ERR/EER prédit**	**CE/CE Prédit**
Reférence	$\bar{Y}^{ref}/\hat{\bar{Y}}^{ref}$	$\bar{U}^{ref}/\hat{\bar{U}}^{ref}$	–	–
Potentiel	$\bar{Y}^{p}/\hat{\bar{Y}}^{p}$	$\bar{U}^{p}/\hat{\bar{U}}^{p}$	$\gamma_t^p/\hat{\gamma}_t^p$	$\eta_t^p/\hat{\eta}_t^p$
Effective	$\bar{Y}/\hat{\bar{Y}}$	$\bar{U}/\hat{\bar{U}}$	$\gamma_t/\hat{\gamma}_t$	$\eta_t/\hat{\eta}_t$
Measuré	$\bar{Y}^{m}$/NA	$\bar{U}^{m}$/NA	–	–

Dans le tableau 4-5, ERR et CE désignent respectivement le taux de réduction d'énergie (*Energy Reduction Ratio*) et l'efficacité de confort (*Comfort Efficiency*). Comme $\bar{Y}^{ref}/\hat{\bar{Y}}^{ref}$ correspondent à la température moyenne de référence/température de référence prédite (de la maison) lorsque des consignes définies par l'utilisateur sont utilisées pour la simulation, elles seront comparées avec $\bar{Y}^{m}$ qui correspond à la température moyenne mesurée de la maison réelle. De même, $\bar{U}^{ref}/\hat{\bar{U}}^{ref}$, c'est-à-dire la demande de chauffage de référence prédite/demande de chauffage de référence (agrégée), seront comparées avec $\bar{U}^{m}$ (demande de chauffage mesurée de la maison réelle). Ces comparaisons consolident l'efficacité du modèle thermo-thermostatique établi et du modèle AR pour la prédiction des charges résiduelles. Les variables $\bar{U}^{p}/\hat{\bar{U}}^{p}$, $\bar{Y}^{p}/\hat{\bar{Y}}^{p}$ sont rapportées car elles servent à calculer $\gamma_t^p/\hat{\gamma}_t^p$ et $\eta_t^p/\hat{\eta}_t^p$ respectivement via (3.42) et l'équation (3.43).

La prédiction du potentiel de DR est réalisée en considérant des cas où l'heuristique

est basée sur la modulation du rapport cyclique. Différents niveaux de facteur de confort (φ) sont également pris en compte : Élevé, Moyen et Faible. Deux horizons de mise à jour ou de contrôle (N_c) sont testés, un horizon de contrôle de 60 min et un horizon de contrôle de 15 min. Le tableau 4-6 regroupe les résultats relatifs aux différents cas ; D représente l'ajustement du rapport cyclique, H, M et L signifient respectivement besoin de confort élevé, moyen et faible. Par exemple, $''D_H_60''$ signifie que l'ajustement du rapport cyclique est employé, avec un besoin de confort élevé, et une mise à jour est effectuée toutes les 60 min. Concernant le cas de test (cas 1 de l'étape 2 à la section 3.3.2), nous supposons que les séquences de consignes potentielles ou les séquences de rapport cyclique potentielles sont effectivement appliquées à la maison comme choix optimal ; la température effective, la puissance de chauffage, l'EER et le CE correspondent donc aux valeurs potentielles (c.-à-d., $\hat{\bar{Y}}_t = \hat{\bar{Y}}_t^p, \bar{Y}_t = \bar{Y}_t^p$, $\hat{\bar{U}}_t = \hat{\bar{U}}_t^p, \bar{U}_t = \bar{U}_t^p$, $\hat{\gamma}_t = \hat{\gamma}_t^p, \gamma_t = \gamma_t^p$, $\hat{\eta}_t = \hat{\eta}_t^p, \eta_t = \eta_t^p$).

Tableau 4-6 Résumé des résultats de la prédiction du potentiel de DR

Moyenne	D_H_60	D_H_15	D_M_60	D_M_15	D_L_60	D_L_15
$\hat{\gamma}_t/\hat{\gamma}_t^p - \gamma_t/\gamma_t^p$	0.5–0.48	0.47–0.47	0.55–0.54	0.52–0.52	0.65–0.64	0.62–0.62
$\hat{\eta}_t/\hat{\eta}_t^p - \eta_t/\eta_t^p$	48%–46%	46%–46%	48%–46%	47%–46%	49%–47%	47%–46%
Coût final d'énergie [CAD]						
$\hat{C}/\hat{C}^p - C/C^p$	33.53–33.41	33.38–33.53	33.04–32.95	32.95–33.09	32.22–32.14	32.12–32.27
$\hat{C}^{ref} - C^{ref}$	37.38–37.11	36.94–37.11	37.38–37.11	36.94–37.11	37.38–37.11	36.94–37.11
MAE [°C]	Mise à jour 60 min			Mise à jour 15 min		
$(\hat{\bar{Y}}^{ref}, \bar{Y}^m)$	0.21			0.19		
$(\bar{Y}^{ref}, \bar{Y}^m)$	0.18					
$(\hat{\bar{U}}^{ref}, \bar{U}^m)$	0.01			0.01		
$(\bar{U}^{ref}, \bar{U}^m)$	0.0					
Coût final d'énergie [CAD]						
$\hat{C}^{ref} - C^{ref} - C^m$	37.38–37.11–37.11			36.94–37.11–37.11		

Le tableau 4-6 montre que le modèle thermo-thermostatique peut reproduire la demande de chauffage et la température, comme le montrent les résultats des MAEs. En effet, on s'attend à ce qu'un horizon de mise à jour plus court conduise à de meilleurs résultats (0.21 °C pour une mise à jour de 60 min et 0.19 °C pour une mise à jour de 15 min). On peut voir la qualité de l'estimation à travers la figure 4.13. L'heuristique d'ajustement du rapport cyclique montre un bon compromis entre le ratio de réduction d'énergie (ERR) et l'efficacité de confort (CE). Par exemple, pour le cas $''D_H_60''$, nous avons 48% de coupure de puissance pendant l'événement DR et une efficacité de confort de 46% en moyenne. À noter que la manière dont l'équation d'efficacité de confort a été conçue (équation 3.43) suggère qu'une CE d'environ 36% signifie : le contrôle fonctionne aussi bien que le cas de référence. Donc 46% de CE est une excellente valeur en ce sens. Voir la figure 4.14 pour la moyenne mobile cumulative (CMA) de la consommation obtenue par l'application de la stratégie de modulation du rapport cyclique. La CMA de la consommation de référence est également montrée.

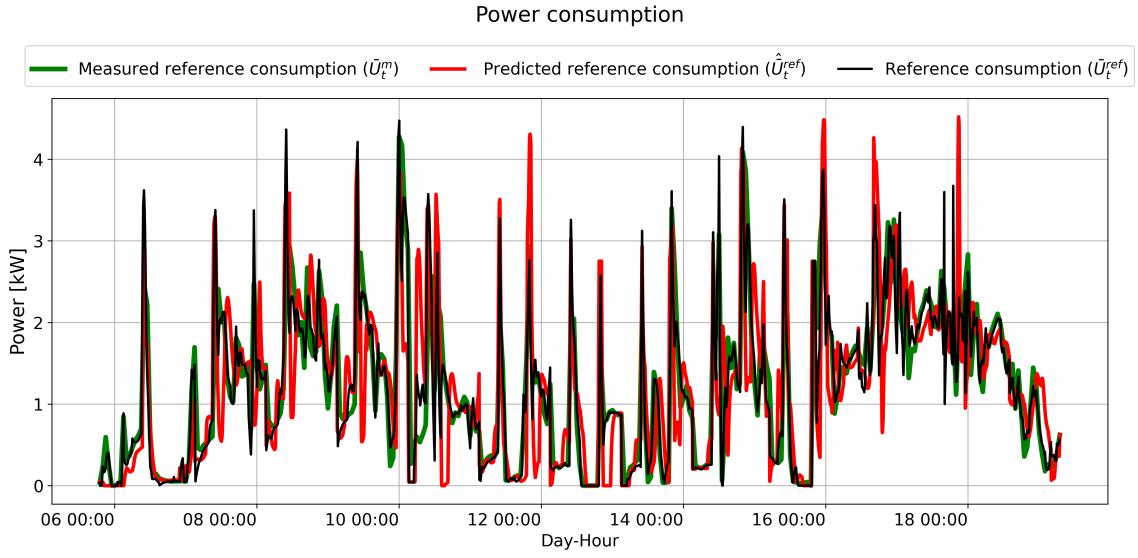


Figure 4.13 Qualité d'estimation, consommation mesurée vs consommation de référence

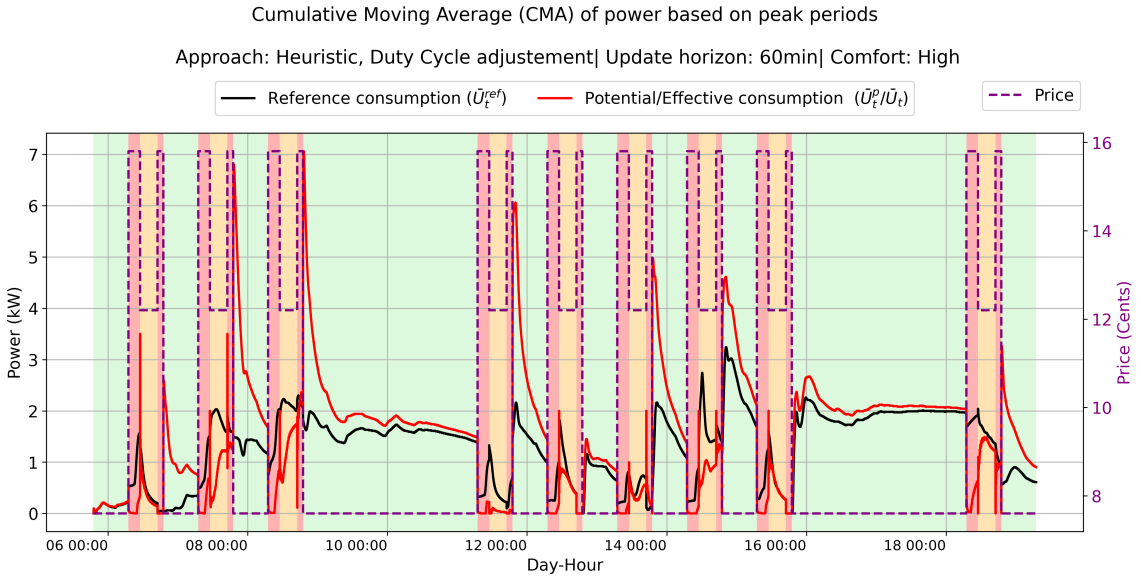


Figure 4.14 Résultat du contrôle par ajustement du rapport cyclique

4.5 Validation de l'algorithme de contrôles des charges de chauffage basé sur une optimisation inverse

Comme dans nos travaux précédents [13], nous considérons huit plinthes électriques contrôlées par des thermostats communicants en tension secteur (LVCTs) à l'intérieur de la maison habitée. Nous nous appuyons sur le modèle établi de cette maison pour tester les approches de contrôle proposées dans un contexte de réponse à la demande (DR). Comme mentionné à la section 3.4.3, trois cas sont retenus :

- "Approche directe et non adaptative",
- "Approche directe et adaptative",
- "Approche inverse et adaptative".

Nous avons reporté dans le tableau 4-7 les résultats de l'algorithme testé pour les cas mentionnés ci-dessus. L'horizon de mise à jour ou horizon de contrôle choisi est

$N_c = 60 min$. Le niveau de confort requis est élevé ($\varphi = 0.75$), avec $n_c = 1$ (une seule valeur de consigne par pas de mise à jour k). En moyenne, les cas directs et adaptatifs montrent un ratio de réduction d'énergie de 0.32 et une efficacité de confort (CE) de 58%. Cela signifie que la puissance observée en condition de fonctionnement normal a été réduite de 32%. Concernant la CE, 58% est une excellente valeur puisqu'elle signifie que le confort est maintenu plus efficacement qu'en condition normale. En fait, comme nous l'avons déjà mentionné das la section 4.4.3, la manière dont l'équation de la CE (3.47) est conçue suggère qu'une valeur de $\sim 36\%$ implique que la stratégie de contrôle optimale fait aussi bien que dans une condition de fonctionnement normale. Le coût énergétique final associé à l'approche directe et adaptative est de 32.36 $, soit 5$ de moins que l'énergie achetée dans le cas de référence sur environ deux semaines. Dans le cas inverse et adaptatif, où nous cherchons à retrouver une consommation optimale, nous avons pu observer que le coût final de la puissance optimale a été presque parfaitement retrouvé. Cela est encore plus clairement mis en évidence par la figure 4.15, qui montre que la courbe du coût énergétique effectif coïncide avec le coût énergétique optimal. En effet, nous pouvons observer dans la figure 4.16 que l'approche inverse peut reproduire le profil de consommation optimal.

Tableau 4-7 Résumé des résultats de contrôle

Approche		Moyenne γ_t	Moyenne η_t	Coût énergétique final	Coût optimal	Coût de référence
Directe	Adaptative	0.32	58%	32.36 $	–	37.11 $
	Non adaptative	0.16	59%	34.86 $	–	
Inverse	Adaptative	0.36	51%	33.58 $	33.53 $	

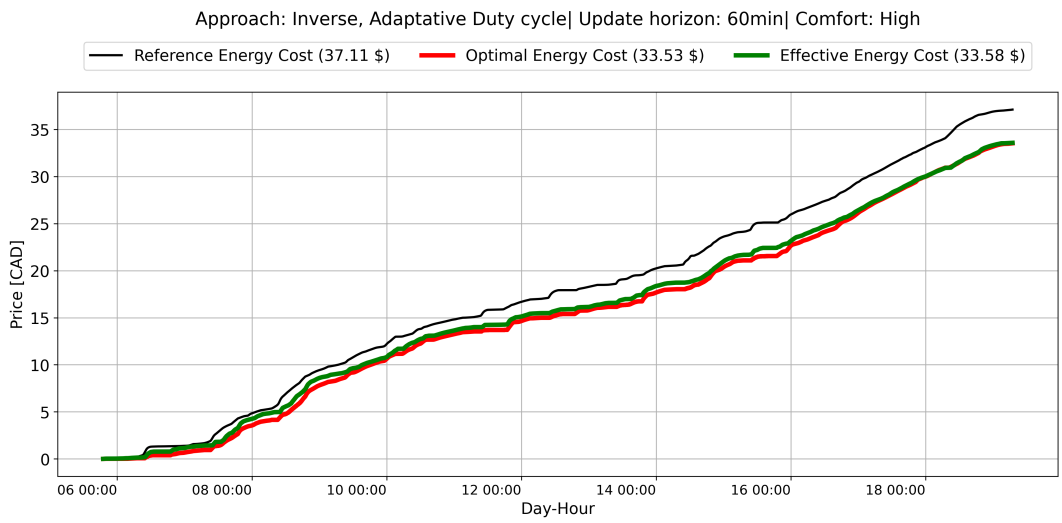


Figure 4.15 Coût énergétique

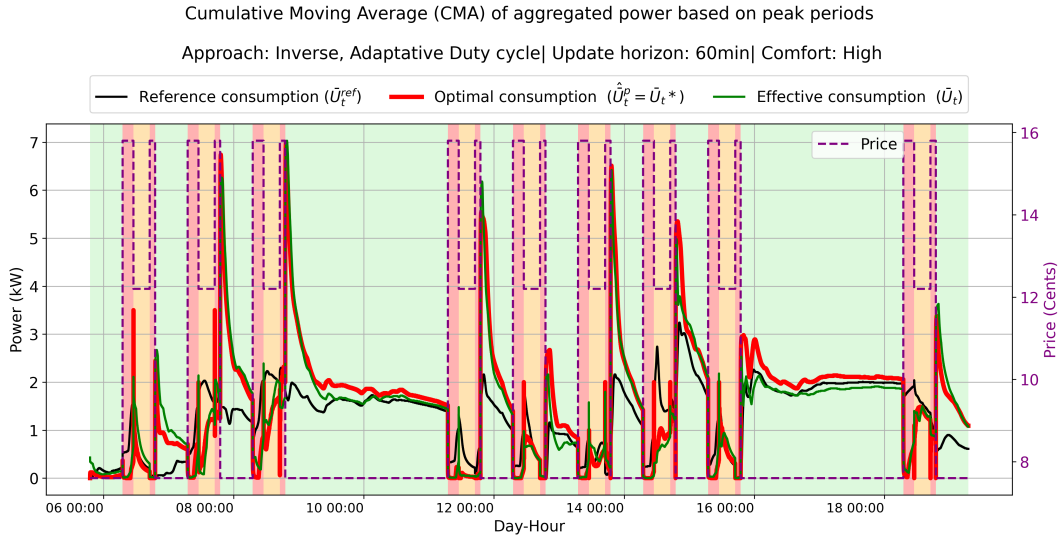


Figure 4.16 Reconstitution de la puissance optimale

Les profils prédits et révélés du ratio de réduction d'énergie (ERR) et de l'efficacité de confort (CE) sont présentés respectivement dans les figures 4.17 et 4.18. Ils montrent à quel point l'approche inverse est capable de fournir une réduction substantielle de puissance tout en maintenant un bon niveau de confort.

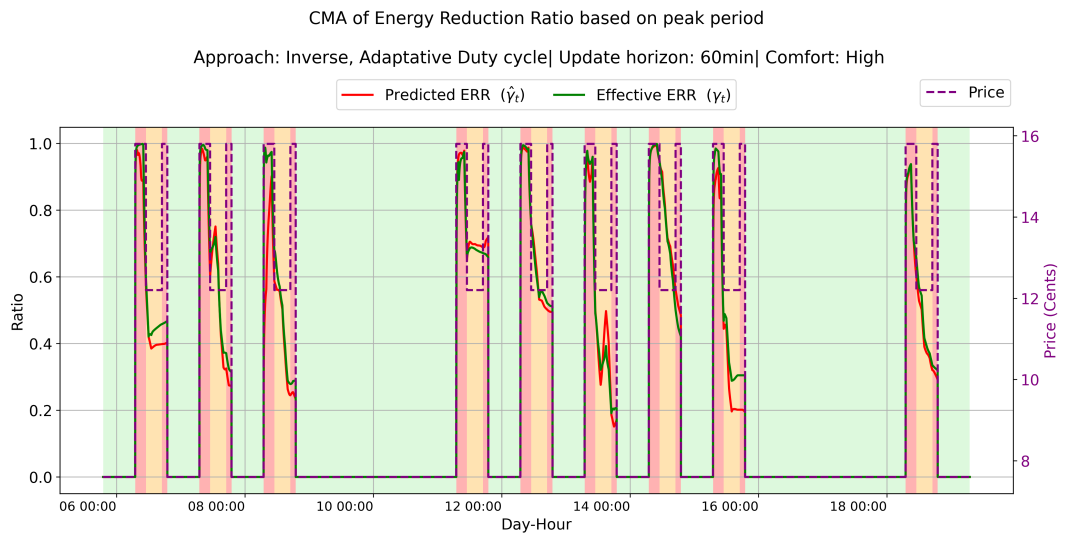


Figure 4.17 Ratio de réduction d'énergie

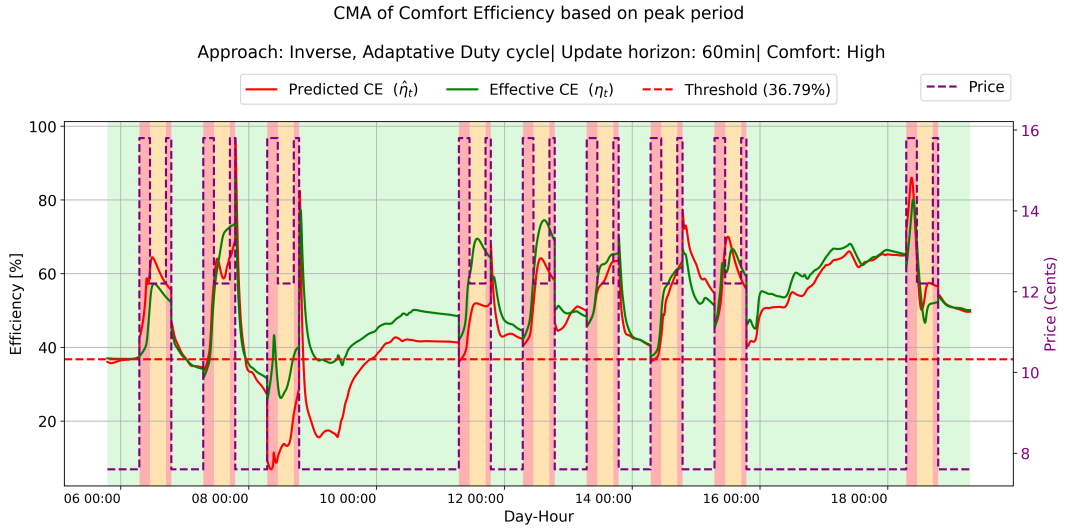


Figure 4.18 Efficacité de confort

En résumé, les résultats ont démontré que même dans un scénario où les usagers ne compromettent pas leur confort, l'algorithme proposé peut réduire substantiellement les charges lors d'un événement DR, ce qui conduit à un coût énergétique inférieur par rapport aux cas de référence. Les usagers pourraient réaliser davantage d'économies s'ils

décidaient d’être moins restrictifs quant à leurs besoins de confort.

Chapitre 5 - Discussion, conclusion générale et recommandation

5.1 Discussion

5.1.1 Synthèse des travaux

On peut résumer la principale contribution de cette thèse à la définition d'un cadre d'étude et l'implémentation d'une méthode permettant une gestion efficace des charges de chauffage en milieu résidentiel. Cette méthode garantit la conversion d'une puissance optimale en termes de température de consigne (et/ou de rapport cyclique), offre une prédictibilité de la consommation des usages ainsi que de la flexibilité au réseau.

Nous avons mis en évidence la difficulté d'identifier des paramètres uniques pour un thermostat. Cette difficulté provient des dynamiques non linéaires propres à son fonctionnement, notamment les phénomènes de saturation. Nous avons donc proposé une méthode itérative permettant de réduire l'espace de recherche lors de l'identification des paramètres du modèle thermostatique. Il est apparu que la méthode proposée permet effectivement de retrouver des paramètres uniques compatibles avec les dynamiques changeantes du thermostat. Nous avons également mis en évidence une méthode de suivi du terme intégrateur, ainsi qu'une approche permettant de rendre convexe le problème d'optimisation à des fin d'identification des paramètres. Les résultats ont montré que le modèle établi était effectivement capable de reproduire le fonctionnement du thermostat.

Ensuite, nous avons proposé une méthodologie permettant, dans un premier temps, par un séquencement approprié, d'identifier les paramètres d'un modèle thermique lorsque la dynamique du bâtiment n'est pas soumise à des charges autres que celles du chauffage. Par la suite, un modèle de correction a été défini : il établit la différence entre la sortie d'un modèle de pseudo-état de la résidence et la sortie réellement observée. Le

modèle de pseudo-état de la résidence consiste à reproduire la dynamique du bâtiment en utilisant uniquement les mesures de puissance disponibles, sans tenir compte des effets éventuels des charges résiduelles. Subséquemment, le modèle de correction est utilisé comme contrainte afin de minimiser l'écart entre les mesures réelles et un modèle thermo-thermostatique de la résidence, dont les entrées sont la température de consigne et la sortie du modèle de correction. Cela a permis de convertir l'écart entre les mesures et la sortie du modèle de pseudo-état en une puissance attribuable aux charges résiduelles. Nous avons ensuite établi un modèle de prédiction de ces charges résiduelles et défini un cadre d'étude permettant de prédire le potentiel de réponse à la demande d'une résidence. À cet effet, une méthode de contrôle par modulation du rapport cyclique, basée sur une heuristique, a été proposée. Nous avons également défini des métriques pour quantifier et évaluer la flexibilité d'une résidence dans un contexte de réponse à la demande.

Enfin, nous nous sommes appuyés sur les modèles développés pour définir un algorithme de contrôle capable de produire des consignes optimales garantissant le maintien du confort des usagers et une consommation modeste en énergie. Deux approches ont été testées. L'une dénommée approche directe permet de produire les consignes optimales sur la base d'une fonction de couts qui traduit un équilibre entre le confort et le cout énergétique. La seconde approche, quant à elle, permet sur la base d'un plan de consommation préétabli de convertir ce plan sous forme de consignes (en température et/ou rapport cyclique). Lesquelles consignes lorsque appliquées aux thermostats entraîneront une reconstitution plus ou moins fidèle du plan de consigne.

Il est important de mentionner que les méthodes conçues dans le cadre de cette thèse ont été appliquées à des données réelles. Ces données proviennent des thermostats à tension de secteur fonctionnant dans une maison habitée. L'efficacité des méthodes a été mise en

évidence comme évoqué ci-haut.

5.1.2 Limites

Les résultats obtenus suite aux travaux menés dans le cadre de cette thèse sont en effet intéressants. Cependant, il convient de noter que, pour l'identification des paramètres du modèle thermostatique, la méthode itérative peut dépendre fortement de l'espace de recherche initial. L'efficacité du modèle de pseudo-état est assujettie à la stabilité des charges résiduelles. En effet, dès lors qu'il est employé dans le modèle de correction, il est supposé que les écarts entre les charges et le modèle sont entièrement dus aux charges résiduelles. Ce qui peut ne pas être vrai dans tous les cas, car d'autres sources d'erreurs peuvent exister : erreurs de modélisation, erreurs de mesure, etc. Le modèle prédictif des charges résiduelles est simplifié et peut ne pas capturer entièrement la dynamique de ces dernières. Pour un ajustement effectué sur un horizon court, cela reste intéressant. Cependant, pour des horizons plus longs, l'efficacité risque d'être compromise. La méthode d'optimisation pour la génération de consignes est recommandable pour les bâtiments moyens. Dans des bâtiments complexes, cette méthode pourrait atteindre ses limites en termes de coût computationnel. Par *horizon court* nous entendons un horizon de prédiction/contrôle de l'ordre de quelques heures (typiquement inférieur à une journée), sur lequel le modèle simplifié de charges résiduelles demeure fiable ; un *horizon plus long* désigne un horizon de plusieurs jours à une saison, sur lequel les effets tendanciels et saisonniers du comportement des occupants deviennent significatifs. De même, par *bâtiment moyen* nous désignons un logement comportant un nombre modéré de zones thermiques (quelques pièces chauffées, faiblement couplées), tandis qu'un *bâtiment complexe* comporte de nombreuses zones fortement couplées thermiquement, ce qui accroît la dimension du problème d'optimisation et donc son coût computationnel.

5.2 Conclusion générale et recommandations

À travers cette thèse, nous avons abordé la notion de problèmes inverses. Nous avons ensuite identifié ceux dont la résolution est indispensable à la mise en place d'un système de gestion de la consommation au sein d'une résidence. Des méthodes spécifiques ont été conçues pour permettre de résoudre chacun de ces problèmes, et un cadre d'intégration de ces solutions a été défini. Ce cadre a permis, dans un premier temps, de réaliser la prédiction et l'évaluation du potentiel de participation d'une résidence à un programme de réponse à la demande. Dans un second temps, des approches de contrôle exploitant cette combinaison de solutions ont été testées, montrant leur efficacité tant en termes de confort que de bénéfices économiques pour les consommateurs résidentiels. Mais aussi de la flexibilité qui peut être offerte au réseau.

Retour explicite sur les contributions: au terme de ce travail, les trois contributions principales annoncées en introduction ont été concrétisées : (1) une méthode de recherche en espace réduit, fondée sur l'optimisation bayésienne, permettant d'obtenir un jeu unique de paramètres interprétables pour des thermostats communicants réels, sans accès interne au contrôleur ; (2) une technique d'estimation et de prédiction en ligne des charges résiduelles (positives et négatives), intégrée à un modèle thermo-thermostatique permettant de prédire le potentiel de réponse à la demande d'une résidence ; et (3) un algorithme de contrôle par optimisation inverse convertissant un profil de puissance cible en consignes applicables aux thermostats. Ces trois briques ont été validées sur des données réelles issues d'une habitation occupée.

Impact et retombées: l'impact de ces contributions se situe à trois niveaux. Pour le consommateur résidentiel, le cadre proposé réduit la facture énergétique tout en préservant le confort, sans nécessiter le remplacement des thermostats existants. Pour l' opérateur de

réseau et l'agrégateur, il fournit une quantification exploitable de la flexibilité résidentielle, jusqu'ici peu accessible faute de modèles adéquats. Pour la communauté scientifique, il propose un cadre inverse unifié, interprétable et validé expérimentalement, transférable à d'autres charges flexibles (chauffe-eau, véhicules électriques). En levant le verrou de l'identification conjointe thermostat–bâtiment et celui de la prise en compte des charges résiduelles, ce travail contribue à rendre la réponse à la demande résidentielle réellement opérationnelle.

À la lumière de ce qui précède et des limites évoquées ci-dessus, nous préconisons :

1. D'investiguer l'efficacité de la méthodologie d'identification et d'estimation des charges résiduelles sur d'autres données réelles, présentant des profils variés et sur de longues périodes.
2. Suite à l'accomplissement du point 1 et à l'obtention des profils de charges résiduelles, il serait recommandé de mettre en évidence le caractère tendanciel et saisonnier du comportement des occupants, qui pourrait se refléter dans les courbes de ces charges.
3. La mise en évidence au point 2 permettra de proposer un modèle capable de prédire le comportement de ces charges sur de longues durées.
4. Avec le modèle proposé au point 3, il serait intéressant de tester la capacité de prédiction du potentiel de réponse à la demande. On pourrait ainsi élargir l'horizon de prédiction et de contrôle, ce qui serait bénéfique pour la planification à horizon long.
5. La prise en compte du temps de latence entre la génération des consignes et leur application effective doit également faire l'objet d'analyses plus poussées. Cela permettra de mettre en évidence le manque à gagner lié au temps de calcul des

consignes optimales.

6. Bien que les approches de contrôle proposées n'aient pas été mises à rude épreuve du point de vue du coût de calcul, il serait intéressant de les tester sur des bâtiments plus complexes afin d'évaluer ce coût.
7. Il serait également intéressant de tester l'efficacité des approches de contrôle proposées sur une large population de consommateurs ou de blocs de consommateurs, afin de conclure sur leur efficacité à grande échelle.

Enfin, d'autres perspectives à explorer peuvent être d'intégrer ces solutions développées au niveau des systèmes énergétiques élargis : quartiers, micro-réseaux, réseau électrique intelligent. L'adaptation des solutions pour une application sur d'autres charges électriques résidentielles comme les véhicules électriques, chauffe-eau, etc. Il serait bénéfique d'évaluer comment l'application de ces travaux peut impacter les modèles d'affaires des fournisseurs d'énergie, redessiner les politiques énergétiques et comment elle peut participer à l'autonomisation des consommateurs. Par ailleurs, il est impératif de regarder les aspects liés à la confidentialité des données des utilisateurs et d'assurer leur sécurité vis-à-vis des cyberattaques. Mais également comment les opérateurs des réseaux peuvent se protéger de fraudes potentielles. Enfin, on peut envisager des projets pilotes pour le déploiement de solutions logicielles qui intègrent les algorithmes développés dans la présente thèse.

Références

[1] International Energy Agency (IEA), "How energy efficiency will power net zero climate goals," Paris, 2021, accessed: 2025-11-01. [Online]. Available: https://www.iea.org/commentaries/how-energy-efficiency-will-power-net-zero-climate-goals

[2] J. Whitmore and P.-O. Pineau, "État de l'énergie au québec," HEC Montréal, Montréal, Rapport technique, 2025, préparé pour le ministère de l'Énergie et des Ressources naturelles. [Online]. Available: http://energie.hec.ca/eeq/

[3] V. M. Balijepalli, V. Pradhan, S. A. Khaparde, and R. Shereef, "Review of demand response under smart grid paradigm," in *ISGT2011-India*. IEEE, 2011, pp. 236–243.

[4] S. Shao, M. Pipattanasomporn, and S. Rahman, "Development of physical-based demand response-enabled residential load models," *IEEE Transactions on power systems*, vol. 28, no. 2, pp. 607–614, 2012.

[5] Ressources naturelles Canada (RNCan). (2025) Statistiques énergétiques – consommation d'énergie dans le secteur résidentiel au québec. Consulté le 1 novembre 2025. [Online]. Available: https://oee.nrcan.gc.ca/corporate/statistics/neud/dpa/showTable.cfm?juris=qc&page=0&rn=5&sector=res&type=CP&utm_source

[6] M. Wood, E. Ogliari, and S. Leva, "The value of forecasting: The effect of building load forecast errors on the performance of an optimal energy management system," in *2024 IEEE 8th Forum on Research and Technologies for Society and Industry Innovation (RTSI)*. IEEE, 2024, pp. 42–47.

[7] Y. Du, F. Li, K. Kurte, J. Munk, and H. Zandi, "Demonstration of intelligent hvac load management with deep reinforcement learning: real-world experience of machine learning in demand control," *IEEE Power and Energy Magazine*, vol. 20, no. 3, pp. 42–53, 2022.

[8] Y. Han, J. Wu, H. Chen, F. Si, Z. Cao, and Q. Zhao, "Enhancing grid-interactive buildings demand response: Sequential update-based multiagent deep reinforcement learning approach," *IEEE Internet of Things Journal*, vol. 11, no. 14, pp. 24 439–24 451, 2024.

[9] S. Kim, R. Mowakeaa, S.-J. Kim, and H. Lim, "Building energy management for demand response using kernel lifelong learning," *IEEE Access*, vol. 8, pp. 82 131–82 141, 2020.

[10] D. Li, Z. Qi, Y. Zhou, and M. Elchalakani, "Machine learning applications in building energy systems: Review and prospects," *Buildings*, vol. 15, no. 4, p. 648, 2025.

[11] M. Ibrar, H. N. Abishu, A. M. Seid, S. Márquez-Sánchez, J. H. Fernandez, J. M. Corchado, and A. Erbad, "Survey on demand response in the landscape of adaptive

and intelligent building energy management systems," *2024 International Wireless Communications and Mobile Computing (IWCMC)*, pp. 1203–1209, 2024.

[12] P. J. Daniell, "Lectures on cauchy's problem in linear partial differential equations. by j. hadamard. pp. viii+316. 15s.net. 1923. (per oxford university press.)," *The Mathematical Gazette*, vol. 12, no. 171, p. 173–174, 1924.

[13] M. I. Moumouni, R. Malhamé, K. Agbossou, N. Henao, S. H. Nagarsheth, and B. Delcroix, "Shrinked-space search method for lvcts' parameters identification," *IEEE Transactions on Industrial Electronics*, 2024.

[14] M. Ibrahim Moumouni, R. P. Malhamé, K. Agbossou, N. Henao, and F. Etedadi, "Two-stage method for grey-box model identification and demand response potential prediction enabled by a non-intrusive thermal loads monitoring," *SSRN Electronic Journal*, 2026, available at SSRN: https://ssrn.com/abstract=7079435. [Online]. Available: https://dx.doi.org/10.2139/ssrn.7079435

[15] ——, "Forward and inverse joint-optimization-based supervisory control of heating loads in demand response context," *SSRN Electronic Journal*, 2026, available at SSRN: https://ssrn.com/abstract=7051831. [Online]. Available: https://dx.doi.org/10.2139/ssrn.7051831

[16] T. C. Chan, R. Mahmood, and I. Y. Zhu, "Inverse optimization: Theory and applications," *Operations Research*, vol. 73, no. 2, pp. 1046–1074, 2025.

[17] J. R. Birge, A. Hortaçsu, and J. M. Pavlin, "Inverse optimization for the recovery of market structure from market outcomes: An application to the miso electricity market," *Operations Research*, vol. 65, no. 4, pp. 837–855, 2017.

[18] J. Saez-Gallego, J. M. Morales, M. Zugno, and H. Madsen, "A data-driven bidding model for a cluster of price-responsive consumers of electricity," *IEEE Transactions on Power Systems*, vol. 31, no. 6, pp. 5001–5011, 2016.

[19] J. Saez-Gallego and J. M. Morales, "Short-term forecasting of price-responsive loads using inverse optimization," *IEEE Transactions on Smart Grid*, vol. 9, no. 5, pp. 4805–4814, 2017.

[20] T. Lu, Z. Wang, J. Wang, Q. Ai, and C. Wang, "A data-driven stackelberg market strategy for demand response-enabled distribution systems," *IEEE Transactions on Smart Grid*, vol. 10, no. 3, pp. 2345–2357, 2018.

[21] R. Fernández-Blanco, J. M. Morales, S. Pineda, and Á. Porras, "Inverse optimization with kernel regression: Application to the power forecasting and bidding of a fleet of electric vehicles," *Computers & Operations Research*, vol. 134, p. 105405, 2021.

[22] Z. Liang and Y. Dvorkin, "Data-driven inverse optimization for marginal offer price recovery in electricity markets," in *Proceedings of the 14th ACM International Conference on Future Energy Systems*, 2023, pp. 497–509.

[23] A. Afshari and L. A. Friedrich, "Inverse modeling of the urban energy system using hourly electricity demand and weather measurements, part 1: Black-box model," *Energy and Buildings*, vol. 157, pp. 126–138, 2017.

[24] A. Esteban-Perez, D. Bunn, and Y. Ghiassi-Farrokhfal, "Estimating the unobservable components of electricity demand response with inverse optimization," *arXiv preprint arXiv:2410.02774*, 2024.

[25] H. Uchida, K. Kishimoto, K. Nishizawa, Y. Shimoda, Y. Yamaguchi, and K. Togawa, "Aggregated smart meter data driven occupant behavior analysis based on inverse problem optimization," *Energy and Buildings*, p. 116074, 2025.

[26] S. Schwarz, D. Carta, A. Monti, and A. Benigni, "A direct and analytical method for inverse problems under uncertainty in energy system design: combining inverse simulation and polynomial chaos theory," *Energy Informatics*, vol. 7, no. 1, p. 55, 2024.

[27] A. Kovács, "Inverse optimization approach to the identification of electricity consumer models," *Central European Journal of Operations Research*, vol. 29, no. 2, pp. 521–537, 2021.

[28] A. Razaq and M. W. Jack, "An inverse-problem approach to simulating smart control of domestic electric hot water cylinders using electricity demand time-series data." *Energy and buildings*, vol. 278, p. 112644, 2023.

[29] K. Nishizawa, K. Kishimoto, H. Uchida, Y. Shimoda, Y. Yamaguchi, and K. Togawa, "Analyzing and modeling occupant behavior by inverse problems with smart meter data," in *Building Simulation 2023*, vol. 18. IBPSA, 2023, pp. 2649–2656.

[30] B. Verma and P. K. Padhy, "Robust fine tuning of optimal pid controller with guaranteed robustness," *IEEE Transactions on Industrial Electronics*, vol. 67, no. 6, pp. 4911–4920, 2019.

[31] M. Yang, S. Tang, and D. Xu, "Comments on "antiwindup strategy for pi-type speed controller"," *IEEE Transactions on Industrial Electronics*, vol. 62, no. 2, pp. 1329–1332, 2014.

[32] J.-W. Choi and S.-C. Lee, "Antiwindup strategy for pi-type speed controller," *IEEE Transactions on Industrial Electronics*, vol. 56, no. 6, pp. 2039–2046, 2009.

[33] K. Ohishi, E. Hayasaka, T. Nagano, M. Harakawa, and T. Kanmachi, "High-performance speed servo system considering voltage saturation of a vector-controlled induction motor," *IEEE Transactions on Industrial Electronics*, vol. 53, no. 3, pp. 795–802, 2006.

[34] N. Krikelis, "State feedback integral control with intelligent integrators," *International Journal of Control*, vol. 32, no. 3, pp. 465–473, 1980.

[35] S. Paoletti, A. L. Juloski, G. Ferrari-Trecate, and R. Vidal, "Identification of hybrid systems a tutorial," *European journal of control*, vol. 13, no. 2-3, pp. 242–260, 2007.

[36] L. Breiman, "Hinging hyperplanes for regression, classification, and function approximation," *IEEE Transactions on Information Theory*, vol. 39, no. 3, pp. 999–1013, 1993.

[37] A. Bemporad, A. Garulli, S. Paoletti, and A. Vicino, "A bounded-error approach to piecewise affine system identification," *IEEE Transactions on Automatic Control*, vol. 50, no. 10, pp. 1567–1580, 2005.

[38] A. L. Juloski, S. Weiland, and W. M. H. Heemels, "A bayesian approach to identification of hybrid systems," *IEEE Transactions on Automatic Control*, vol. 50, no. 10, pp. 1520–1533, 2005.

[39] R. Vidal, S. Soatto, Y. Ma, and S. Sastry, "An algebraic geometric approach to the identification of a class of linear hybrid systems," in *42nd IEEE International Conference on Decision and Control (IEEE Cat. No. 03CH37475)*, vol. 1. IEEE, 2003, pp. 167–172.

[40] J. Roll, A. Bemporad, and L. Ljung, "Identification of piecewise affine systems via mixed-integer programming," *Automatica*, vol. 40, no. 1, pp. 37–50, 2004.

[41] Z. Lassoued and K. Abderrahim, "A comparison study of some pwarx system identification methods," in *2013 17th International Conference on System Theory, Control and Computing (ICSTCC)*. IEEE, 2013, pp. 291–296.

[42] E. Khanmirza, M. Nazarahari, and A. Mousavi, "Identification of piecewise affine systems based on fuzzy pca-guided robust clustering technique," *EURASIP Journal on Advances in Signal Processing*, vol. 2016, no. 1, pp. 1–15, 2016.

[43] D. Piga, A. Bemporad, and A. Benavoli, "Rao-blackwellized sampling for batch and recursive bayesian inference of piecewise affine models," *Automatica*, vol. 117, p. 109002, 2020.

[44] P. Van den Hof, "Closed-loop issues in system identification," *Annual reviews in control*, vol. 22, pp. 173–186, 1998.

[45] G. Van der Veen, J.-W. van Wingerden, M. Bergamasco, M. Lovera, and M. Verhaegen, "Closed-loop subspace identification methods: an overview," *IET Control Theory & Applications*, vol. 7, no. 10, pp. 1339–1358, 2013.

[46] I. Maruta and T. Sugie, "Closed-loop subspace identification for stable/unstable systems using data compression and nuclear norm minimization," *IEEE Access*, vol. 10, pp. 21 412–21 423, 2022.

[47] ——, "A simple framework for identifying dynamical systems in closed-loop," *IEEE Access*, vol. 9, pp. 31 441–31 453, 2021.

[48] K. Li, H. Luo, C. Yang, and S. Yin, "Subspace-aided closed-loop system identification with application to dc motor system," *IEEE Transactions on Industrial Electronics*, vol. 67, no. 3, pp. 2304–2313, 2019.

[49] K. Li, H. Luo, S. Yin, and O. Kaynak, "A novel bias-eliminated subspace identification approach for closed-loop systems," *IEEE Transactions on Industrial Electronics*, vol. 68, no. 6, pp. 5197–5205, 2020.

[50] Y. Chen, J. Castiglione, R. Astroza, and Y. Li, "Parameter estimation of resistor-capacitor models for building thermal dynamics using the unscented kalman filter," *Journal of Building Engineering*, vol. 34, p. 101639, 2021.

[51] M. Trčka and J. L. Hensen, "Overview of hvac system simulation," *Automation in Construction*, vol. 19, no. 2, pp. 93–99, 2010.

[52] S. Song, W. Zhang, Y. Lin, and C. Wang, "Thermo-electrical state and demand response potential estimation for power systems with building thermostats," *International Journal of Electrical Power & Energy Systems*, vol. 145, p. 108588, 2023.

[53] O. M. Brastein, D. W. U. Perera, C. Pfeifer, and N.-O. Skeie, "Parameter estimation for grey-box models of building thermal behaviour," *Energy and Buildings*, vol. 169, pp. 58–68, 2018.

[54] M. Manganelli, G. Greco, and L. Martirano, "Design of a new architecture and simulation model for building automation toward nearly zero energy buildings," *IEEE Transactions on Industry Applications*, vol. 55, no. 6, pp. 6999–7007, 2019.

[55] F. Liberati, A. Di Giorgio, A. Giuseppi, A. Pietrabissa, E. Habib, and L. Martirano, "Joint model predictive control of electric and heating resources in a smart building," *IEEE Transactions on Industry Applications*, vol. 55, no. 6, pp. 7015–7027, 2019.

[56] F. Wang, L. Zhou, H. Ren, X. Liu, S. Talari, M. Shafie-khah, and J. P. Catalao, "Multi-objective optimization model of source–load–storage synergetic dispatch for a building energy management system based on tou price demand response," *IEEE Transactions on Industry Applications*, vol. 54, no. 2, pp. 1017–1028, 2017.

[57] R. Ariwoola and S. Kamalasadan, "An integrated hybrid thermal dynamics model and energy aware optimization framework for grid-interactive residential building management," *IEEE Transactions on Industry Applications*, vol. 59, no. 2, pp. 2519–2531, 2022.

[58] Y. Li, J. Castiglione, R. Astroza, and Y. Chen, "Real-time thermal dynamic analysis of a house using rc models and joint state-parameter estimation," *Building and Environment*, vol. 188, p. 107184, 2021.

[59] Z. Wang, M. Broccardo, and J. Song, "Hamiltonian monte carlo methods for subset simulation in reliability analysis," *Structural Safety*, vol. 76, pp. 51–67, 2019.

[60] S. Wang and X. Xu, "Simplified building model for transient thermal performance estimation using ga-based parameter identification," *International journal of thermal sciences*, vol. 45, no. 4, pp. 419–432, 2006.

[61] Z. Shi and W. O'Brien, "Sequential state prediction and parameter estimation with constrained dual extended kalman filter for building zone thermal responses," *Energy and Buildings*, vol. 183, pp. 538–546, 2019.

[62] M. M. Mazar and A. Rezaeizadeh, "Adaptive model predictive climate control of multi-unit buildings using weather forecast data," *Journal of Building Engineering*, vol. 32, p. 101449, 2020.

[63] B. P. Das, K. Das Sharma, A. Chatterjee, and J. Bera, "Joint state estimation of indoor thermal dynamics with unknown inputs using augmented fading memory kalman filter," *Journal of Building Performance Simulation*, pp. 1–17, 2022.

[64] L. Di Natale, B. Svetozarevic, P. Heer, and C. N. Jones, "Physically consistent neural networks for building thermal modeling: theory and analysis," *Applied Energy*, vol. 325, p. 119806, 2022.

[65] B. Cui, C. Fan, J. Munk, N. Mao, F. Xiao, J. Dong, and T. Kuruganti, "A hybrid building thermal modeling approach for predicting temperatures in typical, detached, two-story houses," *Applied energy*, vol. 236, pp. 101–116, 2019.

[66] G. Gokhale, B. Claessens, and C. Develder, "Physics informed neural networks for control oriented thermal modeling of buildings," *Applied Energy*, vol. 314, p. 118852, 2022.

[67] L. Di Natale, B. Svetozarevic, P. Heer, and C. N. Jones, "Towards scalable physically consistent neural networks: An application to data-driven multi-zone thermal building models," *Applied Energy*, vol. 340, p. 121071, 2023.

[68] R. Z. Homod *et al.*, "Review on the hvac system modeling types and the shortcomings of their application," *Journal of Energy*, vol. 2013, 2013.

[69] C. Deb, F. Zhang, J. Yang, S. E. Lee, and K. W. Shah, "A review on time series forecasting techniques for building energy consumption," *Renewable and Sustainable Energy Reviews*, vol. 74, pp. 902–924, 2017.

[70] C. Fan, F. Xiao, and Y. Zhao, "A short-term building cooling load prediction method using deep learning algorithms," *Applied energy*, vol. 195, pp. 222–233, 2017.

[71] A. Foucquier, S. Robert, F. Suard, L. Stéphan, and A. Jay, "State of the art in building modelling and energy performances prediction: A review," *Renewable and Sustainable Energy Reviews*, vol. 23, pp. 272–288, 2013.

[72] J. Yuan and Y. Weng, "Physics interpretable shallow-deep neural networks for physical system identification with unobservability," in *2021 IEEE International Conference on Data Mining (ICDM)*. IEEE, 2021, pp. 847–856.

[73] Z. Xiao, W. Gang, J. Yuan, Y. Zhang, and C. Fan, "Cooling load disaggregation using a nilm method based on random forest for smart buildings," *Sustainable Cities and Society*, vol. 74, p. 103202, 2021.

[74] N. Kaneko, K. Okazawa, D. Zhao, H. Nishikawa, I. Taniguchi, H. Murayama, Y. Yura, M. Okamoto, F. Catthoor, and T. Onoye, "Non-intrusive thermal load disaggregation and forecasting for effective hvac systems," *Applied Energy*, vol. 367, p. 123379, 2024.

[75] Y. Li, J. Lee, J. Li, P. Wang, and S. Yoon, "Nonintrusive in-situ modeling for unobserved virtual models in digital twin-enabled building hvac systems: A one-year comparison of data-driven and physics-based approaches in a living laboratory," *Journal of Building Engineering*, vol. 101, p. 111811, 2025.

[76] R. L. Kini, A. Vlachokostas, M. R. Brambley, and A. Rogers, "Occupant-centric demand response for thermostatically-controlled home loads," *IEEE Transactions on Smart Grid*, 2025.

[77] F. Pallonetto, M. De Rosa, F. D'Ettorre, and D. P. Finn, "On the assessment and control optimisation of demand response programs in residential buildings," *Renewable and Sustainable Energy Reviews*, vol. 127, p. 109861, 2020.

[78] R. Adhikari, M. Pipattanasomporn, and S. Rahman, "Heuristic algorithms for aggregated hvac control via smart thermostats for regulation service," *IEEE Transactions on Smart Grid*, vol. 11, no. 3, pp. 2023–2032, 2019.

[79] N. U. Hassan, Y. I. Khalid, C. Yuen, and W. Tushar, "Customer engagement plans for peak load reduction in residential smart grids," *IEEE Transactions on Smart Grid*, vol. 6, no. 6, pp. 3029–3041, 2015.

[80] S. J. Darby and E. McKenna, "Social implications of residential demand response in cool temperate climates," *Energy Policy*, vol. 49, pp. 759–769, 2012.

[81] J. H. Yoon, R. Baldick, and A. Novoselac, "Dynamic demand response controller based on real-time retail price for residential buildings," *IEEE Transactions on Smart Grid*, vol. 5, no. 1, pp. 121–129, 2014.

[82] P. Rocha, A. Siddiqui, and M. Stadler, "Improving energy efficiency via smart building energy management systems: A comparison with policy measures," *Energy and Buildings*, vol. 88, pp. 203–213, 2015.

[83] Y. Jiang, J. Wang, and L. Song, "Quantitative analysis of cost savings and occupants' preferences in grid-interactive smart home operation," *Science and Technology for the Built Environment*, vol. 29, no. 9, pp. 845–857, 2023.

[84] M. Tavakkoli, S. Fattaheian-Dehkordi, M. Pourakbari-Kasmaei, M. Liski, and M. Lehtonen, "An incentive based demand response by hvac systems in residential houses," in *2019 IEEE PES Innovative Smart Grid Technologies Europe (ISGT-Europe)*. IEEE, 2019, pp. 1–5.

[85] M. Diekerhof, S. Schwarz, and A. Monti, "Electrothermal flexibility for demand response using inverse simulation," *IEEE Systems Journal*, vol. 13, no. 2, pp. 1776–1785, 2018.

[86] A. Aswani, Z.-J. Shen, and A. Siddiq, "Inverse optimization with noisy data," *Operations Research*, vol. 66, no. 3, pp. 870–892, 2018.

[87] M. Awadalla and F. Bouffard, "Flexibility characterization of sustainable power systems in demand space: A data-driven inverse optimization approach," *IEEE Transactions on Power Systems*, vol. 39, no. 5, pp. 6196–6209, 2024.

[88] A. Costa, M. M. Keane, J. I. Torrens, and E. Corry, "Building operation and energy performance: Monitoring, analysis and optimisation toolkit," *Applied Energy*, vol. 101, pp. 310–316, 2013.

[89] J. Zuo, S. Pullen, J. Palmer, H. Bennetts, N. Chileshe, and T. Ma, "Impacts of heat waves and corresponding measures: a review," *Journal of Cleaner Production*, vol. 92, pp. 1–12, 2015.

[90] M. Ponce-Jara, E. Ruiz, R. Gil, E. Sancristóbal, C. Pérez-Molina, and M. Castro, "Smart grid: Assessment of the past and present in developed and developing countries," *Energy Strategy Reviews*, vol. 18, pp. 38–52, 2017.

[91] A. Zipperer, P. A. Aloise-Young, S. Suryanarayanan, R. Roche, L. Earle, D. Christensen, P. Bauleo, and D. Zimmerle, "Electric energy management in the smart home: Perspectives on enabling technologies and consumer behavior," *Proceedings of the IEEE*, vol. 101, no. 11, pp. 2397–2408, 2013.

[92] J. Rotondo, R. Johnson, N. Gonzales, A. Waranowski, C. Badger, N. Lange, E. Goldman, and R. Foster, "Overview of existing and future residential use cases for connected thermostats," 2016.

[93] J. B. Keller, "Inverse problems," *The American Mathematical Monthly*, vol. 83, no. 2, pp. 107–118, 1976. [Online]. Available: http://www.jstor.org/stable/2976988

[94] J. Kaipio and E. Somersalo, *Statistical and Computational Inverse Problems*. Springer, 2005.

[95] H. Kalhori, *Inverse Dynamics Problems*. MDPI, 2021.

[96] A. Tarantola, *Inverse Problem Theory and Methods for Model Parameter Estimation*. SIAM, 2005.

[97] H. W. Engl, M. Hanke, and A. Neubauer, *Regularization of Inverse Problems*. Kluwer Academic Publishers, 1996.

[98] R. C. Aster, B. Borchers, and C. Thurber, *Parameter Estimation and Inverse Problems*. Elsevier, 2019.

[99] P. C. Hansen, *Discrete Inverse Problems: Insight and Algorithms*. SIAM, 2010.

[100] Q. Bai, A. L. Teckentrup, and K. C. Zygalakis, "Gaussian processes for bayesian inverse problems associated with linear pdes," *Statistics and Computing*, vol. 34, pp. 123–147, 2024.

[101] A. M. Stuart and A. L. Teckentrup, "Inverse problems: A bayesian perspective," *Acta Numerica*, vol. 25, pp. 1–125, 2016.

[102] S. R. Arridge, P. Maass, O. Öktem, and C.-B. Schönlieb, "Solving inverse problems using data-driven models," *Acta Numerica*, vol. 28, pp. 1–174, 2019.

[103] K. H. Jin, M. T. McCann, E. Froustey, and M. Unser, "Deep convolutional neural network for inverse problems in imaging," *IEEE Transactions on Image Processing*, vol. 26, no. 9, pp. 4509–4522, 2017.

[104] Anonymous, "Bo4io: Bayesian optimization for inverse optimization," https://arxiv.org/html/2405.17875, 2024, arXiv:2405.17875.

[105] R. Poovendran, "Cyber–physical systems: Close encounters between two parallel worlds [point of view]," *Proceedings of the IEEE*, vol. 98, no. 8, pp. 1363–1366, 2010.

[106] N. P. Lawrence, G. E. Stewart, P. D. Loewen, M. G. Forbes, J. U. Backstrom, and R. B. Gopaluni, "Optimal pid and antiwindup control design as a reinforcement learning problem," *IFAC-PapersOnLine*, vol. 53, no. 2, p. 236–241, 2020. [Online]. Available: http://dx.doi.org/10.1016/j.ifacol.2020.12.129

[107] K. Wang, F. Wu, and X.-M. Sun, "Switching anti-windup control for aircraft engines," *IEEE Transactions on Industrial Electronics*, vol. 70, no. 2, pp. 1830–1840, 2022.

[108] Y. Chen, M. Yang, K. Liu, J. Long, D. Xu, and F. Blaabjerg, "Reversed structure based pi-lead controller antiwindup design and self-commissioning strategy for servo drive systems," *IEEE Transactions on Industrial Electronics*, vol. 69, no. 7, pp. 6586–6599, 2021.

[109] L. Papenmeier, N. Cheng, S. Becker, and L. Nardi, "Exploring exploration in bayesian optimization," *arXiv preprint arXiv:2502.08208*, 2025.

[110] C. Rasmussen and C. Williams, "Gaussian processes for machine learning.,(mit press: Cambridge, ma)," 2006.

[111] D. R. Jones, M. Schonlau, and W. J. Welch, "Efficient global optimization of expensive black-box functions," *Journal of Global optimization*, vol. 13, no. 4, pp. 455–492, 1998.

[112] J. Koloda, A. M. Peinado, and V. Sánchez, "On the application of multivariate kernel density estimation to image error concealment," in *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*. IEEE, 2013, pp. 1330–1334.

[113] M. P. Wand and M. C. Jones, *Kernel Smoothing*. Chapman and Hall, 1995.

[114] D. W. Scott, *Multivariate density estimation: theory, practice, and visualization*. John Wiley & Sons, 2015.

[115] L. Liberti and N. Maculan, *Global optimization: from theory to implementation*. Springer Science & Business Media, 2006, vol. 84.

[116] J. Bien, J. Taylor, and R. Tibshirani, "A lasso for hierarchical interactions," *Annals of statistics*, vol. 41, no. 3, p. 1111, 2013.

[117] L. Wei, A. Gómez, and S. Küçükyavuz, "Ideal formulations for constrained convex optimization problems with indicator variables," *Mathematical Programming*, vol. 192, no. 1, pp. 57–88, 2022.

[118] S. P. Boyd and L. Vandenberghe, *Convex optimization*. Cambridge university press, 2004.

[119] D. He, W. Lin, N. Liu, R. G. Harley, and T. G. Habetler, "Incorporating non-intrusive load monitoring into building level demand response," *IEEE Transactions on Smart Grid*, vol. 4, no. 4, pp. 1870–1877, 2013.

[120] C. L. Athanasiadis, T. A. Papadopoulos, G. C. Kryonidis, and D. I. Doukas, "A holistic and personalized home energy management system with non-intrusive load monitoring," *IEEE Transactions on Consumer Electronics*, 2024.

[121] H. Li, Z. Wan, and H. He, "Real-time residential demand response," *IEEE Transactions on Smart Grid*, vol. 11, no. 5, pp. 4144–4154, 2020.

[122] Z. Xia, H. Ma, T. K. Saha, and R. Zhang, "Consumption scenario-based probabilistic load forecasting of single household," *IEEE Transactions on Smart Grid*, vol. 13, no. 2, pp. 1075–1087, 2021.

[123] Z. Xia, R. Zhang, H. Ma, and T. K. Saha, "Day-ahead electricity consumption prediction of individual household–capturing peak consumption pattern," *IEEE Transactions on Smart Grid*, vol. 15, no. 3, pp. 2971–2984, 2023.

[124] J. Snoek, H. Larochelle, and R. P. Adams, "Practical bayesian optimization of machine learning algorithms," *Advances in neural information processing systems*, vol. 25, 2012.

[125] Y. Ruan, J. Ma, H. Meng, F. Qian, T. Xu, and J. Yao, "Potential quantification and impact factors analysis of energy flexibility in residential buildings with preheating control strategies," *Journal of Building Engineering*, vol. 78, p. 107657, 2023.

[126] A.-T. Nguyen, S. Reiter, and P. Rigo, "A review on simulation-based optimization methods applied to building performance analysis," *Applied energy*, vol. 113, pp. 1043–1058, 2014.

[127] W. Domschke, A. Drexl, R. Klein, and A. Scholl, *Einführung in operations research*. Springer-Verlag, 2015.

[128] E. Lee, "Indoor environmental quality (ieq) of leed-certified home: Importance-performance analysis (ipa)," *Building and Environment*, vol. 149, pp. 571–581, 2019.

[129] S. Uguz and O. Ipek, "The management of indoor thermal comfort with wireless sensor networks," *Measurement and Control*, vol. 50, no. 9-10, pp. 206–213, 2017.

[130] P. Fanger, "Thermal comfort, copenhagen, denmark," 1970.

[131] I. O. for Standardization, *Ergonomics of the thermal environment: instruments for measuring physical quantities, ISO 7726*. ISO, 1998.

[132] ——, *Ergonomics of the thermal environment — Determination of metabolic rate, ISO 8996*. ISO, 2004.

[133] ——, *Ergonomics of the thermal environment Analytical determination and interpretation of thermal comfort using calculation of the PMV and PPD indices and local thermal comfort criteria, ISO 7730*. ISO, 2005.

[134] ——, *Ergonomics of the thermal environment — Estimation of thermal insulation and water vapour resistance of a clothing ensemble, ISO 9920*. ISO, 2009.

[135] J. Malchaire, F. R. d. Alfano, and B. I. Palella, "Evaluation of the metabolic rate based on the recording of the heart rate," *Industrial health*, vol. 55, no. 3, pp. 219–232, 2017.

[136] N. Morresi, S. Casaccia, M. Sorcinelli, M. Arnesano, A. Uriarte, J. I. Torrens-Galdiz, and G. M. Revel, "Sensing physiological and environmental quantities to measure human thermal comfort through machine learning techniques," *IEEE Sensors Journal*, vol. 21, no. 10, pp. 12 322–12 337, 2021.

[137] ANSI/ASHRAE, *Standard 55. Thermal Environmental Conditions for Human Occupancy*. ASHRAE, 2004.

[138] S. Ø. Jensen, A. Marszal-Pomianowska, R. Lollini, W. Pasut, A. Knotzer, P. Engelmann, A. Stafford, and G. Reynders, "Iea ebc annex 67 energy flexible buildings," *Energy and buildings*, vol. 155, pp. 25–34, 2017.

[139] G. Reynders, R. A. Lopes, A. Marszal-Pomianowska, D. Aelenei, J. Martins, and D. Saelens, "Energy flexible buildings: An evaluation of definitions and

quantification methodologies applied to thermal storage," *Energy and Buildings*, vol. 166, pp. 372–390, 2018.

[140] A. Arteconi, A. Mugnini, and F. Polonara, "Energy flexible buildings: A methodology for rating the flexibility performance of buildings with electric heating and cooling systems," *Applied Energy*, vol. 251, p. 113387, 2019.

[141] G. Tian, Q. Z. Sun, and W. Wang, "Real-time flexibility quantification of a building hvac system for peak demand reduction," *IEEE Transactions on Power Systems*, vol. 37, no. 5, pp. 3862–3874, 2021.

[142] D. Jones, C. Snider, A. Nassehi, J. Yon, and B. Hicks, "Characterising the digital twin: A systematic literature review," *CIRP Journal of Manufacturing Science and Technology*, vol. 29, pp. 36–52, 2020. [Online]. Available: https://www.sciencedirect.com/science/article/pii/S1755581720300110

[143] M. Fournier, M.-A. Leduc, and G. Nadrault, "Winter demand response using baseboard heaters: achieving substantial demand reduction without sacrificing comfort," *Proceedings of ACEEE Summer Study on Energy Efficiency in Buildings (Pacific Grove, CA)*, pp. 1–1, 2016.

[144] R. P. Voss, "I/f noise"" in music and speech," 1975.