

UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES

MODÉLISATION ADAPTATIVE DES SYSTÈMES ÉNERGÉTIQUES
RÉSIDENTIELS DANS UN CONTEXTE DE GESTION
TRANSACTIONNELLE DE LA DEMANDE

THÈSE PRÉSENTÉE
COMME EXIGENCE PARTIELLE
DU DOCTORAT EN GÉNIE ÉLECTRIQUE

PAR

DAVID CAMILO TOQUICA CARDENAS

Décembre 2022

Université du Québec à Trois-Rivières

Service de la bibliothèque

Avertissement

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

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 ou cette thèse. Notamment, la reproduction ou la publication de la totalité ou d'une partie importante de ce mémoire ou de cette thèse requiert son autorisation.

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

Direction de recherche :

Prof. Kodjo Agbossou, directeur de recherche Université du Québec à Trois-Rivières

Prof. Roland Malhamé, codirecteur de recherche Polytechnique Montréal

Jury d'évaluation :

Prof. Kodjo Agbossou Université du Québec à Trois-Rivières

Prof. Roland Malhamé Polytechnique Montréal

Prof. Messaoud Ahmed Ouameur, évaluateur Université du Québec à Trois-Rivières

Prof. Souso Kelouwani, évaluateur Université du Québec à Trois-Rivières

Prof. Antoine Lesage-Landry, évaluateur externe Polytechnique Montréal

Résumé

La transition énergétique actuelle vise à moderniser les systèmes électriques pour les rendre plus durables, équitables et fiables. Dans cette transition, les réseaux électriques sont devenus des systèmes complexes intégrant diverses ressources énergétiques renouvelables et distribuées, des véhicules électriques, des systèmes de stockage et de nouvelles charges intelligentes. Cependant, il est nécessaire d'innover dans les mécanismes de gestion du réseau pour exploiter au mieux toutes ces ressources et garantir leur bon fonctionnement. Dans ce contexte, différents mécanismes ont été proposés pour remplacer la structure hiérarchique traditionnelle du réseau et pour rendre la gestion décentralisée et efficiente. L'un de ces mécanismes est l'énergie transactionnelle (ET), qui permet à toutes les parties prenantes de participer à des marchés de gré à gré pour acheter des services énergétiques. De cette manière, les consommateurs et les générateurs concluent des contrats bilatéraux pour répondre à leurs besoins et maintenir l'équilibre dynamique du réseau. Ces contrats déterminent les prix, les quantités d'énergie et les services associés. Par ailleurs, l'ET cherche à améliorer l'efficacité technique et économique du réseau, de sorte qu'elle encourage des procédures standardisées pour l'échange d'informations et pour découvrir la valeur des services.

Le paradigme de l'ET représente un défi pour certains utilisateurs qui ne sont pas habitués à participer aux marchés de l'énergie. C'est le cas des utilisateurs résidentiels qui jouent un rôle passif dans les mécanismes de gestion traditionnels et qui bénéficient des prix réglementés. Pour cette raison, ce projet propose de développer un agent automatisé qui représente les utilisateurs résidentiels et qui facilite leur participation à un marché de ET. L'objectif de cet agent est de trouver le plan de consommation approprié en considérant l'utilité perçue par les utilisateurs et le coût de l'énergie. L'agent proposé s'appuie sur des comportements asynchrones pour collecter des informations et interagir avec le marché.

Tout d'abord, l'agent doit interagir avec son environnement local afin de connaître les ressources derrière le compteur et de planifier sa consommation. Dans cette interaction, l'agent doit connaître la contrôlabilité des appareils et modéliser leur dynamique de façon appropriée. De plus, il faut tenir compte que les conditions de fonctionnement des appareils changent au

cours du temps, de sorte que les modèles doivent être adaptés. À cette fin, une technique de gestion des données utilisant la validation croisée a été développée pour entraîner les modèles avec les données les plus récentes et les plus pertinentes.

Ensuite, l'agent doit interagir avec l'environnement transactionnel pour obtenir des offres de marché et décider la meilleure stratégie de consommation. Cette stratégie dépend de l'élasticité-prix (la sensibilité de la demande aux variations de prix) de l'utilisateur ou de l'évaluation économique de l'utilité. Afin d'inclure ces informations dans les transactions, on utilise un système de recommandation qui suggère une valeur de l'élasticité en fonction du comportement historique de l'utilisateur. Le système facilite la participation des utilisateurs en leur permettant d'exprimer leurs préférences par des choix simples.

Comme résultat de l'intégration de ces procédures dans une architecture logicielle, l'agent développé est capable de représenter un utilisateur résidentiel dans un marché de ET à terme. Dans le cadre de ce projet, les systèmes de chauffage sont considérés comme des charges contrôlables dans les résidences en raison de leur facilité d'utilisation et du fait qu'ils représentent la plus grosse charge résidentielle en hiver dans des pays comme le Canada. Par conséquent, les agents automatisés trouvent la meilleure stratégie de consommation en tenant compte du confort thermique des utilisateurs. Les résultats des transactions démontrent la faisabilité de l'intégration de ces agents dans les mécanismes de ET pour progresser vers une gestion décentralisée et efficace du réseau électrique.

Abstract

The ongoing energy transition encourages the modernization of electric power systems to make them more sustainable, equitable, and reliable. As a result, the grids have become complex systems that integrate distributed renewable resources, electric vehicles, e-storage systems, and new smart loads. Although, it is necessary to develop new management mechanisms to exploit these resources and guarantee the grid operation. In this regard, different mechanisms have been proposed to change the traditional hierarchical management of the grid and make it decentralized and more efficient. One of the most promising mechanisms is the transactive energy (ET) that allows all stakeholders to participate in over-the-counter markets to acquire energy services. In this way, consumers and generators set prices and quantities of energy and services in bilateral contracts while keeping the dynamic balance of the grid. Besides, ET looks for technical and economic efficiency, so it promotes standard procedures for information exchange and value discovery.

The ET paradigm poses a challenge for customers that are not familiar with energy markets. That is the case of residential customers who have had a passive role in traditional grid management mechanisms by relying on regulated prices. For that reason, this project aims to develop an automated agent that represents the residential customers and facilitates their participation in energy transactions. The objective of this agent is to find an appropriate balance between the customer's utility and the electricity cost. The proposed approach is based on asynchronous behaviors to fulfill the agent's tasks and interact with the environments.

Firstly, the agent needs to interact with the local environment to know the behind-the-meter resources and plan the consumption. In this procedure, the agent needs to know the appliances' capabilities and model their dynamics accordingly. It is relevant to note that operative conditions for the appliances change in time, so the models need to be adapted. In this sense, we develop a data management technique to train the agent models with the most recent and relevant data.

Afterwards, the agent needs to interact with the transactive environment to get the market offers and find the optimal consumption strategy. This strategy depends on the price elasticity of the

customer and its willingness to pay. In order to include this information in the transactions, we develop a recommender system that suggests an elasticity value according to the historical customer behavior. This system eases the customers' participation but not limits its capacity to impose preferences in transactions.

Integrating all these procedures into a software architecture results in an agent that is able to participate in a forward market on behalf of a residential customer. In this project, space-heating systems are considered as controllable loads due to their availability in countries like Canada. Thus, the automated agent maximizes the customer's utility by balancing the thermal comfort and the electricity cost. The transaction results demonstrate the feasibility of integrating these agents into grid management mechanisms to advance towards decentralized and efficient power systems.

Table des matières

Résumé.....	i
Table des figures	vii
Liste des abréviations	viii
Chapitre 1- Introduction	1
1.1 Contexte générale de recherche	1
1.2 Motivation.....	5
1.3 Problématique	6
1.4 Objectifs et contributions.....	9
1.5 Méthodologie	10
1.5.1 Définition de l'environnement transactionnel	11
1.5.2 Développement de l'architecture des agents résidentiels	13
1.5.3 Caractérisation de l'environnement local et apprentissage adaptatif . .	15
1.5.4 Apprentissage des préférences des utilisateurs	16
1.6 Structure du mémoire	17
Chapitre 2- État de l'art	19
2.1 Agent résidentiel automatisé.....	19
2.1.1 Les plateformes multi-agents	22
2.2 Modélisation adaptative des flux de données	24
2.3 Élicitation des préférences	27

Chapitre 3-	Présentation des résultats par articles	30
3.1	Modélisation adaptative des charges résidentiels	30
3.1.1	Contexte	30
3.1.2	Méthodologie	31
3.1.3	Résultats	33
3.2	Architecture logicielle des agents résidentiels automatisés.....	53
3.2.1	Contexte	53
3.2.2	Méthodologie	54
3.2.3	Résultats	55
3.3	Intégration des préférences des utilisateurs	69
3.3.1	Contexte	69
3.3.2	Méthodologie	69
3.3.3	Résultats	71
Chapitre 4-	Mise en œuvre expérimentale	83
4.1	Plateforme multi-agents.....	83
4.2	Déploiement de logiciels	84
4.3	Caractéristiques du matériel	85
4.4	Modèles des charges résidentielles.....	87
4.4.1	Modèle de charges non contrôlables	87
4.4.2	Modèle des dispositifs de génération	87
4.4.3	Modèle de charges contrôlables	89
Chapitre 5-	Discussion et opportunités futures	91
5.1	Perspectives d'évolution des agents résidentiels automatisés	91
5.2	Perspectives de l'énergie transactionnelle	92
Chapitre 6-	Conclusions	95

Table des figures

1-1	Processus d'interaction séquentielle	11
1-2	Interaction entre un agrégateur de demande et les agents résidentiels	12
1-3	Architecture logicielle de l'agent agrégateur	13
1-4	Tâches de l'agent résidentiel	14
1-5	Modélisation à partir du flux de données	15
2-1	Modèle BDI	20
2-2	Types de dérives conceptuelles	25
2-3	Algorithmes d'apprentissage adaptatif	26
3-1	Algorithme d'adaptation	32
3-2	Architecture logicielle de l'agent résidentiel	55
3-3	Interaction de l'utilisateur avec le système de recommandation	70
4-1	Topologie du système de télécommunication	83
4-2	Transition entre les comportements de l'agent résidentiel	84
4-3	Mesures du temps de calcul des processus de l'agent résidentiel	86
4-4	Modèle de charges non contrôlables	87
4-5	Modèle des dispositifs de génération	88
4-6	Modèle de charges contrôlables	90

Liste des abréviations

ADALINE	Adaptive Linear Neuron.
ADAM	Descente de gradient stochastique avec estimation du moment adaptatif (Adaptive Moment Estimation for gradient descent).
ADWIN	Adaptive Windowing Method.
AUML	Langage de modélisation unifié des agents (Agent Unified Modeling Language).
BDI	Modèle de croyances-désirs-intentions (Belief-Desire-Intention software model).
COP26	26 ^e Conférence des parties à la Convention-cadre des Nations Unies sur les Changements Climatiques.
DDM	Drift Detection Method.
DNS	Système de noms de domaine (Domain Name System).
ET	Énergie transactionnelle (Transactive Energy).
FAN	Flexiblepower Alliance Network.
HMI	Interface homme-machine (Human-Machine Interface).
MAP	Maximum a Posteriori.
MAS	Système multiagents (Multi-agent System).
NRMSE	Racine de l'erreur quadratique moyenne normalisée (Normalized Root Mean Squared Error).
ONU	Nations Unies.

P2P	Pair-à-pair (Peer to Peer).
PAR	Rapport entre puissance de crête et puissance moyenne (Peak-to-Average ratio).
PNNL	Pacific Northwest National Laboratory US.
PRS	Procedural Reasoning System.
RLS	Recursive Least Squares filter.
RMSE	Racine de l'erreur quadratique moyenne (Root Mean Squared Error).
SGT	Technologies des réseaux intelligents (Smart Grid Technologies).
SVM	Machines à vecteurs de support (Support Vector Machine).
SVR	Régression basée sur une machine à vecteur de support (Support Vector Regression).
WTA	Propension à accepter (Willingness to Accept).
WTP	Propension à payer (Willingness to Pay).
XMPP	Protocole extensible de présence et de messagerie (Extensible Messaging and Presence Protocol).

Chapitre 1 - Introduction

1.1 Contexte générale de recherche

Le monde est actuellement confronté à de nombreux défis environnementaux tels que la lutte contre le changement climatique et la pollution des éléments abiotiques. Ces défis exigent une transition énergétique vers une exploitation durable des ressources qui limite l'augmentation de la température moyenne mondiale à 1,5 °C par rapport aux niveaux préindustriels. Plusieurs études indiquent que permettre une augmentation supérieure à cette limite causerait des dommages irréversibles à la planète et à nos sociétés [1]. Les activités humaines ont déjà induit une augmentation d'environ 1 °C, et avec les mesures actuelles, la limite de 1,5 °C pourrait être atteinte d'ici 2040 [2]. Il est nécessaire de proposer un programme de travail avec des actions concrètes pour préserver l'environnement.

Lors de la récente convention COP 26, plus de 40 pays ont convenu d'éliminer progressivement les investissements dans les systèmes à base de charbon et de maintenir la croissance des émissions de gaz à effet de serre qui contribuent au réchauffement climatique en dessous de 2 % [3]. Toutefois, cette réduction de l'exploitation des combustibles fossiles n'est pas suffisante pour éviter la limite de l'augmentation de la température mondiale. Les projections du groupe d'experts des Nations Unies (ONU) indiquent qu'il sera nécessaire de réduire de moitié les émissions de gaz à effet de serre au cours de la prochaine décennie et de parvenir à une consommation net-zero d'ici à 2050 [4]. Net-zero signifie qu'au cours d'une période donnée, la consommation des ressources est égale à la production locale. En outre, l'ONU précise que pour réduire l'inégalité causée par le réchauffement climatique, il est nécessaire de remplacer le modèle centralisé d'exploitation des ressources par des systèmes distribués.

Le changement dans la gestion des ressources ne doit pas devenir un obstacle au développement économique. La lutte contre le changement climatique doit s'accompagner d'une augmentation des énergies renouvelables et une amélioration de l'efficacité de la consommation d'énergie. De cette manière, nous serons capables de maintenir un niveau adéquat de bien-être social à mesure que la population augmente [5]. Les énergies renouvelables qui devraient se développer dans les années à venir sont le solaire (13 %/an), l'éolien (9,6 %/an) et les biocarburants (9,2 %/an) [6]. Du côté de la consommation, l'efficacité doit augmenter dans tous les secteurs, bien que les secteurs résidentiels et les transports présentent les meilleures marges d'amélioration (en conservant la productivité, la consommation diminue 2,5 %/an et 0,3 %/an respectivement) [6].

Dans ce contexte, les systèmes électriques sont devenus le cœur de la transition énergétique grâce à leur grande efficacité par rapport aux autres systèmes énergétiques. En conséquence, de nombreux gouvernements ont lancé des plans d'électrification des activités économiques [7]. Pour atteindre l'objectif d'une consommation net-zero en 2050, au niveau mondial, le secteur industriel doit être électrifié à 69 %, les systèmes de chauffage résidentiel à 32 %, la cuisson des aliments à 48 %, le transport léger à 77 % et le transport lourd à 44 % [8]

Les stratégies des plans d'électrification sont diverses, mais leurs objectifs peuvent être encadrés en trois critères : durabilité, équité et sécurité [9]. La durabilité fait référence au maintien du développement et du bien-être social sans compromettre les ressources pour les générations futures. L'équité consiste à garantir des services énergétiques pour tous à un coût abordable. La sécurité fait référence à la fiabilité, à la résilience et à l'adéquation des infrastructures. Le perfectionnement de ces indicateurs est la clé pour relever les défis environnementaux et soutenir le développement économique.

Dans un effort pour améliorer la durabilité, les ressources renouvelables ont été intégrées à différentes échelles dans les systèmes électriques. Cependant, la nature variable et intermittente de certaines de ces ressources constitue un défi pour le maintien de l'équité et de la sécurité du service d'énergie électrique. Par exemple, le manque de prédictibilité de l'énergie éolienne et de l'énergie solaire photovoltaïque empêche de les inclure dans un modèle de planification

économique qui minimise le coût total de fonctionnement du système [10]. Par conséquent, dans de nombreux scénarios, il a été résolu d'accompagner les énergies renouvelables d'autres ressources à réaction rapide telles que le gaz naturel [11]. Dans ces situations, la sécurité est privilégiée au détriment de la durabilité et de l'équité.

Afin de moderniser les systèmes électriques et de faire progresser la transition énergétique, il est nécessaire d'innover dans les ressources flexibles visant à compenser la variabilité des énergies renouvelables [12]. Les cadres réglementaires doivent éviter que la flexibilité d'un système électrique soit basée sur les combustibles fossiles. En fait, il existe des sources de flexibilité moins coûteuses qui peuvent également être efficaces, telles que la gestion de la demande et les reconfigurations du réseau [13]. Ainsi, la tendance à la baisse des prix des dispositifs de stockage d'énergie à grande échelle pourrait les rendre intéressants en tant que sources de flexibilité dans un futur proche [14].

L'intégration des différentes sources de flexibilité doit se faire en considérant leur capacité, coût et l'échelle de temps dans laquelle elles peuvent fonctionner. En général, les sources de flexibilité sont classées selon la durée de leur intervention en ressources opérationnelles, d'équilibrage ou de coordination [15]. Les ressources opérationnelles sont celles qui réagissent dans des délais inférieurs à une minute, comme l'inertie des générateurs, les batteries et les reconfigurations du réseau. Les ressources d'équilibrage réagissent en un intervalle de quelques minutes, comme la gestion à la demande, ou les dispositifs de stockage thermique ou d'hydrogène. Les ressources de coordination réagissent à des intervalles de quelques heures, ou même de quelques jours, comme le réajustement des unités de génération.

Bien que toutes les ressources de flexibilité puissent contribuer au maintien de l'équilibre du réseau, la gestion de la demande résidentielle est considérée comme l'une des ressources ayant le plus grand potentiel, en raison des perspectives d'électrification [16]. Dans des pays comme le Canada, le secteur résidentiel représente déjà 33 % de la consommation totale d'électricité et cette proportion devrait augmenter à moyen terme grâce au développement de nouveaux appareils et aux mesures de télétravail [17]. L'engagement du secteur résidentiel sera essentiel pour gérer le réseau et être en mesure d'intégrer davantage de ressources de

génération renouvelables. Il convient de souligner que les opportunités offertes par ce secteur en matière de flexibilité ne doivent pas compromettre la qualité du service aux utilisateurs [18]. Cela signifie que les utilisations finales de l'énergie ne sauraient être limitées : l'énergie des véhicules électriques doit satisfaire les besoins de mobilité, l'énergie des chauffages doit assurer le confort thermique, etc.

En termes de mécanismes de gestion pour l'intégration des ressources de flexibilité, l'énergie transactionnelle (ET) est une des solutions les plus attrayantes car elle vise à maximiser le bien-être social et à mieux répartir les bénéfices entre tous les agents du réseau. Pour cela, l'ET utilise les évaluations économiques des services énergétiques pour allouer les ressources en tenant compte des contraintes techniques du système. Différents acteurs tels que les producteurs, les consommateurs et les détaillants peuvent alors exprimer leur volonté de payer ou de vendre des services et participer aux décisions d'équilibrage du réseau. L'ET s'oppose à la structure hiérarchique traditionnelle du réseau car il favorise le partage de l'information et l'optimisation distribuée [19]. En fait, chaque agent optimise individuellement ses objectifs et, grâce aux interactions avec les autres, ils atteignent l'équilibre du système.

L'une des principales caractéristiques de l'ET est l'utilisation de réseaux de communication bidirectionnels afin que les acteurs du réseau puissent négocier, coordonner ou coopérer en fonction des services qu'ils peuvent offrir ou dont ils ont besoin. Donc, l'ET peut être considérée comme une application des technologies des réseaux intelligents (SGT) car elle nécessite une infrastructure d'interconnexion cyberphysique [20]. De plus, l'ET repose sur les principes de modularité, d'adaptabilité et d'évolutivité, de sorte que les couches de données et les composants physiques doivent être normalisés, observables et contrôlables [21].

Le champ d'application de l'ET est suffisamment large pour permettre l'intégration de toutes les ressources de flexibilité et de tous les acteurs du secteur de l'électricité [22]. En fait, le concept de l'ET peut être mis en œuvre à différents niveaux du réseau avec différents types de marchés. Par exemple, dans les réseaux de distribution, il est possible de créer des marchés locaux avec des acteurs tels que les générateurs distribués, les détaillants en énergie, les agrégateurs de demande, les organismes de surveillance, les prosommateurs et les

utilisateurs. La diversité des acteurs et des interactions ne doit pas empêcher le mécanisme de l'ET d'atteindre son objectif d'équilibrage du système électrique et d'efficacité économique.

Pour parvenir à un système électrique entièrement géré par l'ET, il sera nécessaire d'intégrer plusieurs marchés locaux. À cette fin, les contrats à terme sont largement recommandés car ils laissent le temps à tous les agents de coordonner et d'intégrer leurs opérations [23]. L'idée d'un contrat à terme est que les parties (acheteurs et vendeurs) conviennent librement de la fourniture d'un service dans le futur. De cette façon, un marché de gros peut alors trouver son équilibre en intégrant les contrats précédemment convenus sur les marchés locaux.

1.2 Motivation

Les nouvelles possibilités offertes par des technologies telles que l'ET invitent à repenser le rôle de tous les acteurs d'un système électrique, tant pour maintenir le fonctionnement du système que pour améliorer des bénéfices aux utilisateurs. Les avantages de ces technologies pour accroître le bien-être social ont été théoriquement démontrés [22]. Toutefois, il faut trouver des stratégies pour faciliter la participation et la mise en œuvre des mécanismes de l'ET. En particulier pour le secteur résidentiel, qui représente une part importante de la demande, il est nécessaire de modifier son rôle passif dans la gestion du réseau électrique. Il convient donc d'identifier les raisons qui motivent les utilisateurs à mettre en œuvre des solutions technologiques et à moderniser leurs systèmes de gestion de l'énergie. Parmi ces motivations figurent la réduction des coûts, l'amélioration de la fiabilité du service, la réduction des pertes et les bénéfices environnementaux.

Dans le cadre de l'ET, les clients résidentiels seront tenus responsables de réagir aux signaux du marché qu'ils reçoivent des autres agents pour gérer leur consommation d'énergie. Cette interaction est essentielle pour atteindre l'équilibre du réseau où le prix de l'énergie reflète les évaluations économiques des services [24]. Le prix d'équilibre indique également la distribution et le niveau d'accès aux services énergétiques, même si les clients négocient de manière égoïste [25]. Il faut souligner que l'ET permet aux agents non seulement de négocier, mais aussi de coopérer et coordonner pour poursuivre des objectifs communs, comme l'amélioration de la durabilité d'un système électrique.

L'évolution du rôle des clients résidentiels constitue une difficulté pour ceux qui n'ont pas l'habitude de participer aux transactions énergétiques. Il est donc nécessaire de développer des agents automatisés qui facilitent la participation dans les mécanismes de l'ET. De plus, ces agents aideront les utilisateurs à respecter les engagements pris sur les marchés, ce qui rendra le fonctionnement du réseau plus fiable. Les agents automatisés ont plusieurs tâches à remplir, dont les principales sont les suivantes :

- Les agents automatisés doivent modéliser la consommation et la dynamique des ressources derrière le compteur pour évaluer la faisabilité des stratégies de consommation. Cette prévision des ressources doit être effectuée de manière efficace afin de pouvoir répondre rapidement aux exigences du marché.
- Les modèles construits par les agents perdent de leur précision au fil du temps en raison de l'évolution des conditions de fonctionnement des appareils. Par conséquent, les modèles doivent s'adapter aux nouvelles conditions.
- Les modèles des différentes ressources doivent être intégrés dans la stratégie de consommation pour que l'agent automatisé puisse maximiser l'utilité du client.
- Les agents automatisés doivent également connaître les préférences des clients avant de participer à des transactions. Si les agents ne tiennent pas compte des préférences, ils ne peuvent pas garantir le meilleur équilibre entre le coût et le confort.

Pour les utilisateurs, il faut aussi envisager des alternatives afin de contribuer à la gestion du réseau qui n'affectent pas le confort. Au Canada, une alternative particulièrement intéressante est le contrôle des systèmes de chauffage. Ces systèmes représentent environ 66% de la consommation du secteur résidentiel et leurs méthodes de contrôle ont été largement étudiées [26]. De plus, les règlements et les normes de construction garantissent que les bâtiments résidentiels ont une isolation thermique, ce qui fournit un certain niveau de stockage thermique [27]. On peut donc tirer parti de ce stockage pour modifier la consommation de chauffage sans réduire sensiblement la température.

1.3 Problématique

Les développements récents des mécanismes de l'ET ont dépassé les défis particuliers des clients résidentiels pour se concentrer sur les besoins du réseau électrique [22]. Il a été

supposé en plusieurs occasions que la demande d'énergie correspondrait aux exigences du système sans analyser en détail les besoins des clients. Cependant, le succès de l'ET dépend de la participation active des clients aux négociations sur l'énergie. Pour cette raison, le problème central de ce projet de recherche est de faciliter la participation efficace des utilisateurs résidentiels (consommateurs et prosommateurs) dans les mécanismes de l'ET par le développement d'un agent automatisé. Cet agent interagit avec les ressources de la résidence et le marché transactionnel pour formuler une stratégie optimale de consommation d'énergie selon les besoins du client. De plus, l'agent automatisé doit présenter des informations simples afin que l'utilisateur puisse facilement comparer les compromis entre le coût et l'utilité.

En ce qui concerne l'interaction avec le mécanisme de l'ET, il est nécessaire de définir le type de marché auquel l'agent va participer. Dans ce cas, on considère un marché à terme dans lequel un agrégateur de demande lance un processus de négociation en demandant à l'agent résidentiel automatisé la consommation prévue pour une période définie. Cette interaction correspond à un jeu de Stackelberg, où l'agrégateur est le leader et l'agent résidentiel le suiveur [28]. Sous ces conditions, la stratégie de consommation de l'agent résidentiel est formulée avec des informations complètes, en se fiant aux signaux qu'il reçoit de l'agrégateur. Comme hypothèse dans ce projet, on considère que la conception du marché ne fournit pas d'incitations pour les agents résidentiels à mentir sur leur consommation. On n'envisage pas non plus la possibilité pour les agents résidentiels de communiquer entre eux ou s'engager dans des transactions de pair-à-pair (P2P) [29].

A partir de la définition du marché et les interactions des agents, les défis pour le développement de l'agent résidentiel automatisé se détaillent de la manière suivante :

- Afin de modéliser la consommation, il faut connaître la contrôlabilité des ressources derrière le compteur. Pour les appareils que l'agent ne peut pas contrôler, il est toujours nécessaire d'estimer la demande d'énergie. En fait, il est possible d'agréger la demande d'équipements non contrôlables et d'utiliser des modèles de boîte noire basés sur des données qui se focalisent sur la performance de l'estimation. En revanche, pour les appareils que l'agent peut contrôler, il est nécessaire de modéliser leur dynamique

avec un certain degré d'interprétabilité pour évaluer la faisabilité des stratégies de consommation. Le défi consiste à identifier un modèle qui fournit une exactitude et une précision acceptables selon chaque type de charge pour formuler la stratégie de consommation et réagir en temps requis aux signaux du marché.

- Afin d'adapter les modèles, il est nécessaire d'analyser l'évolution des conditions de fonctionnement des systèmes modélisés. Dans le contexte résidentiel, les changements peuvent être à la fois graduels et soudains. Par exemple, la dégradation des appareils peut apparaître progressivement alors que le renouvellement des appareils est un changement soudain. Même les changements dans les conditions de fonctionnement peuvent être dus à des variables de calendrier de nature récursive, car ils sont liés au comportement des utilisateurs. Plusieurs méthodes d'adaptation ont été proposées pour différents modèles afin de faire face soit aux changements graduels ou aux changements soudains [30]. Néanmoins, il est nécessaire d'étudier en détail les changements qui peuvent se produire dans ce contexte spécifique et de formuler une stratégie d'adaptation qui les prend tous en compte.
- Pour concevoir les modèles de ressources, les adapter et formuler une stratégie de consommation, l'agent automatisé a besoin d'une méthode structurée de traitement de l'information. À cet égard, le paradigme de programmation orientée agent constitue une alternative intéressante car il permet de définir les comportements réactifs et proactifs de l'agent de manière asynchrone [31]. De cette façon, l'agent peut agir de manière proactive pour collecter toutes les informations dont il a besoin à travers diverses sources et réagir à temps lorsqu'il reçoit un signal de l'agrégateur de demande. Le défi consiste à proposer une architecture logicielle qui intègre tous les comportements requis par l'agent et qui soit facilement réalisable afin de ne pas limiter l'extensibilité des mécanismes de l'ET.
- Pour inclure les préférences des utilisateurs dans les processus de décision, diverses méthodes d'apprentissage actif ont été développées pour demander directement aux utilisateurs les paramètres nécessaires à un problème d'optimisation. Toutefois, cette approche n'est pas adaptée aux utilisateurs inexpérimentés tels que les utilisateurs résidentiels. Par contre, il faut définir la façon de présenter des informations simples et

facilement comparables afin que ces utilisateurs puissent exprimer leurs préférences. Il convient aussi de mettre en œuvre un système de recommandation qui apprend des choix précédents de l'utilisateur pour suggérer des décisions appropriées dans de nouvelles conditions [32]. Ainsi, l'agent sera plus autonome dans ses interactions sur le marché en évitant de consulter l'utilisateur à chaque fois.

1.4 Objectifs et contributions

Pour répondre à la problématique exposée, ce projet propose de développer un agent automatisé avec des techniques d'apprentissage adaptatif pour participer de manière appropriée à un système transactionnel. Les étapes proposées pour atteindre ce but sont résumées dans les objectifs spécifiques suivants :

- Caractériser les systèmes derrière le compteur des consommateurs et des prosummateurs résidentiels pour connaître leurs possibilités dans les mécanismes d'énergie transactionnelle.
- Formuler une méthode d'apprentissage adaptative qui tient compte des profils de consommation et de leurs variables explicatives afin de fournir des informations aux agents pour la prévision et la planification dans un marché à terme.
- Intégrer la méthode d'apprentissage dans l'architecture d'un agent automatisé pour contrôler les appareils en fonction des signaux du marché.
- Analyser les méthodes de collection de données appropriées pour compléter les informations requises pour les transactions et réduire la complexité pour les utilisateurs.

La réalisation de ces objectifs a donné lieu à trois contributions principales

- Une nouvelle méthode d'apprentissage adaptative basée sur la validation croisée pour les agents résidentiels. La méthode est non itérative, de sorte qu'elle est moins complexe sur le plan informatique que les autres méthodes de la littérature. De plus, la méthode permet de conserver une seule fenêtre de données pour entraîner plusieurs modèles, car elle prend en compte différents critères avant d'éliminer les données.

- Une architecture logicielle pour des agents résidentiels automatisés composée de comportements asynchrones. Ces comportements définissent la manière dont l’agent collecte les informations nécessaires pour participer à un marché à terme de l’ET. Parmi les comportements, il y a aussi un processus d’optimisation pour trouver la stratégie de consommation la plus appropriée pour l’utilisateur.
- Un système de recommandation basé sur un processus gaussien qui permet de modéliser les préférences des utilisateurs. Ce système de recommandation a été développé spécifiquement pour les préférences de confort thermique, de sorte que l’agent peut l’utiliser pour contrôler les systèmes de chauffage. Avec ce système, on définit la manière dont l’utilisateur peut configurer ses préférences sans être obligé de connaître les détails techniques des transactions ou les paramètres du système de commande.

1.5 Méthodologie

La méthodologie proposée pour répondre aux objectifs de ce projet de thèse est structurée en quatre étapes. Dans une première étape, on définit le protocole d’interaction de l’agent résidentiel dans l’environnement transactionnel et les signaux qui seront échangés. À cette fin, on a analysé l’état de l’art des plateformes de l’ET pour identifier les signaux les plus fréquemment utilisés par les consommateurs d’énergie. Ensuite, on développe l’architecture logicielle de l’agent résidentiel en intégrant les comportements (modules ou processus) qui lui permettent de réaliser ces tâches. Puis, on analyse comment l’agent peut caractériser son environnement local. Pour ce faire, il est nécessaire d’identifier les besoins en matière de modélisation des charges résidentielles et concevoir une méthode d’adaptation appropriée pour l’agent. Finalement, on définit l’interaction avec l’utilisateur pour fermer la boucle de contrôle des charges résidentielles. Dans ce cas, un système de recommandation a été développé afin de simplifier les informations demandées aux utilisateurs et de rendre la participation de l’agent au système de l’ET plus autonome. La validation de la méthodologie proposée a été faite avec des données réelles de consommation de la région du Québec, Canada.

1.5.1 Définition de l'environnement transactionnel

La théorie des jeux est le cadre conceptuel pour l'analyse des stratégies d'agents rationnels. Dans le cas d'un marché de l'ET sur lequel un agrégateur de demande intervient en tant que leader, la configuration appropriée pour décrire la dynamique du marché est le jeu de Stackelberg [33]. Selon cette configuration, l'agrégateur commence l'interaction avec les agents résidentiels en envoyant un signal de prix à tour de rôle et il attend que chacun réponde avec son plan de consommation. Ainsi, les agents résidentiels forment leur stratégie à chaque fois en s'appuyant sur les informations de l'agrégateur. Après un certain nombre de répétitions de cette interaction, l'agrégateur obtient assez d'informations pour établir des contrats à terme avec chaque agent. La seule marchandise considérée est l'énergie active, les messages sont donc simplement des vecteurs du prix ou de consommation pour la période du marché. Comme condition de fonctionnement, l'agrégateur doit savoir à l'avance quels agents il coordonne et il doit s'assurer que tous participent aux transactions. L'interaction entre les agents est illustrée dans la Figure 1-1.

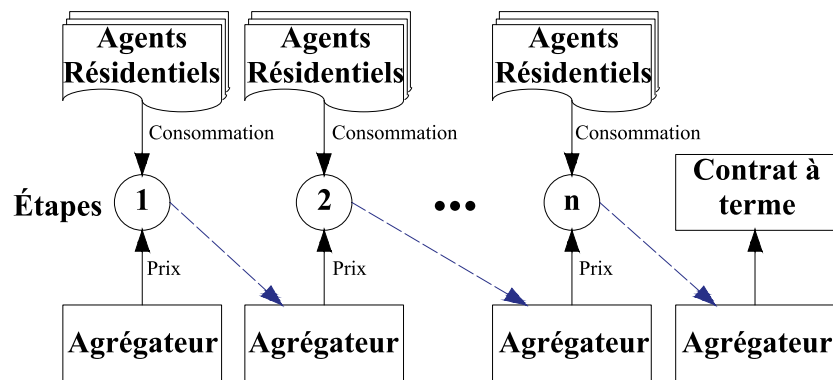


FIGURE 1-1 Processus d'interaction séquentielle

Habituellement, les mécanismes de l'ET sont conçus pour être déployés sur des protocoles de communication de haut niveau (tels que XMPP¹) sans aborder les aspects des couches inférieures [34]. Pour permettre à l'agrégateur d'identifier les agents résidentiels avant de commencer la négociation, ces derniers envoient un message d'inscription annonçant qu'ils sont prêts à participer. Ainsi, l'agrégateur crée la liste des agents et lance le processus séquentiel

1. Extensible Messaging and Presence Protocol

de négociation. Une fois que le profil agrégé de demande est favorable, l'agrégateur envoie un message d'approbation (un accusé de réception en informatique) à tous les agents résidentiels. La Figure 1-2 résume cette interaction dans le langage de modélisation unifié des agents (AUML). Étant donné que les agents poursuivent un contrat à terme pour la provision d'énergie dans une période futur, le temps requis pour effectuer le processus séquentiel n'est pas un facteur critique.

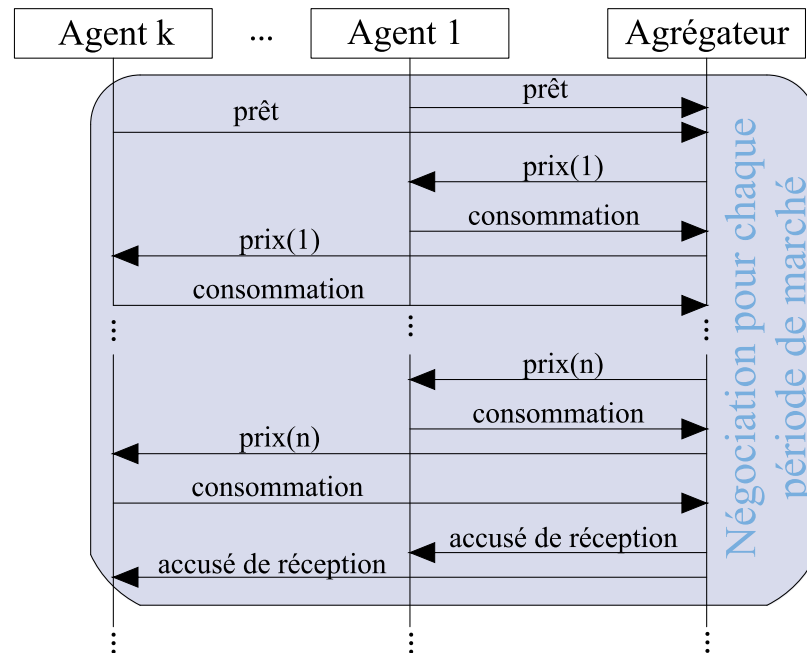


FIGURE 1-2 Interaction entre un agrégateur de demande et les agents résidentiels

Ce projet est focalisé sur les agents résidentiels et il n'est donc pas intéressant d'évaluer la pertinence des agrégateurs ou le bénéfice économique pour les gestionnaires de réseau. On part du principe que l'objectif de l'agrégateur est de coordonner les agents résidentiels afin d'aplanir la demande agrégée (réduire le rapport entre puissance de crête et puissance moyenne PAR), car c'est une approche habituelle dans la littérature [35]. Par conséquent, l'agent agrégateur utilisé pour envoyer des signaux de prix ne possède que les comportements asynchrones suivants : acquisition d'informations sur les prix à partir d'un marché de gros, enregistrement des clients, optimisation du profil agrégé de demande et communication avec les agents. L'architecture de cet agent est présentée dans la Figure 1-3.

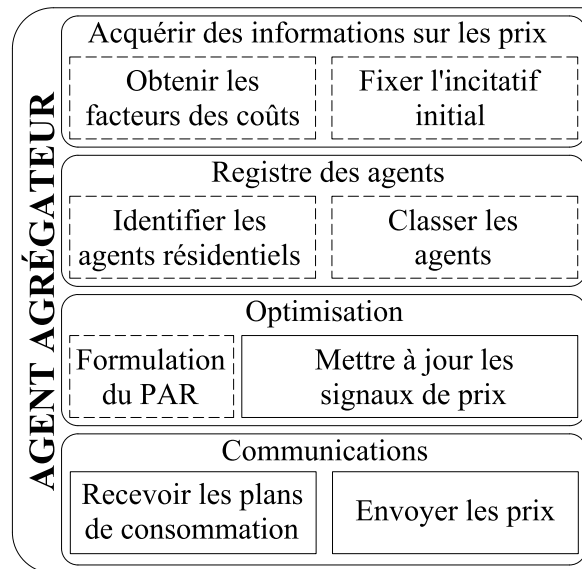


FIGURE 1-3 Architecture logicielle de l'agent agrégateur

Tout d'abord, l'agrégateur doit obtenir les paramètres relatifs aux coûts du réseau afin de formuler une politique tarifaire et la valeur initiale de l'incitatif. L'agrégateur doit également garder en mémoire le registre des agents résidentiels qui appartiennent à son marché et, si possible, les classer en tant que consommateurs ou prosommateurs. Dans le bloc d'optimisation, l'agrégateur met à jour le signal de prix selon les réponses des agents résidentiels et l'objectif de coordination qu'il a (dans ce cas la réduction du PAR). Enfin, l'agrégateur doit disposer d'un module de communication pour envoyer les signaux de prix et recevoir les profils de consommation.

1.5.2 Développement de l'architecture des agents résidentiels

Selon le Pacific Northwest National Laboratory, les agents qui participent à un mécanisme de l'ET doivent effectuer les tâches suivantes : prévision, planification, contrôle de la charge, inscription au marché, négociation, vérification et rapprochement [36]. Ces tâches résument l'interaction de l'agent avec les ressources derrière le compteur et le système transactionnel, comme le montre la Figure 1-4. Dans le cadre du modèle BDI (beliefs, desires, intentions), on peut dire que les croyances de l'agent sont exprimées dans les modèles mathématiques de ressources derrière le compteur, ses désirs sont exprimés dans la fonction objective d'un

problème d'optimisation, et ses intentions apparaissent avec la solution de ce problème pour être ensuite communiquées aux autres agents.

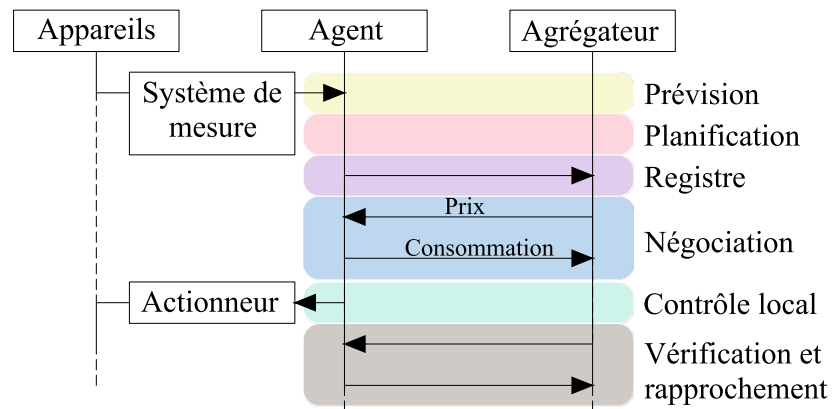


FIGURE 1-4 Tâches de l'agent résidentiel

L'agent résidentiel dispose de trois sources d'information : les systèmes de mesure des appareils, les services d'information externes (tels que les services météorologiques) et l'interface homme-machine (HMI). Il est avantageux pour l'agent de mettre en œuvre une base de données indexée dans le temps pour sauvegarder les données provenant de ces trois sources. L'agent doit traiter ces données afin de reconnaître et modéliser son environnement local. Ensuite, il doit optimiser la stratégie de consommation et établir les signaux de commande pour les actionneurs des appareils. Il existe plusieurs sources d'incertitude dans les données de l'agent, de sorte que la consommation réelle peut s'écarter de la stratégie de l'agent. Pour cette raison, il faut disposer de mécanismes pour concilier les différences sur le marché et permettre à l'agent de calculer les pénalités pour ses écarts. Toutes les tâches de l'agent mentionnées ci-dessus sont structurées sous la forme de fonctions asynchrones dans l'architecture logicielle développée.

Les tâches de l'agent résidentiel peuvent être divisées en deux catégories : la prévision (collecte et organisation des données) et la planification (formulation de stratégies de consommation). La partie prévision est généralisable à différents types de marchés car elle dépend des ressources derrière le compteur. D'autre part, les tâches de planification dépendent des signaux de prix que l'agent reçoit du système de l'ET, elles sont donc formulées spécifiquement pour le jeu de

Stackelberg décrite ci-dessus. Pour participer à d'autres marchés, il faut modifier les horizons d'optimisation ou même les variables de décision.

1.5.3 Caractérisation de l'environnement local et apprentissage adaptatif

À partir du flux de données des systèmes de mesure, l'agent doit générer les modèles des appareils. Dans cette application, l'agent doit savoir à l'avance si les dispositifs sont contrôlables ou non, car les modèles requis seront de nature différente. Pour les appareils qu'il ne peut pas contrôler, il lui suffit de prévoir la consommation. Cela signifie que l'agent peut utiliser des modèles de boîte noire privilégiant la performance [37]. D'autre part, pour les appareils contrôlables, l'agent doit connaître leur dynamique et leurs limites de fonctionnement. Donc, il faut utiliser des modèles qui permettent une meilleure interprétation des caractéristiques physiques pour ces appareils. Le processus de modélisation des données est illustré dans la Figure 1-5.

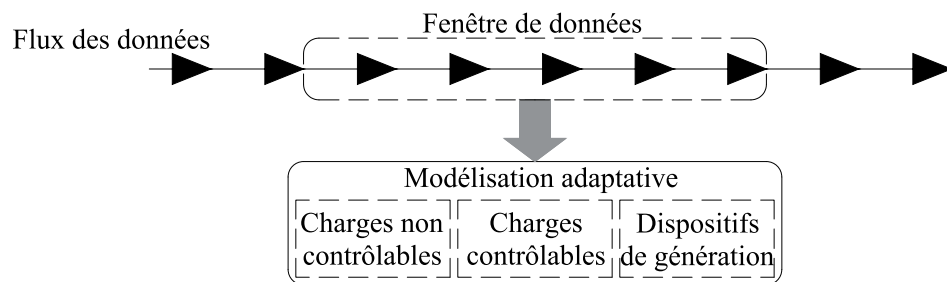


FIGURE 1-5 Modélisation à partir du flux de données

Afin de simplifier la gestion des données et de ne pas rendre les variables des modèles redondantes, l'agent regroupe les données de toutes les charges non contrôlables et de tous les dispositifs de génération. Pour évaluer la méthodologie proposée, on a utilisé une étude de cas basée sur des données de consommation de la région de Québec, CA, qui montrent une corrélation avec des variables telles que l'heure de la journée et la température extérieure. Les données du dispositif de génération correspondent à une installation photovoltaïque de 10 kWp. Par rapport à la charge contrôlable, on considère un système de chauffage d'une seule zone. Pour ce système, on utilise un modèle d'espace d'état qui fournit l'interprétabilité nécessaire pour déterminer les effets de différentes actions de contrôle.

L'algorithme proposé pour adapter les modèles des ressources mentionnés ci-dessus considère que les conditions peuvent changer à des vitesses différentes. Par exemple, les conditions climatiques qui influencent la consommation changent progressivement tout au cours de l'année. La dégradation des appareils peut également être considérée comme un changement progressif. Par contre, le renouvellement des appareils et la déconnexion des modules de génération provoquent des changements soudains.

1.5.4 Apprentissage des préférences des utilisateurs

L'agent doit connaître les préférences de l'utilisateur afin de le représenter dans les transactions. Plus précisément, il doit connaître l'élasticité-prix ou la manière dont l'utilisateur valorise son utilité par rapport au coût de l'électricité. Pour éviter de consulter ce paramètre à chaque fois, on utilise un système de recommandation qui suggère des valorisations appropriées selon le comportement historique de l'utilisateur. Cela réduit l'intervention de l'utilisateur, mais ne limite pas sa capacité à prendre des décisions. Dans le cas du système de chauffage, les préférences de l'utilisateur sont traduites en termes de confort thermique [38].

Lorsqu'on demande à un utilisateur rationnel quelles sont ses préférences, on prévoit qu'il choisira les mêmes valeurs dans les mêmes conditions puisque ses préférences en matière de coûts sont strictement monotones [39]. C'est-à-dire que, face à deux alternatives qui donnent lieu à des utilités égales (même confort thermique), l'utilisateur rationnel préfère toujours l'alternative la moins coûteuse. Certains facteurs induisent du bruit dans les décisions de l'utilisateur, comme l'impatience et l'inattention. Cependant, selon la loi des grands nombres, il est possible de considérer que les préférences suivent une distribution gaussienne pour les décisions en variables continues (ou modèle de Mallows pour les préférences discrètes) [40]. Par conséquent, le système de recommandation devient un processus gaussien.

Un avantage de l'utilisation des processus gaussiens est qu'ils réduisent le problème du démarrage à froid des systèmes de recommandation, car ils peuvent incorporer une distribution a priori et s'adapter rapidement aux nouvelles données. D'autre part, les équations pour prédire les prochains états du processus sont bien documentées dans la littérature [41].

1.6 Structure du mémoire

Au cours de ce chapitre d'introduction, on a énoncé le problème que ce projet de recherche vise à résoudre dans le contexte général de l'ET, ainsi que la méthodologie pour y répondre. Le chapitre 2 suivant présente l'état de l'art des différentes techniques mentionnées dans la méthodologie : en premier lieu, les principales avancées dans le développement d'agents automatisés pour les marchés de l'électricité et les standards applicables sont décrites. Ensuite, les systèmes multiagents et les plateformes de l'ET sont analysés pour mieux comprendre leurs avantages. Puis, on examine en détail les techniques d'apprentissage adaptatif existantes et la possibilité de les intégrer dans des agents résidentiels. Finalement, les méthodes d'apprentissage des préférences existantes dans la littérature sont présentées avec les interactions des utilisateurs.

Le chapitre 3 présente les articles publiés comme résultat de ce travail de recherche. Le premier détaille la technique d'apprentissage adaptatif créée pour répondre aux besoins d'information de l'agent résidentiel. Le deuxième article établit l'architecture logicielle de l'agent pour intégrer les différentes techniques d'apprentissage de manière modulaire. Finalement, le dernier article décrit l'interaction de l'agent avec l'utilisateur et la manière dont l'agent peut apprendre les préférences.

Le chapitre 4 décrit le montage expérimental permettant de valider les fonctions des agents résidentiels. Il convient de noter que la mise en œuvre réelle des agents automatisés nécessite des solutions pratiques pour garantir l'extensibilité du système de l'ET. Par conséquent, ce chapitre présente également des suggestions d'un point de vue technique pour l'installation des agents. A titre d'exemple, les modèles créés pour les simulations sont aussi présentés.

Le chapitre 5 présente les possibilités ouvertes par le développement de l'agent résidentiel automatisé ainsi que la vision d'un système entièrement géré par l'ET. L'approche développée dans ce projet visant à créer de la valeur pour les clients permettra d'évoluer vers une gestion distribuée et efficace des ressources. Ce chapitre aborde également les prochaines étapes du développement des autres acteurs du réseau et l'évolution de l'agent résidentiel pour contrôler

plusieurs charges. Le chapitre 6 présente enfin les conclusions de ce travail de recherche en soulignant les principales contributions.

Chapitre 2 - État de l'art

2.1 Agent résidentiel automatisé

Pour faciliter la participation des utilisateurs résidentiels au système de l'ET, on utilise un agent automatisé programmé sur le matériel local de la résidence. Le concept de programmation orientée agent a été introduit en 1993 comme un paradigme dérivé de la programmation orientée objet [42]. Dans ce paradigme, un agent est défini comme une entité capable de raisonner, de prendre des décisions de manière indépendante, de communiquer avec d'autres agents, de réagir à son environnement et d'exécuter des actions pour atteindre son objectif. Par conséquent, un agent n'agit pas seulement de manière réactive, mais aussi de manière proactive, contrairement aux autres approches de programmation conventionnelles. Ce paradigme a permis d'étendre l'application des agents à diverses domaines telles que la gestion des communications, l'automatisation, la robotique et les jeux vidéo [43].

Un agent doit posséder des compétences cognitives et sociales pour percevoir l'état de son environnement et agir de manière autonome en fonction de sa rationalité [44]. Une méthode largement utilisée pour le développement d'agents automatisés consiste à formuler la structure du logiciel sous la forme du modèle croyance-désir-intention (BDI), comme le montre la Figure 2-1. Ce modèle intègre des fonctionnalités axées sur des mécanismes d'apprentissage et des procédures d'optimisation afin de permettre aux agents de prendre des décisions rationnelles. Il faut considérer que la rationalité d'un agent est limitée par la traçabilité des conséquences de ses actions, les limites cognitives et le temps disponible pour prendre des décisions. Aussi, il convient de souligner que les croyances de l'agent sont des modèles mathématiques qui représentent l'état actuel de son environnement, et peuvent être stochastiques ou déterministes.

Ensuite, les désirs de l'agent sont généralement formulées comme une fonction objectif d'un problème d'optimisation. Les intentions apparaissent alors comme la solution au problème d'optimisation en considérant les croyances que l'agent a sur son environnement. Il existe d'autres méthodes de développement d'agents qui requièrent la connaissance de la transition des états dans l'environnement de l'agent, comme le Procedural Reasoning System (PRS) et le Situation Calculus [45].




FIGURE 2-1 Modèle BDI

Les caractéristiques d'autonomie, de proactivité et de sociabilité des agents les rendent intéressants pour résoudre les problèmes liés aux réseaux électriques. Au cours des dernières années, les agents ont été utilisés pour gérer les microréseaux, surveiller et diagnostiquer les anomalies du réseau, coordonner les protections et planifier le fonctionnement d'un système électrique [46]. Parmi les avantages de l'utilisation d'agents, on peut citer l'amélioration de la supervision du système par la distribution des agents et la réduction de la complexité en évitant les solutions centralisées. De plus, les agents donnent une condition d'adaptabilité au réseau lorsqu'ils sont capables d'apprendre et de se rajuster à de nouvelles conditions [47].

Les agents sont définis par une architecture logicielle qui décrit les modules qui les composent et les relations entre eux [48]. Les modules sont communément appelés comportements, car ils sont initialisés et gérés par l'agent lui-même sans contrôle externe. Les comportements peuvent être exécutés une fois, périodiquement ou en réaction à des événements dans l'environnement. L'architecture logicielle définit également la relation entre ces comportements, car ils peuvent fonctionner de manière asynchrone ou comme une machine à états. Par exemple, un agent peut utiliser un module pour filtrer les messages qu'il reçoit d'autres agents, et ceci peut déclencher un autre module cognitif pour préparer une réponse aux messages.

Dans le contexte du problème transactionnel, différentes architectures logicielles ont été proposées en fonction du rôle de l'agent. Dans la littérature, il est possible de trouver des architectures d'agents pour les gestionnaires de réseau, les agrégateurs de demande et les gestionnaires de groupes de charges spécifiques telles que les véhicules électriques et les batteries, etc. [49]. Cependant, le développement d'agents pour le secteur résidentiel est insuffisant, car les solutions se concentrent sur des agents qui ont une meilleure observabilité du système pour coordonner la demande [50]. En effet, un agent résidentiel n'est pas en mesure d'observer les actions des autres agents, sa rationalité est donc plus limitée et ses décisions ne garantissent pas le fonctionnement optimal du réseau. Il faut les coordonner par l'intermédiaire d'un agrégateur de demande ou d'un agent de niveau supérieur. Il existe également des approches qui évitent l'utilisation d'agents résidentiels en donnant la possibilité aux agents des opérateurs de réseau de contrôler directement les charges [51].

Les développements dans le domaine des agents gestionnaires de charges ont aussi intégré des normes telles qu'ISO¹ 14543 qui spécifie les protocoles de communication pour les équipements du secteur résidentiel, ISO 15067 qui guide les mécanismes de réponse à la demande, et ANSI/CTA² 2045 qui fournit un cadre pour les systèmes de communication modulaires. L'adoption de normes aidera les entreprises intéressées à développer des solutions pour les clients et à réduire le coût de la technologie [52]. De plus, ils permettent le déploiement de systèmes plus efficaces avec une granularité plus élevée. Dans une résidence, plusieurs agents pourraient coexister pour gérer des dispositifs particuliers et même agir de manière opportuniste pour accroître l'utilité de l'utilisateur [53].

Toutefois, la plupart des approches d'agents proposées ne tiennent pas compte des préférences des utilisateurs pour prendre des décisions en matière de transactions énergétiques. En fait, le développement des agents s'est davantage concentré sur les caractéristiques des équipements et n'a pas suffisamment pris en compte le comportement des utilisateurs. En conséquence, les systèmes développés donnent l'impression d'imposer des conditions aux utilisateurs et d'être intrusifs dans la gestion des appareils. Un autre aspect qui n'a pas été bien étudié dans

1. International Organization for Standardization

2. American National Standard / Customer Technology Association

le développement des agents est le changement des conditions de leur environnement. Bien que les objectifs de l'agent peuvent rester les mêmes, ses croyances et ses intentions doivent s'adapter aux informations les plus récentes qu'il possède.

2.1.1 *Les plateformes multi-agents*

Il est essentiel non seulement d'analyser les lacunes de la recherche sur les agents résidentiels, mais aussi de comprendre comment les agents interagissent entre eux pour atteindre leurs objectifs. Au cours des dernières années, les systèmes multiagents (MAS) ont été utilisés dans divers domaines de l'ingénierie pour la gestion distribuée en raison de leur flexibilité, extensibilité et autonomie. En particulier, ces caractéristiques sont appropriées pour le contrôle et la gestion des systèmes électriques qui deviennent de plus en plus complexes en raison de l'incorporation de ressources distribuées. L'adoption des MAS peut contribuer à la popularisation de l'ET, car ils favorisent la participation et l'interaction des utilisateurs avec d'autres acteurs du réseau. Par ailleurs, les MAS améliorent la transparence des marchés de l'énergie parce qu'ils permettent un audit continu des agents et de leurs interactions. Pour ces raisons, l'économie computationnelle basée sur les MAS est considérée comme l'une des clés pour le développement de mécanismes de ET. [54]

L'une des premières applications du MAS sur les marchés de l'énergie apparaît dans les développements de Bunn en 2001 [55]. Dans ce travail, des modèles automatisés basés sur des agents sont proposés pour explorer les impacts de la restructuration et de la décentralisation des marchés de gros en Angleterre. Également pour les marchés de gros, Nicolaisen et al. [56] ont étudié le mécanisme d'enchères à deux niveaux en utilisant des agents qui prennent leurs décisions en fonction d'algorithmes d'apprentissage par renforcement. Pour les marchés locaux, il y a des analyses d'agents capables de décider tant des consommations d'énergie que des types de contrats [57]. Sur la base de ces études, plusieurs plateformes de simulation ont été développées, telles que MASCEM (MAS for competitive Electricity markets) de 2003 par l'Institut polytechnique de Porto [58], AMES de 2017 à l'Université de l'Iowa [59] et TESP de 2017 par Pacific Northwest National Laboratory (PNNL) [60].

Plus récemment, certaines plateformes ont été élaborées spécifiquement pour l'ET, comme

le système Volttron développé par le PNNL [61]. L'objectif principal de cette plateforme est de rendre le marché accessible grâce à des ressources informatiques à faible coût tout en maintenant l'extensibilité, l'interopérabilité et la sécurité des données. Pour conserver ces caractéristiques, la plateforme a intégré plusieurs protocoles de communication et a permis la connexion d'un grand nombre de dispositifs (charges, générateurs et systèmes de stockage). Cette plateforme permet également d'intégrer le protocole OpenADR, créé par une alliance d'industries reconnues dans le secteur de l'électricité, qui vise à normaliser les signaux de gestion de la demande [62]. Cependant, le fait que Volttron soit centré sur les dispositifs plutôt que sur les utilisateurs rend le système intrusif. Une autre plateforme qui suit des principes similaires centrés sur les dispositifs est la plateforme EF-Pi développée par FAN (Flexiblepower Alliance Network), mais elle n'a pas le même niveau d'intégration des standards commerciaux que Volttron [63].

Les plateformes MAS susmentionnées ont permis d'analyser le couplage entre les marchés locaux à court terme et les marchés de gros par le biais de l'ET [64]. Ces couplages sont nécessaires pour améliorer la flexibilité du système et supporter la prise de décision de chaque agent en divers horizons et niveaux de gestion. Les plateformes ont également permis d'améliorer la répartition des coûts et de comprendre que les MAS ne sont pas à l'abri des défaillances du marché, telles que la concurrence imparfaite, les barrières à l'entrée ou les rationalités limitées [65]. Par ailleurs, il a été possible d'étudier les MAS avec des agents régulateurs pour harmoniser les interactions et rendre les marchés plus transparents.

Les développements dans le domaine des MAS ont conduit à la création de cadres de référence visant à normaliser les interactions entre les agents, tant pour les réseaux de distribution que pour les microréseaux [66]. Par exemple, il existe des patrons pour les interactions entre les agents résidentiels, les agrégateurs de demande et les détaillants, afin de réduire les coûts de participation et d'exploiter tous les avantages qu'ils peuvent offrir à un système électrique [24]. Les cadres de référence permettent à ces acteurs du marché de formuler des stratégies alignées sur les intérêts des gestionnaires de réseau et des gouvernements [67]. De plus, grâce à la scalabilité du MAS, les systèmes électriques pourraient être coordonnés et gérés entièrement avec des signaux de l'ET [49].

Toutefois, la confidentialité et la sécurité des données constituent l'une des préoccupations croissantes concernant la mise en œuvre des MAS en l'ET [22]. Étant donné que les interactions des agents utilisent directement les signaux de prix, il y a un risque d'injection de fausses données et des distorsions [34]. L'une des solutions pour éviter ces problèmes consiste à intégrer la technologie Blockchain, qui a prouvé son utilité pour améliorer la sécurité des transactions énergétiques [68]. De plus, la technologie Blockchain est alignée sur les principes de transparence et de décentralisation de l'ET.

2.2 Modélisation adaptative des flux de données

Dans le modèle BDI présenté précédemment, les croyances que l'agent a sur son environnement sont des modèles mathématiques obtenus à partir de méthodes d'apprentissage automatique supervisé [69]. Pour l'agent résidentiel, ces modèles lui permettent d'estimer la consommation des appareils et de connaître leur dynamique afin de les contrôler. Dans l'apprentissage supervisé, l'agent identifie les variables explicatives qui influencent la consommation et trouve la relation entre elles. Les modèles sont donc le résultat d'un problème de régression. Cette approche d'apprentissage automatique a été utilisée pour modéliser la consommation du secteur résidentiel à différentes échelles de temps et s'est avérée pratique pour les besoins en information des agents [70]. Pour mettre en œuvre les méthodes d'apprentissage supervisé, il faut disposer d'un ensemble de données d'apprentissage prédéfini avec des interprétations précises.

Afin que l'agent puisse se fier aux informations contenues dans les modèles, il doit s'assurer que les données d'apprentissage sont liées à son environnement actuel. En cas de changement des conditions de l'environnement, l'agent doit adapter les modèles en apprenant des nouvelles conditions. Cela implique que la procédure d'apprentissage de l'agent est intégrée dans un algorithme adaptatif qui définit quand et comment entraîner les modèles [71]. Différents algorithmes d'adaptation ont été développés pour appliquer des méthodes d'apprentissage supervisé à des flux de données en tenant compte des différents types de changements qui peuvent apparaître.

Formellement, le changement dans le temps de la distribution conjointe entre une variable à prédire (y) et ses variables explicatives (X) est connu sous le nom de "dérive conceptuelle" [72]. La distribution conjointe $\mathbb{P}_t(X, y)$ en temps t s'exprime de la manière suivante en raison de la relation causale qui existe entre les variables [73] :


$$\mathbb{P}_t(X, y) = \mathbb{P}_t(y|X)\mathbb{P}_t(X) \quad (2.1)$$

$\mathbb{P}_t(y|X)$ est la distribution postérieure de la variable à estimer conditionnée par les variables explicatives, et $\mathbb{P}_t(X)$ est la distribution des variables explicatives [74]. La dérive conceptuelle peut se produire en raison d'un changement de l'une ou des deux distributions dû à diverses causes. Par exemple, si les variables explicatives contiennent des informations météorologiques, les changements saisonniers apparaîtront dans $\mathbb{P}_t(X)$, tandis que les effets tels que la dégradation intrinsèque des équipements apparaîtront dans $\mathbb{P}_t(y|X)$. Les modèles génératifs, $\mathbb{P}_t(X|y)$, ne sont pas pris en compte sous l'hypothèse que la variable à estimer ne conditionne pas les instances futures des variables explicatives. Généralement, une dérive conceptuelle est exprimée avec la distribution conjointe évaluée aux temps t et $t + m$, ($\mathbb{P}_t(X, y) \neq \mathbb{P}_{t+m}(X, y)$) ainsi les dérives conceptuelles peuvent être classées comme soudaines ou graduelles selon la magnitude de m [75]. La Figure 2-2 représente différents types de dérives conceptuelles qui pourraient apparaître dans les données de l'agent résidentiel, telles que les dérives soudaines, graduelles, et incrémentales (un cas particulier de dérives graduelles).

Dérive soudaine



Dérive incrémentale



Dérive graduelle



FIGURE 2-2 Types de dérives conceptuelles

En vue de résoudre le problème de la dérive conceptuelle, différentes stratégies d'adaptation

ont été développées pour les modèles d'apprentissage supervisé. Afin de limiter l'analyse de l'état de l'art, il est nécessaire de déterminer les caractéristiques des dérives conceptuelles qui peuvent se produire dans le contexte d'un agent résidentiel. Tout d'abord, il peut y avoir des dérives conceptuelles graduelles et soudaines dans la même fenêtre de données, ainsi que des valeurs aberrantes du système de mesure ; l'adaptation doit donc être robuste et ne pas se limiter à un seul type de changement [76]. Ensuite, l'agent doit entraîner les modèles des multiples appareils, ou groupes d'appareils, pour prendre une décision en un temps limité, de sorte qu'il n'est pas pratique d'utiliser l'adaptation par ensemble de modèles [77]. Finalement, l'agent doit intégrer facilement de nouveaux appareils avec différents modèles, donc l'utilisation de techniques d'adaptation incrémentale n'est pas recommandée, car ils sont basés sur un modèle spécifique [78].

À partir de ces considérations, la Figure 2-3 montre les caractéristiques que doit avoir l'algorithme pour adapter les modèles d'un agent résidentiel. En ce qui concerne la stratégie d'adaptation, elle peut être continue ou déclenchée uniquement lorsqu'une dérive conceptuelle est détectée. En ce qui concerne la gestion des modèles, l'option consiste à utiliser un modèle unique pour réduire le volume de données à traiter. Concernant l'acquisition des données, l'option est alors d'intégrer des fenêtres de données à chaque fois car l'agent opère sur un marché à terme. Pour le mécanisme d'oubli des données, il faut tenir compte à la fois du temps d'acquisition et de la pertinence des données. Enfin, la stratégie d'apprentissage doit se faire par le biais du recyclage (re-entraîner) car il n'est pas possible d'utiliser des méthodes incrémentales.

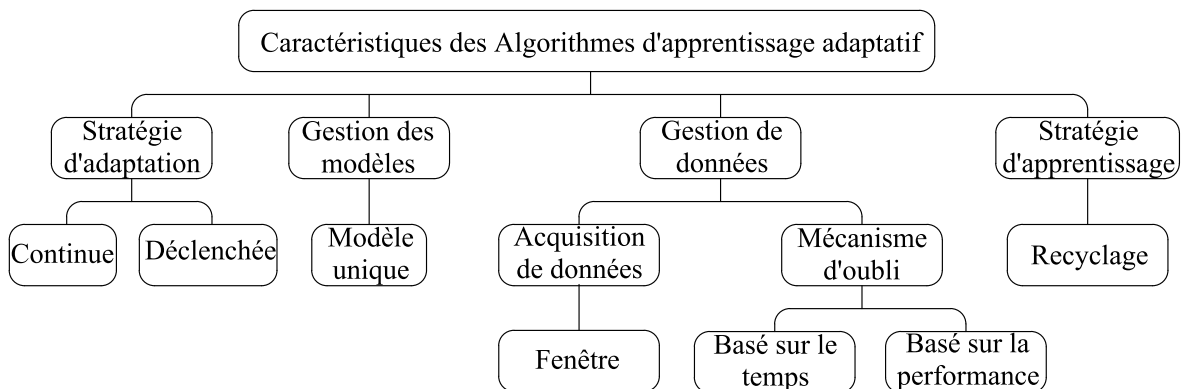


FIGURE 2-3 Algorithmes d'apprentissage adaptatif

Dans la littérature, il est possible de trouver plusieurs algorithmes qui ont les caractéristiques souhaitées pour cette application, par exemple : le "Drift Detection Method" (DDM) qui est basée sur le suivi de l'erreur de prédiction du modèle pour adapter ses paramètres lorsque cette erreur dépasse un seuil [79]. La méthode d'adaptation continue basée sur le nombre d'or, qui consiste à rechercher de manière exhaustive le nombre optimal de données permettant de minimiser l'erreur du modèle à chaque instant [80]. Une autre option est la méthode proposée par Klinkenberg dans [81] qui est basée sur la validation croisée en prenant les données les plus récentes comme ensemble de test. La méthode "Fish", qui repose sur l'entraînement continu du modèle en ne sélectionnant que les données les plus récentes qui sont les plus liées aux variables explicatives de la période à prévoir [75]. La méthode ADWIN, qui est basée sur un test d'hypothèse où l'hypothèse nulle est qu'il n'y a pas de dérive conceptuelle et donc pas de données à ignorer. Cette hypothèse est testée avec la différence de la moyenne des ensembles des données avant et après l'ajout de nouveaux échantillons [82].

2.3 Élicitation des préférences

Dans le secteur résidentiel, plusieurs études ont identifié des charges qui peuvent être utilisées pour donner de la flexibilité aux systèmes électriques [83]. Les mécanismes de l'ET permettent de valoriser cette flexibilité de sorte que les agents automatisés puissent réaliser des économies en modifiant leur consommation. Toutefois, pour modifier la consommation sans compromettre le confort, les agents doivent tenir compte des préférences des utilisateurs.

Une méthode simple pour connaître les préférences des utilisateurs consiste à interroger directement la disposition à payer (WTP) par le biais d'une interface homme-machine (HMI) [84]. On pourrait aussi demander aux utilisateurs sa propension à accepter (WTA) un certain degré d'inconfort en échange d'économies [85]. Une autre option consiste à demander les préférences en termes relatifs à l'utilisation finale de l'énergie, comme la température de chauffage ou le degré d'éclairage, sans demander explicitement la WTA ou la WTP [86].

Le problème des interrogations directes est que le système finit par dépendre de l'intervention de l'utilisateur (humain dans la boucle) [87]. Afin de réduire cette intervention et de ne pas imposer ou supposer des conditions à l'utilisateur, l'agent devrait apprendre les préférences

et suggérer des actions appropriées au lieu de les demander à chaque fois. De ce point de vue, l'apprentissage des préférences pourrait être considéré comme un apprentissage supervisé, car il exige que l'utilisateur désigne des interprétations dans un ensemble de données d'apprentissage. Même si on peut utiliser des stratégies d'apprentissage actif ou bayésien pour créer l'ensemble de données d'apprentissage en ligne [88].

Concernant l'apprentissage des préférences, il existe deux approches dans la littérature : les méthodes de classement ou les systèmes de recommandation [89]. Dans le premier cas, l'agent essaiera d'établir un classement des options disponibles sur les données de l'utilisateur. Ces classements peuvent être absolus ou par comparaison entre pairs [90]. Par contre, les systèmes de recommandation sont basés sur des filtres d'information : filtres collaboratifs ou filtres basés sur le contenu. Un filtre collaboratif tente de trouver des utilisateurs ayant des comportements similaires pour construire l'ensemble de données d'apprentissage, tandis que un filtre basé sur le contenu utilise les informations des expériences précédentes du même utilisateur pour recommander des décisions appropriées [32].

Étant donné que l'agent automatisé doit connaître l'élasticité de la demande par rapport au prix (soit par WTA ou WTP) et non une valeur discrète, il n'est pas possible de faire un classement complet avec toutes les valeurs que les utilisateurs peuvent choisir. D'autre part, comme un agent résidentiel n'a pas accès aux informations des autres utilisateurs dans un mécanisme TE, il n'est pas non plus possible d'utiliser des techniques de filtrage collaboratif. Par conséquent, l'alternative pour développer le système de recommandation des agents est d'utiliser un filtre basé sur le contenu. Les techniques les plus couramment utilisées dans ces filtres de contenu sont les classificateurs bayésiens, le partitionnement k-means, les arbres de décision et les réseaux neuronaux [91].

Pour développer le filtre basé sur le contenu, il est important de considérer que l'utilité perçue par l'utilisateur est monotone par rapport au coût de l'électricité, mais concave par rapport à la consommation [39]. De plus, les utilisateurs sont rationnels et, par conséquent, leurs préférences sont stationnaires [92]. Cela implique que lorsque les préférences d'un utilisateur sont interrogées dans les mêmes conditions, il a tendance à choisir les mêmes options. Il y

a des facteurs de bruit tels que l'impatience ou l'inattention, mais en appliquant la loi des grands nombres, les préférences tendent à avoir une distribution gaussienne [40]. Ce même principe est utilisé pour l'élicitation des préférences dans les méthodes de classement telles que la méthode de Mallows [93].

Un défi fréquemment rencontré par les filtres basés sur le contenu est le démarrage à froid, car ils ne disposent pas de suffisamment de données au démarrage pour fournir une recommandation précise [32]. Certaines des solutions à ce problème ont été données dans une perspective d'optimisation bayésienne et d'apprentissage par renforcement [87], [94]. Un deuxième défi pour ces systèmes est d'avoir un bon degré de sérendipité, ou de trouver de bonnes recommandations qui n'ont pas été explorées par l'utilisateur. En effet, les agents ne sont entraînés que sur la base des expériences précédentes de l'utilisateur, sans vraiment savoir si ce dernier a exploré toutes les options qui pourraient lui être bénéfiques [95]. Un dernier défi pour ces systèmes est d'avoir une précision et une exactitude adéquates. Dans ce cas, la précision est plus importante pour les agents résidentiels car les écarts impliquent des dépassements de coûts et des pénalités dans les mécanismes de l'ET.

Dans le cas spécifique de ce projet avec les systèmes de chauffage, les préférences que l'agent automatisé doit reconnaître sont liées à la sensation de confort thermique de l'utilisateur. Spécifiquement pour ce type de préférences, on trouve dans la littérature des méthodes basées sur les chaînes de Markov [96] et des filtres de contenu avec des variables de calendrier [97]. Ces approches sont compatibles avec notre proposition de modéliser les préférences des utilisateurs par un processus gaussien.

Chapitre 3 - Présentation des résultats par articles

Les résultats de la méthodologie proposée pour atteindre les objectifs de ce projet de recherche ont été séparés en trois publications. En premier lieu, la technique d'apprentissage adaptatif développée est présentée, puis l'intégration de cette technique dans l'architecture logicielle de l'agent, et finalement la technique d'apprentissage des préférences pour inclure les informations de l'utilisateur.

3.1 Modélisation adaptative des charges résidentiels

3.1.1 Contexte

Dans cette première partie, on considère le problème de la reconnaissance de l'environnement local de l'agent résidentiel. Cet environnement est composé des dispositifs situés derrière le compteur, à partir desquels on obtient un flux de données contenant les mesures de consommation. De ce flux de données, l'agent automatisé doit créer des modèles qui lui permettent de prévoir et de planifier la consommation. Dans ce cas, la consommation est considérée comme une variable continue pour les groupes d'appareils considérés. Par conséquent, les modèles sont le résultat de problèmes de régression qui sont résolus à l'aide de techniques d'apprentissage automatique supervisé.

Étant donné que les appareils ne sont pas tous contrôlables, l'agent doit savoir à l'avance sur quels appareils il peut prendre des décisions. Cela est dû au fait que les approches de modélisation sont différentes en fonction du type de charge. Pour les appareils qui ne sont pas contrôlables, il faut seulement prévoir la consommation pour la période de marché demandée. Par contre, pour les appareils contrôlables, les modèles doivent permettre de comprendre la

dynamique et d'évaluer les actions de contrôle. C'est-à-dire que les modèles pour les charges contrôlables doivent avoir un degré d'interprétabilité plus élevé.

Une fois que l'agent dispose des modèles des différents appareils ou groupes d'appareils, il doit se demander quand les réentraîner pour les adapter à de nouvelles conditions. La technique d'adaptation développée pour les modèles de l'agent résidentiel est expliquée ci-dessous. Contrairement aux méthodes existantes dans la littérature, la méthode développée ici regroupe les fenêtres de données de plusieurs modèles pour éviter la redondance des informations. De cette façon, l'agent résidentiel peut s'adapter aux changements dans le fonctionnement des charges contrôlables et non contrôlables et des dispositifs de génération.

3.1.2 Méthodologie

La méthode d'adaptation est basée sur la réduction de l'ensemble des données d'apprentissage uniquement lorsque les performances des modèles sont inférieures à une valeur de référence. Cette valeur peut être choisie en fonction de la taille de la variable à prédire ou en utilisant une métrique relative qui indexe l'erreur d'estimation avec une mesure descriptive des données. La performance est mesurée par validation croisée en utilisant comme ensemble de test l'ensemble de données le plus proche des variables explicatives de la période à prédire. Donc, si le résultat de la validation croisée est satisfaisant, le modèle est réentraîné avec toutes les données disponibles ; sinon, les données les moins pertinentes sont supprimées. Pour évaluer la pertinence des données, on utilise non seulement la proximité dans le temps, mais aussi la distance dans l'espace d'échantillonnage [98]. La distance euclidienne est utilisée comme mesure de la proximité entre les échantillons. L'algorithme est résumé dans la Figure 3-1.

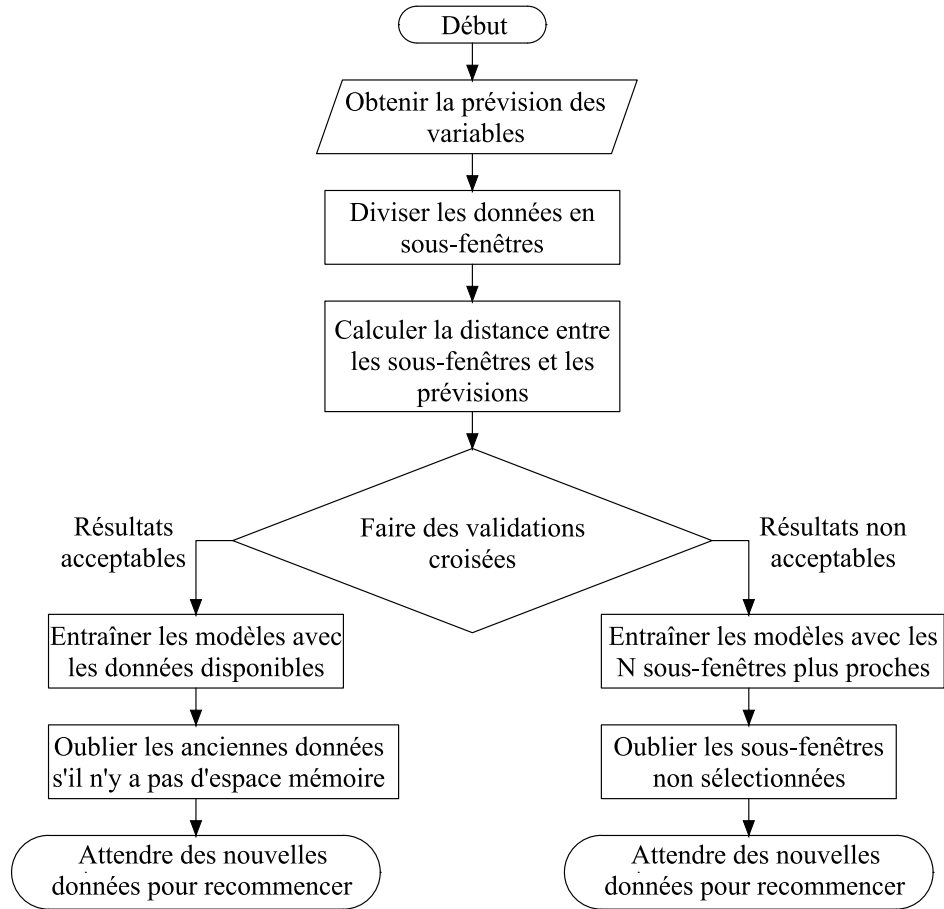


FIGURE 3-1 Algorithme d'adaptation

Pour mettre en œuvre cet algorithme, il est nécessaire de définir la mesure indicative pour accepter ou rejeter le résultat du test de validation croisée. Dans la détection de la dérive conceptuelle, il est habituel d'utiliser la RMSE (erreur quadratique moyenne), car elle donne plus de poids aux grandes déviations. Cependant, il est également possible d'utiliser la valeur normalisée NRMSE pour exprimer la limite de tolérance en valeurs relatives plutôt qu'en unités de la variable à prédire. D'autre part, il est nécessaire de définir la taille minimale de l'ensemble de données d'entraînement, car elle doit être beaucoup plus grande que le degré de liberté du modèle pour garantir la convergence de l'entraînement. Pour la mise en œuvre de cette méthode dans les agents résidentiels, la taille minimale de la fenêtre de données est considérée comme une valeur fixe. Cependant, d'autres applications de cette méthode peuvent intégrer des techniques de sélection de modèles pour définir ce paramètre.

L'un des avantages de cette technique par rapport aux autres techniques de la littérature est qu'elle permet de sélectionner les données d'entraînement à chaque fois, ce qui permet à l'agent d'entraîner plusieurs modèles sans conserver de données redondantes. La conception de cette méthode a été focalisée sur l'aspect pratique de son intégration dans l'agent résidentiel automatisé et non sur l'adaptation d'un modèle particulier à une dérive conceptuelle spécifique.

3.1.3 Résultats

La méthode proposée pour adapter les modèles de l'agent a été testée dans deux conditions où l'on suppose l'existence d'une dérive conceptuelle. Pour trouver ces conditions, on a entraîné les modèles pour les différents groupes d'appareils avec différentes fenêtres de données, et on a vérifié si l'ajout de données induisait des erreurs de prévision plus élevées. Les résultats obtenus en termes d'erreur d'estimation sont similaires à ceux obtenus par d'autres méthodes bien connues dans la littérature telles que ADWIN [82] ou DDM [79]. Il n'est donc pas possible d'affirmer que la méthode proposée est la meilleure option dans tous les cas de dérive conceptuelle qui peuvent se présenter à l'agent résidentiel. En fait, une méthode simple comme le maintien d'une fenêtre de données dans un buffer peut être une stratégie d'adaptation acceptable pour certaines dérives qui peuvent survenir. On a également comparé cette méthode avec des méthodes qui ne considèrent le problème d'adaptation que pour les dérives soudaines, comme la méthode du nombre d'or qui effectue une recherche exhaustive [80]. En supposant que tous les changements sont soudains, cette méthode tend vers l'optimum global avec une complexité de calcul de $\mathcal{O}(\log_2(\frac{a}{N}))$, où a est l'espace de recherche et N est la taille minimale de la fenêtre de données.

L'avantage de la méthode proposée réside dans la gestion des données, car elle ne supprime pas tous les échantillons qui n'ont pas été utilisés pour l'entraînement des modèles. De cette façon, l'agent peut conserver une seule fenêtre de données pour entraîner les différents modèles sans perdre les données pertinentes. Un autre avantage de cette méthode par rapport à d'autres dans la littérature est qu'elle est exécutée comme un algorithme non-récuratif (one-shot), c'est-à-dire qu'elle utilise moins de ressources computationnelles que les algorithmes de recherche exhaustive comme la méthode du nombre d'or.

Article

Adaptive Machine Learning for Automated Modeling of Residential Prosumer Agents

David Toquica ^{1,*}, Kodjo Agbossou ¹, Roland Malhamé ², Nilson Henao ¹,
Souso Kelouwani ³ and Alben Cardenas ¹

¹ Department of Electrical and Computer Engineering, Université du Québec à Trois-Rivières, 3351, Boul. des Forges, Trois-Rivières, QC G8Z 4M3, Canada; Kodjo.Agbossou@uqtr.ca (K.A.); Nilson.Henao@uqtr.ca (N.H.); Alben.Cardenasgonzalez@uqtr.ca (A.C.)

² Department of Electrical Engineering, Polytechnique Montréal, C.P. 6079, Succ. Centre-Ville, Montréal, QC H3C 3A7, Canada; roland.malhame@polymtl.ca

³ Department of Mechanical Engineering, Université du Québec à Trois-Rivières, 3351, Boul. des Forges, Trois-Rivières, QC G8Z 4M3, Canada; Souso.Kelouwani@uqtr.ca

* Correspondence: david.camilo.toquica.cardenas@uqtr.ca

Received: 26 February 2020; Accepted: 15 April 2020; Published: 4 May 2020



Abstract: An efficient participation of prosumers in power system management depends on the quality of information they can obtain. Prosumers actions can be performed by automated agents that are operating in time-changing environments. Therefore, it is essential for them to deal with data stream problems in order to make reliable decisions based on the most accurate information. This paper provides an in-depth investigation of data and concept drift issues in accordance with residential prosumer agents. Additionally, the adaptation techniques, forgetting mechanisms, and learning strategies employed to handle these issues are explored. Accordingly, an approach is proposed to adapt the prosumer agent models to overcome the gradual and sudden concept drift concurrently. The suggested method is based on triggered adaptation techniques and performance-based forgetting mechanism. The results obtained in this study demonstrate that the proposed approach is capable of constructing efficient prosumer agents models with regard to the concept drift problem.

Keywords: adaptation; concept drift; data streaming; forecast; modeling; prosumer; regressor; supervised machine learning

1. Introduction

In recent years, the growth of distributed generation and residential prosumers [1] has motivated energy companies to develop new ways of commercializing energy. Their main objective is to reduce the cost and improve the power system management. Accordingly, decentralized optimization processes that enable more participation of final customers expected to help this ambition [2]. In order to facilitate higher cooperation of end customers (including both consumers and prosumers), intelligent decision-making systems are required [3]. In the residential sector, these systems' aim of minimizing the energy cost must also account for customers comfort. For instance, controllable loads, such as heating, ventilation, and air conditioning (HVAC), allow the cost reduction based on dynamic tariffs by taking into account preferable temperature set-points [4].

The intelligent systems are considered as agents since they can perceive the environment and take decisions according to an objective [5]. The quality of the decisions of an agent depends on the information that they have [6]. Consequently, it is crucial to have reliable information about the environment. However, information can become unreliable due to shifting on weather conditions, integration of new devices, change of user preferences, and degradation of appliances.

Generally, for a residential prosumer agent, it is possible to distinguish two environments that are labeled as local and external. The former refers to the behind-the-meter resources [7], while the latter describes situations where the prosumer agent can interact with other agents and information services. In most cases, the external environment only collects data of either weather variables or their forecast, but in a decentralized management scheme, it is possible to consider the external environment as a multi-agent system (MAS) [8]. The agent is able to perceive the local environment by observing the power consumption data of different appliances. In fact, it constructs a time-series database by accumulating new information from a data stream [9]. However, this process is problematic since agents have limitations on memory and processing time [10]. In addition, the data stream can *drift* over time, thus causing previously trained data models of appliances to lose accuracy [11]. Therefore, model adaptation on the basis of recent data is essential [12].

In this regard, several approaches have been developed to address the problems related to non-stationary data streams. In automated machine learning, active and adaptive learning algorithms have been utilized. The active learning techniques query for the information that they need each time for training a model [13]. Besides, the adaptive learning methods only update the models when they detect a drift [14]. Particularly, studies have considered retraining after fixed-size data windows and rule-based models as adaptation methods, applied to residential appliances models [15,16]. Therefore, they have underestimated the importance of drift issues on data management. Moreover, other researches have been conducted on training the models incrementally without analyzing the changes on data streams. For example, Farzan et al. increased the information of a transition matrix of a discrete-time Markov model to simulate both electricity and heating demands of individual households [17]. Yoo et al. trained a Kalman filter, recursively, in order to forecast a household load, considering temperature and occupancy variables [18]. However, adding the information of new samples directly to the models limits the set of models that can be used to represent the behavior of appliances. The applicability of these incremental learning techniques should be examined in detail according to the conditions of prosumer agents [19].

Considering the above restrictions, the main objective of our study is to investigate adaptation methods that can be useful for prosumer agents to have more reliable information. Through extensive analysis, this paper contributes to:

- The definition of the main criteria when choosing an adaptation algorithm in the context of prosumer agents. Here, the issues that the adaptation techniques address are examined to determine the best solution for models management, future concept assumptions, mixed drifts, and selection of training strategies.
- The identification of suitable algorithms for adapting the prosumer agents models to overcome environment changes. The algorithms are estimated with different adaptation strategies and forgetting mechanisms, such as Adaptive Windowing (ADWIN) [20], FISH [21], and Drift Detection Method (DDM) [22], in order to identify their required features in the prosumer agent context.
- Proposition of a new adaptation algorithm based on triggered adaptation techniques and performance-based forgetting mechanisms. The proposed method is non-iterative; thus, it is less computationally complex than other methods in the literature. The suggested approach is capable of training several appliances' models in relatively fast data streams for the prosumer agent context, using a single data window.

This paper is organized as follows: Section 2 presents the problem of prosumer agents obtaining accurate information in a changing environment. The concept drift definition with the implications of the prosumer agent is also discussed in this section. Section 3 explains the main criteria dictating the choice of a particular adaptation algorithm for the agents. Next, Section 4 presents the proposed adaptation algorithm for prosumer agent models. Section 5 presents the experimental setup and the

comparison of results obtained by using different algorithms followed by the concluding remarks in Section 6.

2. Problem Statement

The local environment of the prosumer agent is composed of several appliances and local power generation systems. In order to reduce the number of variables, residential appliances are aggregated into two main groups, namely fixed loads and controllable loads. Controllable loads correspond to the appliances that can give some flexibility to the user, allowing him to modify energy consumption according to external signals he receives. Particularly, controllable loads that are examined in this study consist of heating systems because they are the most common flexibility source in the residential sector. In order to forecast both household power demand and know the thermal dynamics, the local environment is modeled with the data window that the agent creates from the data stream, as shown in Figure 1. These models have been generally constructed based on supervised machine learning methods. [23]. For fixed loads and local power generation, the models objective is only to forecast total power since the agent cannot take any action over these two elements. On the other hand, the model of controllable loads is developed to estimate the internal temperature based on the household power consumption profile, decided by the residential agent. As mentioned, this decision has to take into consideration the occupants' comfort levels.

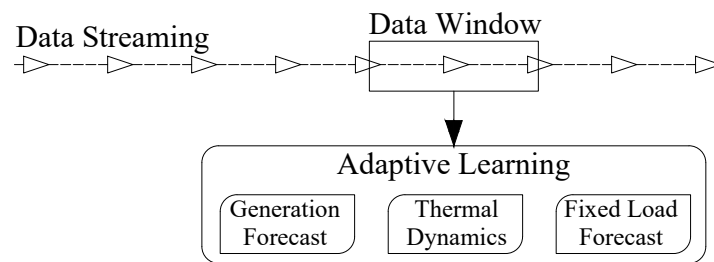


Figure 1. Adaptive learning application.

In all cases, residential prosumer agents need to adapt their models to new environmental conditions. An essential prerequisite to perform effective adaptations is to analyze the causes of data changes and the impacts of these changes on agents knowledge. In this context, it is important to notice that, for data-driven models, the underlying joint probability between features and targets is known as a concept, and it is assumed to be invariant over some interval of time. However, this underlying distribution could evolve over time sufficiently to cause a so-called concept drift [11]. The formal definition of concept drift is presented in Equation (1), where the X stands for the input features (or observations), y is the target variable (or label), and, hence, $\mathcal{P}(X, y)$ is the joint distribution (or concept [21]) evaluated at time t and $t + m$.

$$\mathcal{P}_t(X, y) \neq \mathcal{P}_{t+m}(X, y). \quad (1)$$

Due to causality between the features and the target, it is suitable to consider the following form of the joint probability distribution [24].

$$\mathcal{P}_t(X, y) = \mathcal{P}_t(y|X)\mathcal{P}_t(X), \quad (2)$$

where $\mathcal{P}_t(y|X)$ is the posterior probability of the target given the features, and $\mathcal{P}_t(X)$ is the prior distribution of the features. For example, weather variables as features are subject to changes with seasonal conditions that are explained by the term $\mathcal{P}_t(X)$. Besides, $\mathcal{P}_t(y|X)$ being the conditional distribution on features could also incorporate time-dependent effects, such as degradation of appliances.

As mentioned, the solution to deal with inaccuracy due to concept drift is to adapt the models parameters. However, before choosing an adaptation technique, it is meaningful to look at the characteristics of the concept drifts that can appear in the data streams of residential prosumers. Therefore, a prosumer-oriented study on the quantitative and qualitative measures of drift is provided below based on a general framework, discussed in Reference [25].

2.1. Drift Magnitude

Drift Magnitude $D(t, t + m)$ measures the distance between two probability distributions at two different instants t and $t + m$ for $m > 0$. Generally, drift magnitude is measured with the Hellinger distance H^2 since it has a non-negative value, and the distance between A and B concepts is the same as B and A [26]. However, it is possible to use other distance metrics, such as the total variation distance.

$$\begin{aligned} D(t, t + m) &= H^2(\mathcal{P}_t(X, y), \mathcal{P}_{t+m}(X, y)) \\ &= 1 - \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \mathcal{P}_t(X, y) \mathcal{P}_{t+m}(X, y) dXdy. \end{aligned} \quad (3)$$

The drift magnitude can be used for drift classification. For example, a minor drift does not necessitate training the model. However, a major drift can imply the need for either retraining or changing the models (in case of ensemble learning mechanisms). In the data streams that a prosumer receives, it is possible to identify several minor drifts during the day at short timesteps that do not necessarily match with a gradual drift, especially for the fixed loads. Besides, when the time step goes bigger, the drift magnitude does not always increase, which means that there could be recurring concepts. For example, for the power generation model, if the prosumer has photovoltaic panels, the concept at dawn may be closer to the concept at night than at noon.

2.2. Drift Duration

The drift duration noted as m can define either a sudden (abrupt) or progressive (gradual or extended) transition between two concepts, depending on its value. As an example, in the local environment of a prosumer agent, a sudden concept drift (small drift duration) occurs when appliances are added, removed, or changed. Other special cases of concept transition like blip drifts and probabilistic drifts are hard to recognize by the prosumer since they can be mistaken for outliers in the data stream.

2.3. Drift Subject

Distinguishing a drift subject is difficult for prosumer agents since similar changes on features distribution can cause different drift subjects. However, it is important to mention that not all the drifts will require retraining the models. Normally, two categories of drift types are considered according to its causes [25]:

- Real concept drift: This type occurs when the posterior probability, $\mathcal{P}(y|X)$ changes over time and requires a retraining of the model. The change can occur in either a portion of the domain of X (sub-concept drift) or all of it (Full-concept drift).

$$\mathcal{P}_t(y|X) \neq \mathcal{P}_{t+m}(y|X). \quad (4)$$

- Virtual concept drift: It happens when, instead, it is the distribution of the features $\mathcal{P}(X)$, which changes over time while the posterior probability, $\mathcal{P}(y|X)$ remains the same. In that case, it is not always necessary to update the model.

$$\mathcal{P}_t(y|X) = \mathcal{P}_{t+m}(y|X) \quad \mathcal{P}_t(X) \neq \mathcal{P}_{t+m}(X). \quad (5)$$

2.4. Drift Predictability

The drift in a data stream can be related to independent events, such as seasons and days of the week. Consequently, it is possible to predict some aspects of the drift if the occurrence of these events is known. Furthermore, a concept drift can be predicted if a known recurrence pattern exists. Nevertheless, in the context of a prosumer agent, there can be different concept drifts coming from different environmental changes that cannot be well differentiated, so it will be barely impossible to anticipate the occurrence of certain types of drift. Moreover, define a magnitude threshold to identify the data that corresponds to previously seen concepts depends on the timestep that the prosumer agent uses.

3. Adaptive Algorithms

In this section, the adaptation algorithms are classified in order to identify suitable methods for residential prosumer agents problems. This classification is preceded by an examination of sub-issues that an adaptation algorithm faces [21]:

- **The appearance of gradual drifts makes it impractical to assume that the concept of future data is always closer to the latest data.** Therefore, instead of assuming the concept of future data, it will be useful to implement an algorithm that recognizes the distribution of the features of arriving data. Besides, in some applications of prosumers, the robustness of the methods is essential to differentiate outliers from concept drifts. However, in this study, the agent trusts the external information he receives from measurement systems and weather information services.
- **In the data stream, there could be different kinds of drifts mixed and outliers data samples.** Another important concern with the concept drift in the specific context of the prosumer agent is the concurrence of the drift types. Thus the agent could be facing sudden drifts, gradual drifts, and incremental drifts within one timeframe [27]. For that reason, adaptation algorithms that were made to solve problems related to specific cases of drift are not the best option for the agent. Here, we test some of those algorithms to validate this affirmation.
- **It is impractical for a prosumer agent to have different models trained with different data sets and ensemble the forecasts.** Therefore, considering the available mechanisms to update the agents knowledge, when using a single model, the only strategy is to adapt the parameters. Nevertheless, in addition to parameters' adaptation, it is also possible to combine the models by weighting them as in ensemble learning [28]. The choice of the method should be made by taking into account the residential agent's restrictions related to the processing time and hardware limitation. Normally, the models of three main groups are used to provide information for other processing systems, such as a Home Energy Management Systems (HEMS), with a practical objective, like either minimizing energy cost or maximizing comfort. These systems usually provide results in five to fifteen minutes intervals, thus limiting convenient exploitation of ensemble learning.
- **Not all adaptation techniques may work for all the models.** The adaptation of parameters depends on the model type since some models can be trained incrementally, for example, by using adaptive linear neuron rule (ADALINE) or recursive least squares (RLS) [29], while others have to start from zero every time. The drawback of incremental learning is that outliers are directly included in the model's knowledge. Notwithstanding, it can reduce memory usage and processing time. Besides, the choice of the learning strategy depends on the nature of data and the rate of data collection. Thus, the residential agent could be receiving and processing the data under both forms of single or batch measurements. For instance, the labels of the models could be given every time while the features could be queried in batches each several hours.

According to the above considerations, the taxonomy of adaptive learning algorithms is presented in Figure 2. This classification is different from other ones, previously provided in Reference [14,30], due to the specificity of the prosumer agent. The new arrangement is to highlight the main concerns

of agents over the choice of an algorithm, involving an adaptation strategy, model management, data acquisition, a forgetting mechanism, and a learning strategy. In Figure 2, blind adaptation refers to a case in which the algorithm updates the model parameters at a pre-defined frequency without specific verification of the occurrence of concept drift in the data stream [30]. Alternatively, some algorithms utilize a method to detect concept drift before triggering the adaptation. This mechanism is sometimes referred to as active adaptation.

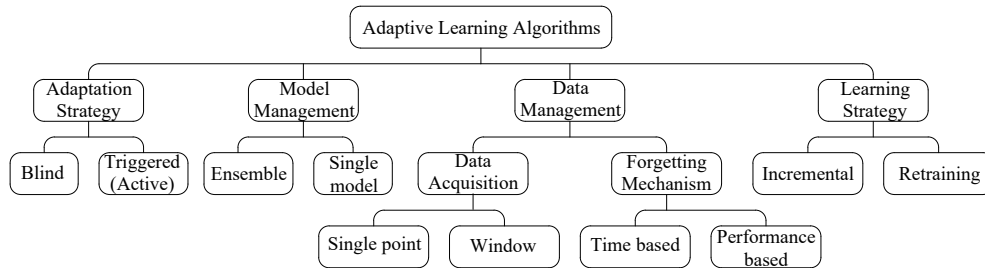


Figure 2. Taxonomy of adaptive learning.

The forgetting mechanism can be time-based in case the oldest samples are deleted, while the size of the data window either is kept fixed, changes according to a rule, or assigns fading factors to make old samples irrelevant. In addition, this mechanism can be performance-based in accordance with the adequacy of the samples for training the model or their similarity with future samples considering their statistical properties.

Now, with all the considerations for the prosumer agents' problem, the following algorithms were selected to adapt the models of the local appliances. In addition, they present some remarkable characteristics that can be useful to formulate new methods.

3.1. Drift Detection Method

This method proposed in Reference [22], starts with the premise that more items of the same concept in the data window will reduce prediction error. Consequently, it is possible to take an error increase as a proof of concept drifts [31]. This is under the assumption that the base learner controls over-fitting.

For classifiers, the error can be modeled as a random variable from Bernoulli trials; then, the Binomial distribution gives the general form of the probability for the variable. In that context, if \mathcal{P}_t is the error rate of the learner at time t , then the standard deviation s_t will depend on the window size N_t as follows [22]:

$$s_t = \sqrt{\frac{\mathcal{P}_t(1 - \mathcal{P}_t)}{N_t}}. \quad (6)$$

The algorithm stores the minimum value encountered of \mathcal{P}_{\min} and the corresponding s_{\min} . Subsequently, two validations are made according to the confidence level:

- Warning level: confidence level is 95%, so it is reached when $\mathcal{P}_t + s_t \geq \mathcal{P}_{\min} + 2s_{\min}$.
- Drift detection: confidence level is 99%, so it is reached when $\mathcal{P}_t + s_t \geq \mathcal{P}_{\min} + 3s_{\min}$.

When the drift is detected, the onset of a new concept is declared starting at the time when the warning first appeared. As can be noted, this method was designed for sudden drifts. Hence, for residential agents, the algorithm will detect a drift several consecutive times when there are gradual drifts. For that reason, in order to apply this method, it was deemed necessary to define a minimum distance in time between a warning level and drift detection. Furthermore, the regressor models of the residential agent need to be considered as multi-label classifiers to implement this method. The method is summarized in Algorithm 1.

Algorithm 1: Drift Detection method.

```

input :Data stream of labels ( $y$ ) and features( $X$ )
output:Trained model
Set initial conditions of  $\mathcal{P}_{min}$  and  $s_{min}$ ;
begin
  if New sample is added at time  $t$  then
    Calculate  $\mathcal{P}_t$  and  $s_t$  with Equation (6);
    Compare  $\mathcal{P}_t + s_t$  with the warning level and the drift detection conditions;
    if A drift is detected then
      | Resize the window data since the warning level appeared or to a minimum size;
    end
    Train the model with the resulting data window;
  end
end

```

3.2. Gold Ratio Method

This method proposed in Reference [32] was also designed for adapting to sudden drifts. It assumes that the concept has changed if, at any time, the error of the model surpasses a defined level. The significance test must be sensitive enough to discover concept drift as soon as possible and robust to avoid mischaracterizing noise as concept changes. When the accuracy decreases, the oldest examples should be forgotten, and the size of the data window can be optimized by using a search algorithm in one dimension. The search algorithm used here is the Golden Ratio method. Considering a unimodal function, in the interval between a minimum window size (N_{min}) and the current size ($N_{current}$), the accuracy function has only one max at N_{opt} . Then, the algorithm minimizes the number of function evaluations by dividing the range using the golden ratio ($\tau = 0.618$); in so doing, the optimal window size is clustered fast [32].

The stopping criteria for the method is the minimum size of the search interval (100 samples proves to be adequate for the prosumer agent case). The significance test was done by using the root mean squared error (RMSE), and the acceptance level was adjusted according to the base learner. For the fixed load model, it is suitable to accept a higher RMSE since it is the most unpredictable signal. If no concept drift is detected, then the windows continue growing by adding more samples because a bigger training set will improve learning results if the concept is stable. The complete procedure is presented in Algorithm 2.

3.3. Klinkenberg and Joachims' Algorithm

The idea of this method proposed in Reference [33] is to select the window size to minimize the estimated generalization error. In the original case, the base learner is a support vector machine (SVM) because of the residual errors of the training ($\alpha\epsilon - estimator$) can give an upper bound of the leave-one-out errors without training the learner several times. However, the generalization error can still be minimized by using different window sizes and using k-fold cross-validation, assuming that most recent samples have a higher correlation with future features. In that way, this method can also be seen as a search method as presented in Algorithm 3.

Algorithm 2: Gold ratio method.

```

input :Data stream of labels ( $y$ ) and features ( $X$ )
output:Trained model
begin
  When a sample is added, calculate the  $R^2$  coefficient of the regressors;
  if  $R^2$  coefficient is lower than expected then
     $N_a = N_{min} + 0.618(N_{current} - N_{min});$ 
     $N_b = N_{min} + (1 - 0.618)(N_{current} - N_{min});$ 
    Train the model with the  $N_a$  and  $N_b$  most recent samples;
    if the accuracy of the model with  $N_a$  data is bigger than the one with  $N_b$  then
      The new search space is between  $[N_b, N_{current}]$ ;
    else
      The new search space is between  $[N_{min}, N_a]$ ;
    end
    Train the model with the resulting data window;
  end
end

```

Algorithm 3: Klinkenberg and Joachims' Algorithm.

```

input :Data stream of labels ( $y$ ) and features ( $X$ )
output:Trained model
begin
  Divide the current data window in  $k$  sub-windows;
  Take the last sub-window for testing (cross-validation);
  for  $k - 1$  times do
    Train the model adding an older sub-window each time;
    Perform the cross-validation test;
  end
  Train the model with the number of sub-windows that performed better on the test;
end

```

3.4. Fish Method

For sudden concept drift, it should be possible to find the moment of the drift t_D by evaluating extensively for all the samples the likelihood between the distributions before and after that sample, using the Hotelling test, for example [21].

$$\mathcal{T}_D = \max \mathcal{P}(\text{drift} | t_D). \quad (7)$$

However, when the drift is gradual, it is not only the distance in time which is relevant to select the samples needed to train the models. For that reason, the Fish method proposes to estimate also the distance in the feature space of the samples respect to the new ones [21]. Thus, for each sample in the window, it will be necessary to calculate the combined distance [34].

$$d_t = d_t^{(T)} + \beta d_t^{(s)}, \quad (8)$$

where $d_t^{(T)}$ is the distance in time, and $d_t^{(s)}$ is the distance in feature space of a sample in time t with respect to the future features. Note that the existence of gradual drifts makes it necessary to give some relevance to the distance on feature space $\beta > 0$. Subsequently, by organizing the samples according to their distance, it is easy to pick up the N closest samples to train the models. This method is best

suitable for the residential agents' problems since it can account for both sudden and gradual drifts. The problem is to define a good distance function that gives reliable insights without increasing too much the processing time. The prosumer models have few features, so the feature space distance is calculated as the Euclidean distance because it is easy to compute and works well in low-dimensional spaces [35]. The method is summarized in Algorithm 4.

Algorithm 4: Fish method.

input :Data stream of labels (y) and features (X)
output:Trained model
begin
 Calculate the distance d_t for each sample in the data window;
 Organize the samples according to their distance;
 Train the model with the N closest samples;
end

3.5. ADWIN

This algorithm proposed in Reference [20] is based on hypothesis testing. The idea is that, when two sub-windows have different averages μ , the expected values are different. Like in a Hoeffding test, the null hypothesis is that the expected values are the same. The test can be written as follows for two different sub-windows of sizes N_0 and N_1 : If $|\hat{\mu}_0 - \hat{\mu}_1| > \epsilon$, then the null hypothesis is false. Here, $\hat{\mu}$ corresponds to the average value of the sub-window, and ϵ depends on the confidence value δ according to:

$$\epsilon = \sqrt{\frac{N_0 + N_1}{2N_0N_1} \ln \frac{4(N_0 + N_1)}{\delta}}. \quad (9)$$

For the problem of residential agents, analyzed in this paper, the confidence value is taken as 0.5%. The ADWIN method is summarized in Algorithm 5.

Algorithm 5: ADWIN algorithm.

input :Data stream of labels (y) and features (X)
output:Trained model
begin
 Divide the available data in sub-windows;
 Calculate ϵ with Equation (9);
 while the null hypothesis is false **do**
 Drop the oldest sample;
 Perform the hypothesis test for every pair of sub-windows;
 end
 Train the model with the resulting data window;
end

4. Proposed Algorithm

Given the collection of algorithms we presented above, we propose herein a hybrid approach that we think is best suited for the prosumer agents problem. Similar to the Drift Detection method and Gold Ratio method, the proposal is to use triggered adaptation. The algorithm will reduce the training set of the models only when the expected performance drops below a defined value, not each time that a new sample arrives.

To check the performance of the models, the procedure will be cross-validation using batches of the same size as the forecasting horizon (24 h, in this case), like in the Klinkenberg and Joachim's

method [33]. The measurement of fit, in this case, is the RMSE because it gives more weight to bigger deviations; thus, it is better to identify the appearance of concept drifts [36]. It is relevant to mention that the threshold to accept the results of the cross-validation depends on the nature of the target variable of each model [37]. The test data set will be the closest batch to future features. Now, to identify that batch, the distance will be measured as in the FISH method [34] as a combined distance in time and space of the samples. If the result of the cross-validation test is not good enough, then the model will be retrained only with the closest N batches. The parameter N needs to be tuned according to the model to avoid convergence problems in training but knowing that, when a concept drift appears, it is safer to train with a small amount of data to ensure that all samples correspond to the new concept. Figure 3 summarizes the proposed algorithm with the procedure for when new data arrives.

Furthermore, forgetting data is a risky task since there are gradual drifts. The proposal here is to store a data window that contains the N selected samples, as well as the samples that were not selected but fall in between selected samples.

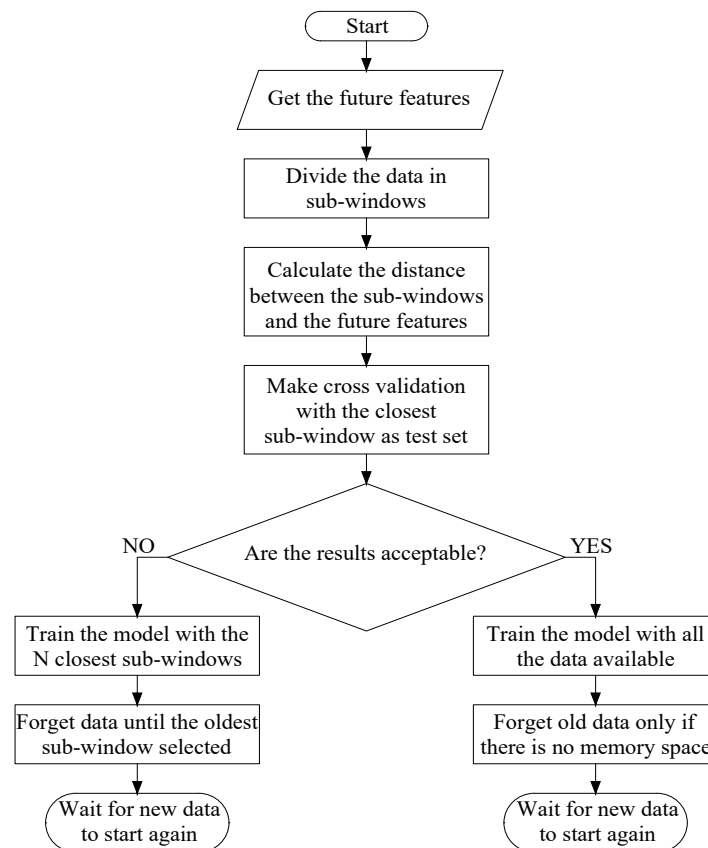


Figure 3. Flowchart of the proposed algorithm.

5. Numerical Results

In order to validate our proposal, we now report the results of a numerical experiment where we use a neural network as the power generation model, a decision tree for the fixed load, and a linear model for the thermal load. The details of the models implemented on Scikit-learn [38] are shown here below:

Power Generation: The base learner is a feed-forward neural network that forecasts the power output of a generation system P_{gen} , as shown in Figure 4. The hidden layers of the network have 100×5 neurons; the activation function is a hyperbolic tangent, the step size is fixed at 0.0001, the initial state of weights is 1, and the method used to train the model is stochastic gradient descent. The data

used in this case was synthetically created by simulating a photovoltaic array in PVlib [39] library with random cloud coverage (from 0 to 100% with transmittance offset of 0.75) and real temperature of Trois-Rivières, QC, in 2018.




Figure 4. Model of power generation.

Fixed Load: The model to forecast the fixed load consumption P_{fix} is a decision tree where the quality of a split is measured using the mean squared error, and nodes are expanded until all leaves are pure [40]. The variables considered in this model are a cosine signal with a period of 24 h, the number of the day (from 1 to 7), the temperature, and the previous consumption (since the agent obtains data every 5 min, 288 samples correspond to 24 h). This model is presented in Figure 5. The data used in this case is real measurements of the power demand of a house in Trois-rivières, QC, during 2018.




Figure 5. Model of fixed load.

Controllable Load (Thermal model): This model is based on the equivalent circuit 5R1C proposed in the standard ISO 13790:2008 [41]. The inputs in this case are the external temperature T_{ext} , the fixed load consumption P_{fix} , the solar irradiance P_{irr} , and the power demand of the heating system P_{heat} . The output will be the internal air temperature T_{air} . We assume that there is no special ventilation system, so there is only one external temperature as shown in Figure 6.




Figure 6. Model of thermal dynamics.

The following equation describes the model.

$$T_{air}^{(t)} = \alpha_1 T_{ext}^{(t)} + \alpha_2 T_{air}^{(t-1)} + \beta_1 P_{heat}^{(t)} + \beta_2 P_{fix}^{(t)} + \beta_3 P_{irr}^{(t)}, \quad (10)$$

where $T_{air}^{(t-1)}$ corresponds to the internal temperature at timestep $t - 1$. This linear model is trained by using Ordinary Least Squares (OLS) to find the parameters α_1 , α_2 , β_1 , β_2 , and β_3 , which are combinations of the original parameters of the standard circuit model. The data used, in this case, corresponds to real measurements in a house in Trois-rivières, QC, during 2018.

The results presented here correspond to simulations starting in two different days when there are suspicions of concept drift: A spring day (19 April 2018) and a summer day (23 August 2018). As mentioned, when the concept changes, old data gives inappropriate data to the models, therefore the error is reduced by training only with the most recent data. In the selected days, there are symptoms of concept drift because when training the models with sliding windows, some times the smaller data window leads to lower errors. Training with sliding windows can be seen as a way to perform adaptation because, every time the agent receives new data, it retrains the models with the most recent data, adding the new samples and forgetting the oldest. Here, the training with sliding windows is used to detect possible concept drifts in data with the evolution of the RMSE. The normalized RMSE (NRMS) is obtained by dividing the RMSE into the range of the label signal.

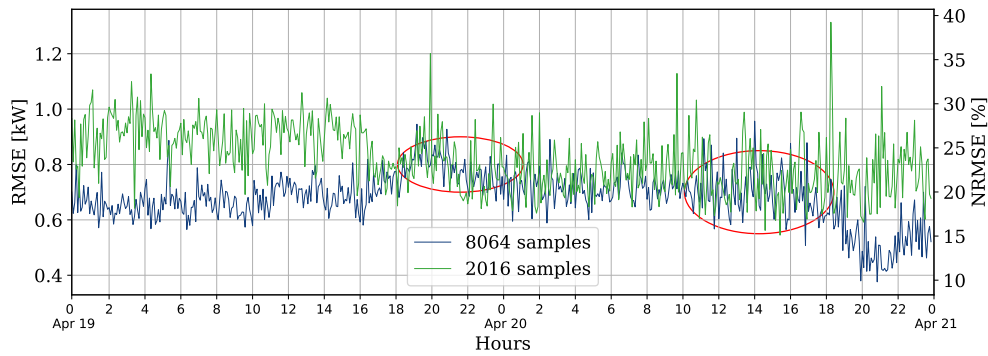
The maximum limit of training data for each model is 8064 samples (28 days sampled every 5 min), and the minimum to ensure convergence is 2016 (7 days). The limits were established according to the models, the linear thermal model can be fitted with less than 2016 samples, but the power generation model does not converge with less than that. This information about the base learners is relevant since it is used to tune parameters of the adaptation methods. Here, the models started with previous knowledge (1 month of data) before beginning the adaptation. In the case that the agent does not have enough information, the parameters of the models can start with prior values [42].

5.1. Spring Day


As can be seen in Figure 7 with the evolution of the RMSE, running over 48 h, some periods seem to present concept drifts. For the power generation model, close to the 19 h of April 19th, it is possible to see an increase of the error when using a window of 8064 samples, that ends close to the 18 h of the next day. Similarly, for the thermal model, the biggest data window lead to a higher error most of the time, until the 14 h of April 20th. For these reasons, these days were chosen to test the adaptation techniques. On the other hand, for the fixed load forecast, the errors with both sizes of sliding windows are close most of the time, and some outliers on the label data may create prominent peaks.

Before presenting the results, it is pertinent to mention some characteristics of the the weather data on these days: the external temperature fluctuates in a range from 1.4 °C and 9.3 °C, with a mean of 6.06 °C; the maximum irradiation of 945 kJ/m²/h is reached at 12 h of the first day. The heating system of the house has a capacity of 15 kW, and the internal temperature goes from 17.6 °C to 21.1 °C, with an average of 19 °C.


Afterwards, the models were adapted during the selected period with the techniques presented earlier. The average RMSE (and NRMS) for each case is presented in Table 1. The results obtained with the proposed method are systematically better than the most straightforward adaptation by sliding window, which means that implementing the method gives more reliable information to the prosumer than not doing so, even though the error reduction may be small. Other algorithms will occasionally perform better for adapting specific models. For example, the golden ratio method reduces the error when adapting the power generation model, but it is not suitable to adapt the thermal load model. Furthermore, the proposed method forgets less data, thus making it possible for the prosumer to use a single database for all three models.



(a) Root mean squared error (RMSE) for the power generation model using fixed window sizes



(b) RMSE for the fixed load model using fixed window sizes



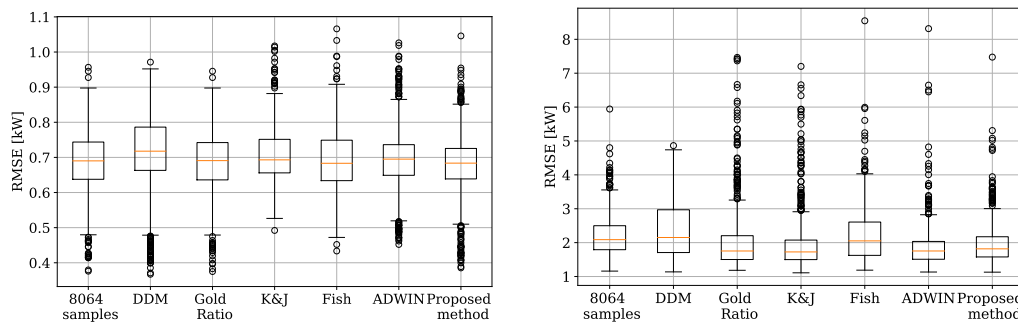
(c) RMSE for the thermal model using fixed window sizes

Figure 7. Identification of possible concept drifts in a spring day.

Another aspect that should be analyzed when choosing an algorithm is the dispersion of the error. Algorithms can be deluded by outliers and recurring concepts, leading to an increase in the error. Consequently, choosing a robust algorithm with low average error and low dispersion is important to give reliable information to the prosumer. In this regard, the performance of the proposed method is comparable with the others, as can be seen in Figure 8. One compelling case is the FISH method to adapt the thermal model because it is less sensible than the all the other algorithms.


Table 1. Average RMSE and Average NRMSE for a spring day.

	Power Generation [kW]	Fixed Load [kW]	Thermal Load [°C]
Full memory (8064 samples)	0.68479 (20.89%)	2.22717 (35.71%)	0.65367 (21.57%)
Drift Detection Method	0.70753 (21.65%)	2.36283 (37.90%)	0.74063 (24.37%)
Gold Ratio Method	0.68168 (20.77%)	2.08994 (33.47%)	0.7432 (24.45%)
Klinkenberg Method	0.70976 (21.64%)	1.99740 (32.02%)	0.653353 (22.01%)
FISH Method	0.69418 (21.15%)	2.22050 (35.63%)	0.64908 (21.59%)
Adwin Method	0.69573 (21.19%)	1.89000 (30.31%)	0.70723 (23.33%)
Proposed Method	0.67787 (20.67%)	1.97518 (31.68%)	0.62385 (20.52%)



(a) RMSE for the power generation model

(b) RMSE for the fixed load model




(c) RMSE for the thermal load model

Figure 8. RMSE dispersion in the spring day.


5.2. Summer Day

Similarly to the procedure to choose the spring day, we train the models using sliding windows to identify another day with signs of concept drift. On August 23rd, at 16 h, the error of the power generation model goes bigger when using 8064 samples than 2016, as shown in Figure 9. For the thermal load, the error with the bigger data window also surpasses the other at the same time. Again, the results for the fixed load model are close, making it challenging to identify concept drifts. On these selected days, the external temperature has a range from 12.6 °C to 29 °C, with a mean of 22.4 °C;


the maximum irradiation is $2900 \text{ kJ/m}^2/\text{h}$; and the internal temperature goes from $24 \text{ }^\circ\text{C}$ to $28.3 \text{ }^\circ\text{C}$, with an average of $25.8 \text{ }^\circ\text{C}$.



(a) RMSE for the power generation model using fixed window sizes



(b) RMSE for the fixed load model using fixed window sizes



(c) RMSE for the thermal model using fixed window sizes

Figure 9. Identification of possible concept drifts in a summer day.

In Table 2, the average RMSE for the selected summer days is displayed. Again, the proposed method performs better than the sliding window for all models. Nevertheless, for the fixed load model, the Klinkenberg and Joachims method achieves a lower average error. This result suggests that adapting different models with different techniques is preferable in some cases, even if that implies managing different databases for each model.

Table 2. Average RMSE and average NRMSE for a summer day.

	Power Generation [kW]	Fixed Load [kW]	Thermal Load [°C]
Full memory (8064 samples)	0.44479 (17.32%)	2.80095 (34.55%)	0.47161 (19.82%)
Drift Detection Method	0.44250 (17.24%)	2.55943 (31.58%)	0.44122 (18.775%)
Gold Ratio Method	0.45597 (17.80%)	2.43693 (30.04%)	0.47094 (19.79%)
Klinkenberg Method	0.53091 (20.64%)	2.39652 (29.55%)	0.44375 (19.04%)
FISH Method	0.46619 (18.17%)	2.95768 (36.87%)	0.79645 (32.82%)
Adwin Method	0.46240 (18.05%)	2.69773 (33.26%)	0.43769 (18.81%)
Proposed Method	0.43797 (17.06%)	2.71268 (33.52%)	0.4423 (18.68%)

In this case, the dispersion of the error is comparable for all the methods, but, for the fixed load model, Drift Detection and Gold Ratio Methods seem to be less sensitive to outliers and recurrent concepts. On the other hand, in Figure 10, it is shown that the FISH method has the biggest dispersion in all three models, which means it is not suitable for the kind of drift that appears on these days.

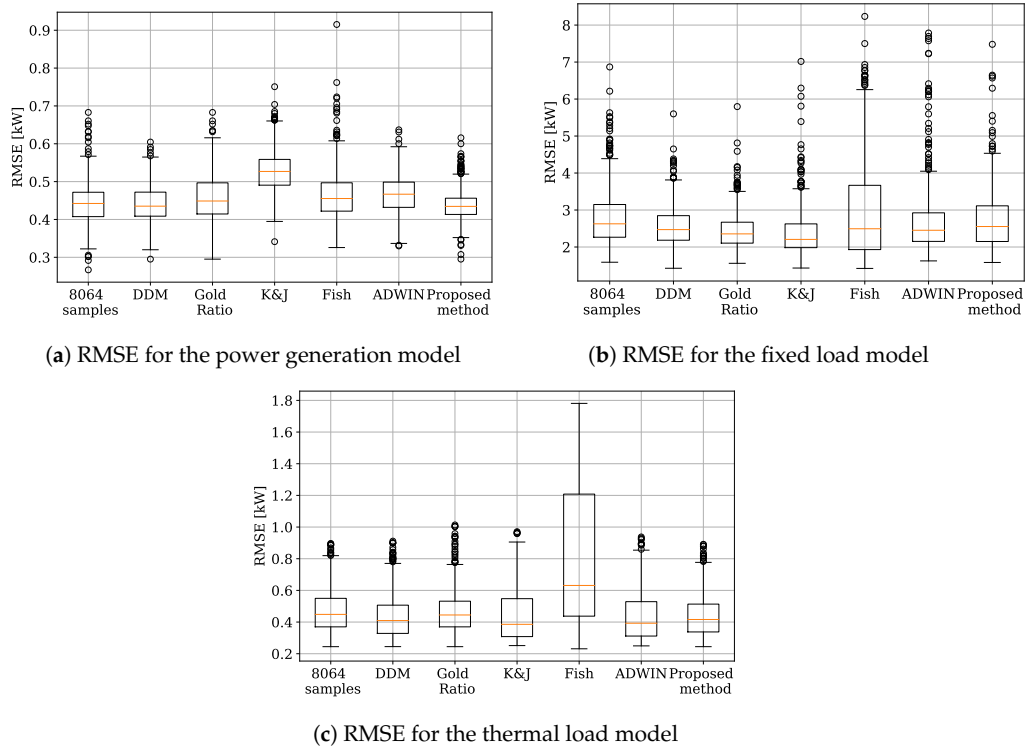


Figure 10. RMSE dispersion in the summer day.

5.3. Results Analysis

As mentioned before, for the case of the prosumer agents, concept drift can appear in different ways, and they are hard to predict. As a consequence, forgetting data becomes a difficult decision because the agent could lose relevant information for the forecast. In this context, the proposal of keeping in memory more data than only the training set seems to be adequate for the agent. However, for some models, other methods obtain a better result using fewer data. For example, for the fixed load model, ADWIN and Klinkenberg's methods had the lowest average errors. It is relevant to mention that these methods assume that future samples are more strongly related to the most recent data in memory, and it is not possible to keep that assumption when there are gradual drifts.

Another key finding of the experiment is in comparison with the average error when using a fixed data window. In particular, it is possible to observe that some adaptation techniques were not adequate since they lead to an increase in the error. In contrast, the proposed method always had a better performance than using a simple sliding data window. As for the parameters of the proposed algorithm, the error threshold for accepting the result of the cross-validation was 0.8 kW for the power generation model, 2 kW for the fixed load model, and 0.8 °C for the thermal model. For the parameter N , the used value was 2016 since it ensures convergence on the training of all the models in the tested periods. Tuning algorithms parameters depends on knowledge about the performance of the base learners, so the agents should have validated the models beforehand.

A final remark is that most of the algorithms have a fixed number of operations or training processes. The only method that has an indefinite amount of operations is the gold ratio search, for which the complexity is estimated at $\mathcal{O}(\log \frac{1}{100})$ (100 is the minimum search interval in this case) [43]. Inevitably, this method takes more processing time than the others presented here. Since the models are trained with different amounts of samples every time, it is complicated to establish a metric to compare processing times.

6. Conclusions

Prosumer agents will play an essential role in energy management systems as they move towards decentralization. Then, it will be necessary to address their information needs to achieve adequate decisions. In particular, it is important to recognize that the agent environment is subject to change, and the models of different appliances need to be adapted to overcome different kinds of concept drift.

In order to formulate strategies to give the residential prosumers more reliable information upon which to base their decisions, this paper presented relevant criteria to account for when choosing adaptive algorithms to train the models of the local environment. Some of the existing algorithms in the literature were tested here with satisfactory results as they occasionally performed better than having a fixed window size.

Additionally, in this paper, we proposed another method that works for the information needs of the agents. The method depends on the number of batches selected to train the models; this parameter should be small to ensure that most of the samples correspond to the new concept but big enough to ensure the convergence when training the model. In experimental results, this algorithm was the only one that systematically produced better results than that obtained with a fixed data window size.

Author Contributions: Conceptualization, D.T., K.A., N.H., and A.C.; methodology, D.T. and N.H.; validation, R.M. and S.K.; formal analysis, D.T., K.A., R.M., and N.H.; writing—original draft preparation, D.T.; writing—review and editing, R.M., S.K., and A.C.; All authors have read and agreed to the published version of the manuscript.

Funding: This work was supported in part by the Laboratoire des technologies de l'énergie d'Hydro-Québec, the Natural Science and Engineering Research Council of Canada, and the Foundation of Université du Québec à Trois-Rivières.

Acknowledgments: The authors would like to thank the Laboratoire des technologies de l'énergie d'Hydro-Québec, the Natural Science and Engineering Research Council of Canada, and the Foundation of Université du Québec à Trois-Rivières.

Conflicts of Interest: The authors declare no conflicts of interest.

References

1. U.S. EIA. Annual Energy Outlook 2019 with projections to 2050. Available online: <https://www.eia.gov/aeo> (accessed on 20 December 2019).
2. GWAC. GridWise Transactive Energy Framework. *GridWise Archit. Counc. Trans. Energy* **2013**, *1*, 1–23.
3. Lian, J.; Zhang, W.; Sun, Y.; Marinovici, L.; Kalsi, K.; Widergren, S. *Transactive System. Part I: Theoretical Underpinnings of Payoff Functions, Control Decisions, Information Privacy, and Solution Concepts*; Technical Report December; Pacific Northwest National Laboratory: Richland, WA, USA, 2017.
4. Yoon, J.H.; Baldick, R.; Novoselac, A. Dynamic demand response controller based on real-time retail price for residential buildings. *IEEE Trans. Smart Grid* **2014**, *5*, 121–129. [[CrossRef](#)]
5. Nagi, K. *Transactional Agents: Towards a Robust Multi-Agent System*; Springer Berlin Heidelberg: Karlsruhe, Germany, 2001.
6. Odell, J.; Giorgini, P.; Müller, J. *Agent-Oriented Software Engineering V*; Springer: Berlin/Heidelberg, Germany, 2004.
7. Damisa, U.; Nwulu, N.I.; Sun, Y. Microgrid energy and reserve management incorporating prosumer behind-the-meter resources. *IET Renew. Power Gener.* **2018**, *12*, 910–919. [[CrossRef](#)]
8. Zhang, Y.; Huang, T.; Bompard, E.F. Big data analytics in smart grids: A review. *Energy Inform.* **2018**, *1*, 1–24. [[CrossRef](#)]
9. Khamphanchai, W.; Saha, A.; Rathinavel, K.; Kuzlu, M.; Pipattanasomporn, M.; Rahman, S.; Akyol, B.; Haack, J. Conceptual Architecture of Building Energy Management Open Source Software (BEMOSS). In Proceedings of the 2014 5th IEEE PES Innovative Smart Grid Technologies Europe (ISGT Europe), Istanbul, Turkey, 12–15 October 2014; pp. 1–6. [[CrossRef](#)]
10. Bifet, A.; Gavaldà, R. Adaptive Learning from Evolving Data Streams. In *Advances in Intelligent Data Analysis VIII*; Springer: Berlin, Germany, 2009; pp. 249–260. [[CrossRef](#)]
11. Loeffel, P.X. Adaptive Machine Learning Algorithms for Data Streams Subject to Concept Drifts. Ph.D. Thesis, Iniversité Pierre et Marie Curie, Paris, France, 2018.
12. Zaknich, A. *Principles of Adaptive Filters and Self-Learning Systems*; Springer: Murdoch, Australia, 2005.
13. Balasubramanian, V.; Ho, S.S.; Vovk, V. *Conformal Prediction for Reliable Machine Learning*; Elsevier: Waltham, MA, USA, 2016. [[CrossRef](#)]
14. Gama, J.; Zliobaitė, I.; Bifet, A.; Pechenizkiy, M.; Bouchachia, A. A Survey on Concept Drift Adaptation. *ACM Comput. Surv.* **2013**, *46*. [[CrossRef](#)]
15. Al-Ali, A.; Zualkernan, I.A.; Rashid, M.; Gupta, R.; Alikarar, M. A smart home energy management system using IoT and big data analytics approach. *IEEE Trans. Consum. Electron.* **2017**, *63*, 426–434. [[CrossRef](#)]
16. Keshtkar, A.; Arzanpour, S. An adaptive fuzzy logic system for residential energy management in smart grid environments. *Appl. Energy* **2017**, *186*, 68–81. [[CrossRef](#)]
17. Farzan, F.; Jafari, M.A.; Gong, J.; Farzan, F.; Stryker, A. A multi-scale adaptive model of residential energy demand. *Appl. Energy* **2015**, *150*, 258–273. [[CrossRef](#)]
18. Yoo, J.; Park, B.; An, K.; Al-Ammar, E.A.; Khan, Y.; Hur, K.; Kim, J.H. Look-ahead energy management of a grid-connected residential PV system with energy storage under time-based rate programs. *Energies* **2012**, *5*, 1116–1134. [[CrossRef](#)]
19. Bouchachia, A.; Gabrys, B.; Sahel, Z. Overview of some incremental learning algorithms. In Proceedings of the IEEE International Conference on Fuzzy Systems, London, UK, 23–26 July 2007. [[CrossRef](#)]
20. Bifet, A.; Gavaldà, R. Learning from Time-Changing Data with Adaptive Windowing. In Proceedings of the 2007 SIAM International Conference on Data Mining, Minneapolis, MN, USA, 26–28 April 2007; Society for Industrial and Applied Mathematics: Philadelphia, PA, USA, 2007; pp. 443–448. [[CrossRef](#)]
21. Zliobaite, I. Adaptive Training Set Formation. Ph.D. Thesis, Vilnius University, Vilnius, Lithuania, 2010.
22. Gama, J.; Medas, P.; Castillo, G.; Rodrigues, P. Learning with Drift Detection. In *Advances in Artificial Intelligence-SBIA 2004*; Springer: Berlin, Germany, 2004; Volume 3171, pp. 286–295. [[CrossRef](#)]
23. Murphy, K. *Machine Learning: A Probabilistic Perspective*; The MIT Press: Cambridge, MA, USA, 2012; pp. 27–71. [[CrossRef](#)]
24. Moreno-Torres, J.G.; Raeder, T.; Alaiz-Rodríguez, R.; Chawla, N.V.; Herrera, F. A unifying view on dataset shift in classification. *Pattern Recognit.* **2012**, *45*, 521–530. [[CrossRef](#)]
25. Webb, G.I.; Hyde, R. Characterizing Concept Drift. *Data Min. Knowl. Discov.* **2016**, *30*, 964–994, arXiv:1511.03816v6.

26. Cieslak, D.A.; Hoens, T.R.; Chawla, N.V.; Kegelmeyer, W.P. Hellinger distance decision trees are robust and skew-insensitive. *Data Min. Knowl. Discov.* **2012**, *24*, 136–158. [[CrossRef](#)]
27. Widmer, G.; Kubat, M. Learning in the presence of concept drift and hidden contexts. *Mach. Learn.* **1996**, *23*, 69–101. [[CrossRef](#)]
28. Zhou, Z.H. *Ensemble Methods: Foundations and Algorithms*; CRC Press: Boca Raton, FL, USA, 2012.
29. Palnitkar, R.; Cannady, J. A Review of Adaptive Neural Networks. In Proceedings of the IEEE SoutheastCon, Greensboro, NC, USA, 26–29 March 2004; pp. 38–47. [[CrossRef](#)]
30. Kuncheva, L.I.; Gunn, I.A. A concept-drift perspective on prototype selection and generation. In Proceedings of the International Joint Conference on Neural Networks, Vancouver, BC, Canada, 24–29 July 2016; pp. 16–23. [[CrossRef](#)]
31. Bifet, A.; Gavaldà, R.; Holmes, G.; Pfahringer, B. *Machine Learning for Data Streams: With Practical Examples in MOA*; The MIT Press: Cambridge, MA, USA, 2018.
32. Koychev, I.; Lothian, R. Tracking Drifting Concepts by Time Window Optimisation. In *Research and Development in Intelligent Systems XXII*; Springer: London, UK, 2006; pp. 46–59. [[CrossRef](#)]
33. Klinkenberg, R.; Joachims, T. Detecting Concept Drift with Support Vector Machines. In Proceedings of the Seventeenth International Conference on Machine Learning, Stanford, CA, USA, 29 June–2 July 2000; pp. 487–494.
34. Aggarwal, C.C. Towards systematic design of distance functions for data mining applications. In Proceedings of the Ninth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining-KDD '03, Washington, DC, USA, 24–27 August 2003; ACM Press: New York, NY, USA, 2003; p. 9. [[CrossRef](#)]
35. Aggarwal, C.C.; Hinneburg, A.; Keim, D.A. On the Surprising Behavior of Distance Metrics in High Dimensional Space. *Am. J. Dermatopathol.* **2001**, *30*, 420–434. [[CrossRef](#)]
36. Chai, T.; Draxler, R.R. Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. *Geosci. Model Dev.* **2014**, *7*, 1247–1250. [[CrossRef](#)]
37. Touzani, S.; Granderson, J.; Fernandes, S. Gradient boosting machine for modeling the energy consumption of commercial buildings. *Energy Build.* **2018**, *158*, 1533–1543. [[CrossRef](#)]
38. Pedregosa, F.; Varoquaux, G.; Gramfort, A.; Michel, V.; Thirion, B.; Grisel, O.; Blondel, M.; Müller, A.; Nothman, J.; Louppe, G.; et al. Scikit-learn: Machine Learning in Python. *Psychol. Sci.* **2012**, *25*, 1682–1690. [[CrossRef](#)]
39. Holmgren, W.; Hansen, C.; Mikofski, M. pvlib python: A python package for modeling solar energy systems. *J. Open Source Softw.* **2018**, *3*, 884. [[CrossRef](#)]
40. Alpaydin, E. *Introduction to Machine Learning Second Edition*, 3rd ed.; The MIT Press: Cambridge, MA, USA, 2010; pp. 350–380. [[CrossRef](#)]
41. Jokisalo, J.; Kurnitski, J. Performance of EN ISO 13790 utilisation factor heat demand calculation method in a cold climate. *Energy Build.* **2007**, *39*, 236–247. [[CrossRef](#)]
42. Gelman, A.; Carlin, J.; Stern, H.; Rubin, D. *Bayesian Data Analysis*; Chapman & Hall: London, UK, 2004.
43. Chong, E.; Zak, S. *An Introduction to Optimization*, 4th ed.; Wiley and Sons: Hoboken, NJ, USA, 2013.



© 2020 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).

3.2 Architecture logicielle des agents résidentiels automatisés

3.2.1 Contexte

Une fois que l'agent a créé des modèles des appareils dans son environnement local, il est nécessaire de les intégrer dans une architecture logicielle pour prendre des décisions et agir dans l'environnement transactionnel. Dans l'architecture logicielle on définit les comportements : quand et comment l'agent exécute ses actions.

Dans ce cas, l'objectif de l'architecture logicielle est de réaliser deux tâches fondamentales pour l'agent résidentiel : la prévision et la planification de la consommation. Étant donné que l'agent interagit dans un marché à terme, ces deux tâches définissent les autres actions telles que le contrôle de charges locales et la communication avec d'autres agents. Compte tenu des conditions du marché à terme de l'ET, une fois que l'agent a communiqué sa planification de consommation, il est obligé de la réaliser dans la mesure de ses possibilités pour éviter une éventuelle sanction.

Le problème de planification de l'agent consiste à trouver une stratégie de consommation optimale. C'est-à-dire la stratégie qui maximise la différence entre l'utilité que l'utilisateur perçoit pour la consommation d'énergie et le coût de celle-ci. Ce problème est résumé par l'équation 3.1, où U_t est la fonction d'utilité, C_t est la fonction de coût et T est la période de marché. La fonction de coût dépend des prix d'achat π_t et de vente λ_t de l'électricité. Habituellement, le prix d'achat est égal au prix de vente, mais dans les cas où ils sont différents, il apparaît des discontinuités qui peuvent affecter la convexité du problème. La variable de décision pour l'agent est la consommation des charges contrôlables $P_{cl,t}$ qu'il doit évaluer avec l'estimation de la consommation des charges non contrôlables $\hat{P}_{f,t}$ et l'estimation de la génération locale $\hat{P}_{g,t}$. La fonction d'utilité U_t dépend de la nature de la charge contrôlable. Dans ce cas, avec les systèmes de chauffage, la fonction d'utilité est liée à la température à l'intérieur de la maison, il faut donc disposer d'un modèle reliant cette température à la consommation de chauffage.

$$\max_{P_{cl,1}, \dots, P_{cl,T}} \sum_{t=1}^T U_t - C_t \quad (3.1)$$

s.c. :

$$C_t = \begin{cases} \pi_t(P_{cl,t} + \hat{P}_{f,t} - \hat{P}_{g,t}) & \text{if } \hat{P}_{g,t} \leq P_{cl,t} + \hat{P}_{f,t} \\ \lambda_t(P_{cl,t} + \hat{P}_{f,t} - \hat{P}_{g,t}) & \text{if } \hat{P}_{g,t} > P_{cl,t} + \hat{P}_{f,t}. \end{cases} \quad (3.2)$$

$$U_t \propto P_{cl,t} \quad (3.3)$$

Le résultat de ce problème d'optimisation est utilisé pour obtenir un contrat à terme dans l'environnement de l'ET. En supposant que l'agent est neutre par rapport au risque, la variabilité des prédictions n'est pas prise en compte dans les transactions. De son côté, l'agent agrégateur atteint l'équilibre du marché lorsqu'il peut paramétrer les solutions déterministes de ce problème d'optimisation. Ce paramétrage peut nécessiter de multiples interactions en fonction de la taille du marché et de l'horizon d'optimisation.

3.2.2 Méthodologie

L'architecture logicielle est composée de six comportements asynchrones sans ordre hiérarchique pour les tâches suivantes : acquisition de données, modélisation adaptative, optimisation, contrôle des appareils, calcul des rapprochements et communications. Étant donné que l'agent résidentiel est un suiveur dans le mécanisme transactionnel, son problème d'optimisation est résolu avec une information complète en se fiant sur les données qu'il possède.

Dans le bloc d'acquisition des données, l'agent obtient le flux de données des appareils, les informations météorologiques qui affectent la consommation et les préférences de l'utilisateur. Avec ces données, l'agent crée les modèles ou adapte ceux qu'il possède déjà pour formuler sa stratégie de consommation dans le bloc d'optimisation. Une fois que l'agent a sa stratégie, il communique ses intentions de consommation d'énergie afin d'obtenir l'approbation du système transactionnel et de programmer les actions de contrôle sur les appareils. Comme il existe des sources d'incertitude qui peuvent empêcher que la consommation planifiée soit respectée, il est nécessaire pour l'agent d'inclure un bloc de traitement des rapprochements dans le marché. La Figure 3-2 illustre l'architecture de l'agent.

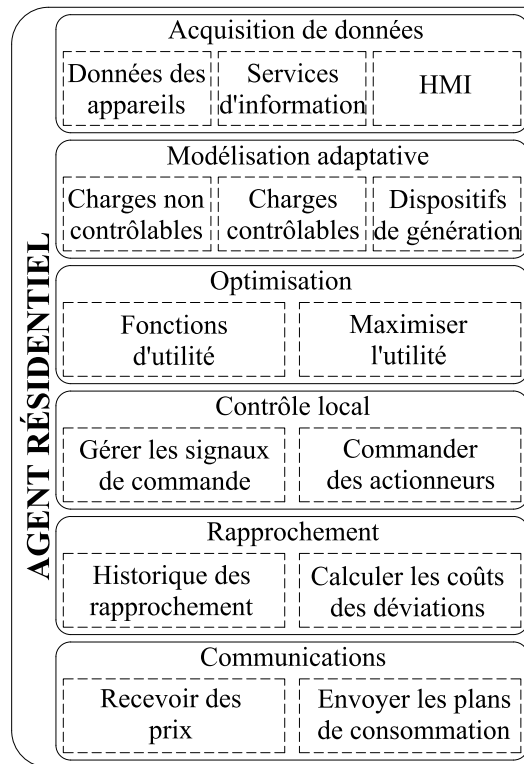



FIGURE 3-2 Architecture logicielle de l'agent résidentiel

3.2.3 Résultats

L'architecture proposée a été testée sur un marché local de l'énergie, où un agrégateur de demandes joue le rôle de leader et envoie des signaux de prix. Les résultats des transactions simulées montrent que l'architecture est suffisante pour que l'agent puisse rassembler les informations nécessaires et planifier une stratégie de consommation. En outre, la forme modulaire de l'architecture permet d'être facilement étendue pour intégrer de nouvelles fonctions au cas où l'agent participe à d'autres marchés.

Les simulations avec un signal de prix unique ont permis d'identifier une situation de dilemme du prisonnier qui limite les objectifs des agents dans la configuration des marchés locaux. Pour les agrégateurs de demandes, cette condition limite le facteur d'aplatissement qu'ils peuvent obtenir dans le profil de la demande. D'autre part, cette configuration limite aussi les économies que les utilisateurs les plus élastiques peuvent réaliser puisque le prix dépend également des actions des agents résidentiels voisins sans coordination. Les solutions possibles

à ces inconvénients sont discutées dans le chapitre 5 du présent document. Dans les simulations présentées dans l'article, le prix d'achat a été considéré comme égal au prix de vente pour éviter les discontinuités et accélérer la solution. Dans les cas où les prix sont différents, l'agent devra évaluer les différents optimums locaux avant d'annoncer sa stratégie de consommation.



Prevision and planning for residential agents in a transactive energy environment

David Toquica ^{a, b, *}, Kodjo Agbossou ^{a, b}, Nilson Henao ^{a, b}, Roland Malhamé ^c,
Souso Kelouwani ^{b, d}, Fatima Amara ^e

^a Department of Electrical and Computer Engineering, Université du Québec à Trois-Rivières, 3351, boul. des Forges, Trois-Rivières, Quebec, QC, G8Z 4M3, Canada

^b Smart Energy Research and Innovation Laboratory, LIREI, Canada

^c Department of Electrical Engineering, Polytechnique Montréal, C.P. 6079, Succ. Centre-ville, Montréal, Quebec, QC, H3C 3A7, Canada

^d Department of Mechanical Engineering, Université Du Québec à Trois-Rivières, 3351, Ioul. des Forges, Trois-Rivières, Quebec, QC, G8Z 4M3, Canada

^e Institut de Recherche L'Hydro-Québec (IREQ-LTE), Canada

ARTICLE INFO

Article history:

Received 30 December 2020

Received in revised form

4 April 2021

Accepted 21 April 2021

Available online 9 May 2021

Keywords:

Agents interaction
Forward market
Multi-agent system
Price-elasticity
Prosumer
Smart energy markets
Stackelberg game
Transactive energy
Utility function

ABSTRACT

Transactive Energy (TE) has brought exciting opportunities for all stakeholders in energy markets by enabling management decentralization. This new paradigm empowers demand-side agents to play a more active role through coordinating, cooperating, and negotiating with other agents. Nevertheless, most of these agents are not used to process market signals and develop optimal strategies, especially in the residential sector. Accordingly, it is indispensable to create tools that automate and facilitate demand-side participation in TE systems. This paper presents a new methodology for residential automated agents to perform two key tasks: prevision and planning. Specifically, the proposed method is applied to a forward market where agents' planning is a fundamental step to maintain the dynamic balance between demand and generation. Since planning depends on future demand, agents' prevision of consumption is an inevitable part of this step. The procedures for automating the targeted tasks are developed in a general way for residential prosumers and consumers, interacting at the distribution level. These players are managed by a demand aggregator as the leader by means of the Stackelberg game. The suggested process results in a TE setup for multi-stage single-side auctions, useful to manage future Smart Energy Markets. Through simulated transactions, this paper examines the market clearing mechanism and the convenience of agents' planning. The results show that customers with higher price-elasticity leverage lower costs periods. However, they make it harder to reduce the peak-to-average ratio of the aggregated demand profile since a unique price signal can create prisoner's dilemma conditions.

© 2021 The Author(s). Published by Elsevier Ltd. This is an open access article under the CC BY-NC-ND license (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

1. Introduction

Energy systems must confront significant challenges to successfully integrate renewable resources due to their intermittency and variability [1]. Accordingly, several technologies have been deployed to realize smart energy systems that offer more flexibility and sustainability. The new technologies allow for identifying synergies between electricity, thermal, and gas grids regarding optimal global solutions [2]. These advancements along with new

energy market designs can exploit the potential of each component in the system. Diverse innovative market solutions using smart infrastructure can result in a better resource allocation to improve security, equity, and social welfare [3].

Some of the most promising market designs in electrical grids are based on Transactive Energy (TE) [4]. The main objective of TE is to decentralize grid management in order to help stakeholders maintain the balance of the grid while pursuing their objectives. The change from centralized to decentralized optimization improves grid management because it reduces uncertainties, risks, and inefficiencies [5]. Particularly, the changes in electricity markets affect all energy sectors due to the conversion stage, needed for the final energy use and the synergy with other energy grids.

The TE paradigm applied to energy markets transforms all

* Corresponding author. Department of Electrical and Computer Engineering, Université du Québec à Trois-Rivières, 3351, boul. des Forges, Trois-Rivières, Quebec, QC, G8Z 4M3, Canada.

E-mail address: david.camilo.toquica.cardenas@uqtr.ca (D. Toquica).

stakeholders into decision-makers that interact (coordinate, cooperate, and negotiate) with each other [6]. In this sense, TE creates complications for stakeholders that have a passive role like residential customers. Indeed, these customers have to process a significant amount of data to quickly develop a consumption strategy and find resources through the whole smart infrastructure [7]. This situation necessitates employing automated tools to fulfill the transactions on behalf of the residential customers [8]. In this paper, the automated device is referred to as an agent.

In the literature, the feasibility of integrating residential agents into grid management has been studied by the game theory [9]. Indeed, different enhancements have been made towards a framework for agents' interactions in distribution grids [10]. However, residential agents' rationality has been assumed without special considerations to how they create beliefs, update their desires, and generate intentions. Therefore, it is necessary to define agents' behaviors in detail and develop standard procedures for their tasks. The development of reliable agents help engage customers into TE systems [11].

Since grid management depends on agents' interactions and agreements, the information that they share is one of the most important aspects to control [12]. There should not exist incentives to lie in a well-designed mechanism, and each decision-maker must minimize information errors [13]. For instance, residential agents need to have a comprehensive understanding of their energy consumption and retailers need to supply accurate price signals. In this scenario, residential agents must perform some anticipation tasks to ensure that their information is reliable. They need a prevision of uncontrollable variables and a plan to handle controllable loads. This anticipation helps build trust and define other agents' behaviors like local control.

In the specific case of forward-markets, the agents' anticipation tasks define the operation of the grid [14]. In such context, agents agree on energy price and consumption for future delivery, and then they execute their plans to fulfill agreements and avoid penalties. Table 1 summarizes different authors' proposals for agents' interaction to reach agreements, explicitly in electric grids. Most of the literature approaches do not take into account agents' information needs from diverse sources such as weather data or user' valuations. Besides, some interaction schemes do not consider the extend of the solutions considering large TE systems. For these scalability issues, a demand aggregator agent is favored as a great

bridge to link residential agents and wholesale energy markets [15].

In this paper, the proposed market configuration is a Stackelberg game where the aggregator leads the interaction to realize a forward contract with the residential agents as followers. Consequently, each residential agent formulates its strategy based on the signals it receives without either parametrizing or anticipating other agents' responses [25]. The observability conditions of agents are different. Residential and aggregator agents fail to parametrize market signals and individual consumption, respectively [26]. As a result, they both have to trust the information they receive [27]. TE mechanisms are beneficial for building such trust since they are multistage games that allow agents to discover information while they interact [16]. Thus, in the end of the interactions, agents will not have an incentive to deviate from their plan considering other agents' strategy. This condition leads to a Nash equilibrium point [28].

The residential agents' strategy is formulated to maximize the utility by balancing costs and customers' comfort considering the constraints of loads dynamics [29]. Energy conversion technologies in smart energy systems (like power-to-X) are advantageous because they allow formulating strategies without excessively compromising comfort [30]. Indeed, residential agents can characterize all their behind-the-meter resources (local environment) and make an integrated consumption plan. This characterization of the local environment can be done by using data-driven and stochastic modeling approaches [31]. Besides, an agent can adapt these models to overcome the accuracy loss when external conditions change [32]. In this case, for simplicity in data management, energy consumption and generation devices are considered in groups.

Once the residential agent has characterized its local environment, it can make a prevision and process the market signals to optimize its energy consumption plan. Afterwards, it can communicate its plans and intentions with the demand aggregator or other participants in the Multi-Agent System (MAS). To complete this procedure and systematically integrate the prevision results into the planning procedure, it is valuable to have a structured software design in terms of agent-oriented programming. Such scheme can also contribute to the scalability of TE solutions [33]. Within this context, this paper aims to promote standard procedures for the prevision and planning tasks of residential agents in a TE system. The contributions of this work can be summarized as follows:

Table 1
Limitations in state of the art work.

Interaction scheme	Achievements	Limitations
Cournot competition [16]	Considers customers' willingness to pay and preferences.	Agents interact directly in the wholesale market, making it problematic for large power systems.
Coordination of opportunistic agents [17]	Optimal scheduling of appliances according to resource availability. Impose agents' solutions over customer preferences.	Increase the implementation requirements since it proposes a MAS in the local environment.
Distributed demand response algorithms [18]	Improved (flatten) aggregated demand profile.	Agents need to be informed about their peers' strategies and the pricing scheme.
Centralized demand response with TE as security mechanism [19]	Combined approach to overcome imbalances in the grid and improve system resiliency.	Agents depend on centralized optimization and forecasts.
Peer-to-peer trading [20,21]	Proved economic benefits for the agents.	Assumes perfect information and perfect agents that make rational decisions
Coalition operations and collaborative agents [6,22]	Interactions between agents successfully integrate DER and bring economic benefits. Scalable solutions.	Coalitions among suppliers left customers in a disadvantageous position.
Double-side auctions [7,23]	Independent agent strategies. Information privacy. Improved cost allocation.	Lower social welfare compared with iterative games.
Aggregators' direct load control [24]	Reduces uncertainties.	It does not consider customers' preferences and information privacy.
Stackelberg game with MAS in the local environment [25]	Economic benefits for the residential agent.	Hard to extend for multiple agents since retailers have to send in advance a definitive price signal without information about the consumption.
Energy Hubs [9]	Distributed grid management. Scalable solution.	Assumes deterministic consumption with perfect agents.

- A sequential interaction protocol between residential agents and a demand aggregator agent to find equilibrium points in an iterative Stackelberg game. As a result of this interaction, the agents reach forward contracts that set the energy price. Moreover, this protocol allows the aggregator to coordinate the demand in a small part of an energy system and offer useful insights for managing the wholesale energy market.
- A planning algorithm based on agent-oriented programming paradigm for solving residential agents' information needs in TE. The algorithm is used to find the best consumption strategy according to the perception of local environments and the price signal. This helps characterize the agents' rationality that is commonly assumed in the literature. Agents' behavior is formulated for groups of appliances considering risk-neutral users in order to overcome customers' heterogeneity.

By explicitly defining the decision-making procedure of residential agents, this work addresses the problem of assuming perfect agents with perfect information that is common in the literature, as presented in Table 1. Furthermore, it proposes to manage energy systems by coordinating the demand of small parts through aggregator agents owing to forward-markets potentials. These aggregators have proven to bring benefits to all stakeholders in the system [15]. Through this proposition, we prevent residential agents from interacting directly with wholesale markets since it complicates the management of large energy systems.

The rest of this paper is organized as follows: Section 2 explains the developed framework of TE and the opportunities of residential agents in the market. Section 3 presents the proposed procedures for residential agents to perform the anticipation tasks with the definition of their behaviors. The experimental setup and results, obtained from case studies with simulated transactions, are discussed in Section 4, followed by the concluding remarks in Section 5.

2. Transactive energy framework

Transactive Energy systems are composed of economic and control mechanisms that allow the dynamic balance of supply and demand by using value as a key operational parameter [34]. The main features that differentiate TE from other grid management schemes are the distributed decision-making process and the two-way communication channel between all agents [35]. TE allows agents interaction to find equilibrium points and balance the grid. Particularly, user-perceived values reflect their willingness to pay. In an aggregated manner, these valuations tune the price of energy and services in the transactions [36].

Commonly, interactions between agents are not unique because they can have different objectives. For example, retailers and final consumers can have opposite objectives and thus, they should negotiate. On the other hand, two prosumers with similar objectives can cooperate [37]. Individually, each agent looks for optimizing its payoff function. However, at the end, the system reaches an equilibrium with agreed transactions [38]. Normally, agents have to know market rules and perhaps even pricing schemes and taxation regulations before agreeing on transactions [39].

In this study, we consider that agents representing residential customers interact only with a demand aggregator. Therefore, residential prosumer and consumer agents negotiate with this aggregator agent to buy or sell energy in a forward market [40]. For simplicity, it is assumed that the only commodity in trades is active energy. It should be noted that TE is conceived for electricity grids and its implementation requires all the layers, proposed in the Smart-Grid Architecture Model (SGAM), to provide communication between agents [41]. The schematic of the proposed setup is

presented in Fig. 1, where HQ is the aggregator agent and H1, H2, ..., Hk are the residential agents. Since the system is not meant to operate as an isolated microgrid, generation resources adequacy and reliability are not advised [42].

Since there is only one commodity in trades, the exchanged messages between the agents are more straightforward than others proposed in the industry such as OpenADR and ANSI/CTA 2045 [43]. Firstly, the aggregator registers the residential agents. Afterwards, it waits for the "ready" (RDY) message from each one to start the interaction process. All agents have to participate in all market periods even if they send void purchasing or selling offers. When all agents are ready, the aggregator, as the leader, sends the price signal first and then, waits for each residential agent's response. Finally, whenever the aggregated demand profile is satisfactory, the aggregator sends an "acknowledgment" (ACK) message and the residential agents assume their last proposed consumption is accepted. This interaction is represented by the Unified Modeling Language (AUML) in Fig. 2.

It is presumed that there are no security concerns in lower layers since the interaction is made on high-level communication layers by utilizing protocols like XMPP or MQTT [44]. The main advantage of the strategy of waiting for each response is that it ensures all residential agents participate in transactions even if it takes longer processing times than other approaches in the literature [40]. Since the residential agents get a forward contract, their planning and interaction procedures are made in advance and consequently, the processing time is not critical.

The changes in the residential sector strategy towards transacting active energy inevitably affect other energy markets [45]. Moreover, residences can be directly connected to heat and gas grids in order to supply specific demands by switching the technologies [46]. Accordingly, it is necessary to analyze the scaling options of a market re-design to advise a higher social welfare [47]. In this regard, the proposed agents' interaction allows for coordinating the residential sector active energy demand, in advance, and using the resulting forward contracts for clearing the wholesale electricity market. Furthermore, the results can be utilized in other energy markets to forecast the demand.

2.1. Proposed aggregator agent architecture

In the value discovery mechanism, the aggregator, as the leader of a Stackelberg game, makes an initial assumption about residential agents' consumption to start negotiations [25]. Under this concern, the proposed agent architecture for aggregators has four behaviors, as presented in Fig. 3. First, the aggregator agent gets data from two components of the price accounting for the unitary cost of energy and the initial incentive or commercialization/aggregation rate. Second, it registers customers and per chance classifies them according to their demand flexibility or elasticity. Third, it takes the residential agents' responses to update the demand model and formulate the pricing strategy based on an optimization problem. The pricing strategy corresponds to the aggregator's




Fig. 1. System setup with one demand aggregator.

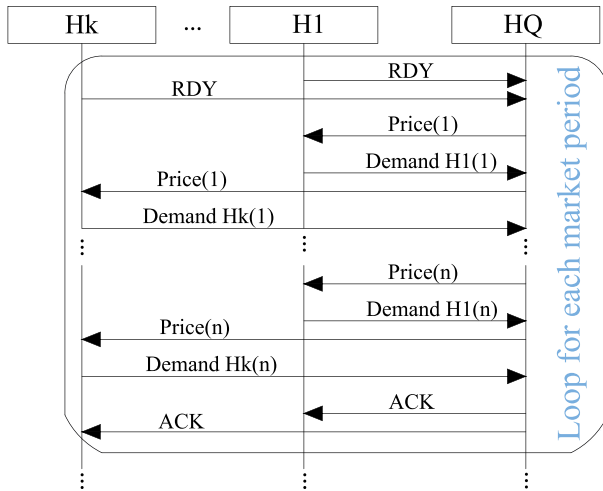


Fig. 2. Proposed AUML diagram.

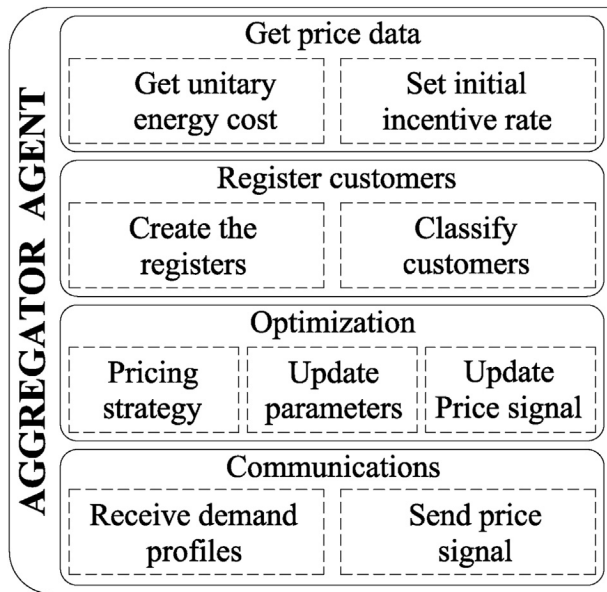


Fig. 3. Aggregator Agent architecture.

objective in the energy system. Generally, in electrical grids, the aggregator's goal is to flatten the aggregated demand profile minimizing the peak-to-average ratio (PAR) [48]. It should be noticed that it is possible to minimize the PAR by employing reinforcement learning techniques without building the demand model [49]. Finally, the aggregator agent architecture requires a behavior to communicate the price signals with the residential agents.

Employing a single aggregator to minimize PAR improves risk management and grid assets use [42,50]. However, it is interesting to have competing aggregators in order to mitigate their market power in cases where they try to maximize revenues [15]. The problem formulation for the aggregator in our case is presented in Eq. (1).

$$\min_{I_1, \dots, I_T} PAR = \frac{T \max(P_1, \dots, P_T)}{\sum_{t=1}^T P_t} \quad (1)$$

$$st : P_t = P_{flex,t} \pi_t + P_{fix,t} \quad \forall t \quad (2)$$

$$\pi_t = UC + I_t \quad (3)$$

$$\sum_{t=1}^T P_t I_t = E \quad (4)$$

Where, I_t (decision variable) stands for the incentives at each time t , and P_t is the power demand signal discretized in T energy blocks according to the market period. UC stands for the unitary cost of electricity and E expresses the expected revenue. Normally, the price π_t is the sum of UC and I_t . Here, UC is considered as a constant value that the aggregator knows beforehand from the wholesale market. Since a part of the electricity demand is inelastic (even some appliances can be necessity goods), E has a limit, given by a revenue cap regulation. The optimization horizon, T , is often set to 24 h (day-ahead) in forward-markets. However, reducing T can be suitable for micro-grids because it can assist with a reliable forecast of intermittent distributed energy resources (DER) [51].

The aggregated demand, P_t , is modeled as a linear function of the price as naive approach without further information on each house appliances. $P_{fix,t}$ and $P_{flex,t}$ correspond to the fixed and proportional parts of the demand, respectively. These parameters are estimated from a simple linear regression by using the Least-squares method based on Eqs. (5) and (6) with normally distributed error term (as an assumption). An individual incentive formulation for each customer by using independent values of $P_{fix,t}$ and $P_{flex,t}$ can result in a lower PAR considering users' participation in various energy markets. However, this is out of the scope of this paper. Besides, when there are only consumers and the energy price is ensured to be positive, the demand can be modeled as a function of the logarithm of the price to accelerate the convergence.

$$\hat{P}_{flex,t} = \frac{COV(\pi_t, P_t)}{VAR(\pi_t)} \quad (5)$$

$$\hat{P}_{fix,t} = \bar{P}_t - \hat{P}_{flex,t} \bar{\pi}_t \quad (6)$$

The mean values, \bar{P}_t and $\bar{\pi}_t$ are incrementally updated in each iteration of the negotiation process. Similarly, the variance, (VAR) and covariance, (COV) are updated with the Welford's online algorithm [52]. The iterative process between the aggregator and the residential agents stops when there are no significant changes in the estimated regression parameters.

3. Residential decision-making process

The Pacific Northwest National Laboratory (PNNL) summarizes the tasks that stakeholders should perform to participate in TE systems as follows: planning, prevision, local control, register, negotiation, check-out, and reconcile [35]. Indeed, the success of these tasks depends on the knowledge that the agent has about its environment. In the residential agent context, we can distinguish two environments that account for a local environment composed




Fig. 4. Interaction of the residential agent with its environments.

of behind-the-meter resources and a transactive environment as the MAS. Fig. 4 presents the interactions of the residential agent and its environments. Due to the number and heterogeneity of appliances that a house can have, it is convenient to classify them into controllable loads, uncontrollable loads, and power generation devices.

Automating the tasks for residential users is essential because the flexibility in this sector comes from elastic users operating controllable loads. However, exploiting flexibility can be challenging if users do not appropriately respond to market signals. Instead, an automated agent guarantees rationality in the operation of loads at least inside the range of its observability [53]. The residential sector flexibility assists with the proper incorporation of intermittent and variable renewable resources, which, in turn, results in more sustainable energy systems.

This work focuses on the planning and prevision tasks because they define the operation of a forward-market. The planning intends to find the right sequence of actions to minimize cost considering the agents' Beliefs, Desires, and Intentions (BDI) [54]. The BDI approach implies that the residential agent has reactive behavior to respond to events and cognitive behavior to model its environment. Note that, in this context, agent's behavior defines activities that should be performed autonomously without external instruction [55]. In brief, the residential agent acquires the following.

- Beliefs corresponding to models that are built by using the local environment.
- Desires that are expressed in the pay-off function of an optimization problem.
- Intentions that present the solutions to the optimization problem during the planning task.

Since weather conditions influence both power generation of DER and energy consumption, the residential agent needs to receive weather data from an external information services to plan its strategy. Therefore, the first step in the anticipation tasks is to connect to those information services. It should be noted that the agent carries out the consumption planning in a way to reach a forward contract. Therefore, it should trust the weather forecast to formulate its action [56]. The next step in the planning procedure is to get data related to user's price-elasticity. This information can be obtained directly from a Human-Machine Interface (HMI) or inferred by using preference learning methods. Once the agent has both weather forecasts and price-elasticity data, it is ready to receive price offers and solve its optimization problem. The proposed planning procedure is summarized in the Algorithm 1.

Algorithm 1. Residential agent planning procedure.

Algorithm 1: Residential agent planning procedure

inputs: Historical data of consumption and its explanatory variables (environmental conditions)

output: Energy consumption strategy

begin

```

Get weather forecast for the next market period;
Get user's price-elasticity;
Adapt the models of appliances if needed;
Make the prevision of uncontrollable consumption:
    Forecast the fixed load consumption;
    Forecast the power generation ;
Receive price offers for the next market period ;
Optimize to find the consumption strategy for
controllable loads;
Send the expected total consumption for the market
period;

```

end

In the Stackelberg game configuration, presented above, the residential agents are followers and thus, they wait for the aggregator's offers. Since there is only one aggregator, the residential agents do not need to arrange bids and they can recognize the market period directly from the price signal [5]. The follower agents formulate their best strategy, s^* , by taking into account only the price signal, which they receive at each moment. It is noted that the complexity of the MAS and the unobservability of other agents' responses make it infeasible to parametrize the price signal [57]. Therefore, residential agents undergo difficulties to find perfect subgame equilibrium points albeit knowing that the TE mechanism has an optimal substructure [24]. This limitation can be regarded as a major issue of spot markets (not forward-markets) due to their small planning window.

The consumption strategy, s^* , deals with controllable loads, $P_{cl,t}$, uncontrollable loads, $P_{f,t}$, and power generation devices, $P_{g,t}$. The models of uncontrollable loads and power generation devices are required to forecast their outcomes. On the other side, the model of controllable loads is needed to know their dynamics under different conditions and evaluate the strategies' feasibility. As a result, the total estimated consumption, \hat{P}_t , for a given time, t , can be computed by Eq. (7).

$$\hat{P}_t = \hat{P}_{f,t} + P_{cl,t} - \hat{P}_{g,t} \quad (7)$$

Accordingly, the architecture to accomplish the prevision and planning tasks is presented in Fig. 5. It contains six asynchronous behaviors with no hierarchical order comprising data acquisition, adaptive modeling, optimization, local control, reconciliations, and communications. The agent's primary knowledge must contain the data window for training each model and all the external information, needed to solve the optimization problem. The calculation of reconciliations is also presented in the agent's architecture because the historical results of penalties can provide useful information for some users' planning. For instance, risk-averse agents can use past reconciliation costs to improve their strategies regarding asymmetric market penalties [23]. However, that is not part of the anticipation tasks considered here to be automated.

3.1. Data acquisition

The agent measures appliances' power consumption in the local environment and creates a data stream [58]. It can be convenient to

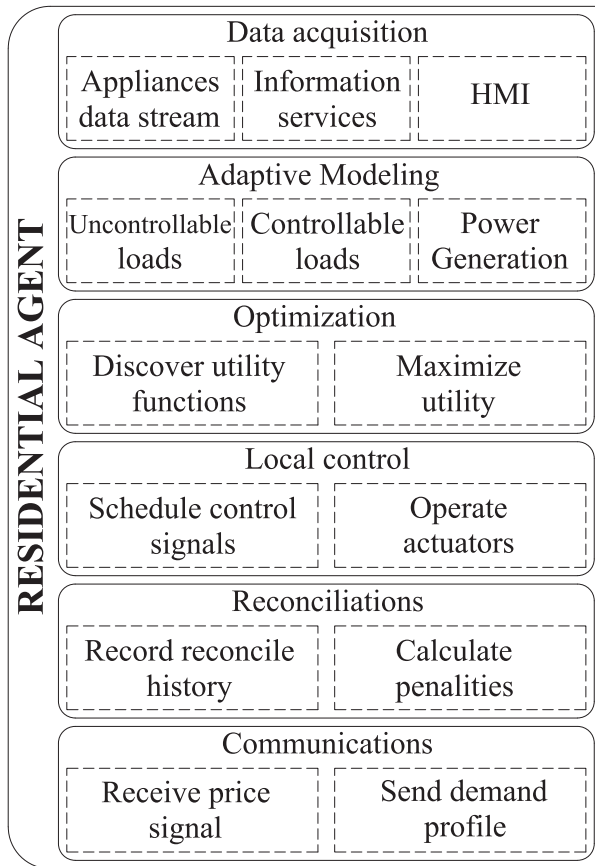


Fig. 5. Residential Agent's architecture.

implement lambda-based processing architectures for this behavior, depending on the sampling time and the number of appliances [59]. Consequently, the agent stores parts of the data stream, needed to create its environment models, in a time-indexed database. Furthermore, this database contains data from other sources such as weather forecast services to complete the information, required for the modeling phase.

Since the agent represents a final consumer, it is crucial to consider users' comfort constraints and price-elasticity. For this purpose, the data acquisition behavior includes an HMI that enables the communication between the agent and the user. For example, users could define preferred temperature setpoints for controlling heating systems, or state of charge limits for controlling electric vehicles [22,60].

3.2. Adaptive modeling

It is relevant to have an adaptive learning process because there can be concept drifts in the data. Concept drift is a change in the hidden joint probability between the consumption ($P_{f,t}, P_{cl,t}, P_{g,t}$) and its explanatory variables. In fact, the collected data can present any kind of drift because there are many changing sources. For example, weather conditions and appliances degradation can cause gradual drifts while technology upgrades can bring about sudden drifts. Therefore, the models should be adapted to overcome both kinds of drifts. This can be achieved by a suitable technique that is chosen considering the data management and the forgetting mechanisms as key factors. Models management or learning strategy can be adjusted according to the chosen configuration because not all the models can be ensembled or incrementally

trained [61].

For the residential agent, a technique based on Fish and Drift Detection methods, presented in Ref. [62], is utilized. This manner, summarized in the Algorithm 2, is suitable for this case because it forgets less data and, in turn, allows the agent to train many models with a single data window.

Algorithm 2. Adaptive Learning method.

Algorithm 2: Adaptive Learning method

inputs: Historical consumption data and weather forecast for the planning horizon

output: Trained models

begin

```

Divide the historical data into sub-windows;
Calculate the distance between each sub-window
and the weather forecast;
Make cross-validation using the closest sub-window
as the test set and the rest of the data as training set;
if Results have an acceptable error level then
    Train the model with all the available data;
    Forget old data only if there is no memory space;
else
    Train the model with the closest sub-windows;
    Forget old data until the oldest selected
    sub-window;

```

end

end

It can be noticed that the algorithm depends on the distance between data sub-windows and the error metrics. Indeed, the distance in time in the data stream and the distance in feature space must be weighted. The euclidean distance is frequently used in the literature for measuring distance in feature space due to its fast calculation [63]. Afterwards, it is convenient to use relative metrics like the Normalized Root Mean Square Error (NRMSE) in the cross-validation step to make the acceptance criteria independent of the variable magnitude. The number of data sub-windows, selected to train the models, should be always enough to ensure convergence in training.

3.3. Optimization

Subsequently, the agent takes the prevision results from the local environment models to plan its consumption strategy. As a follower, the MAS is not fully observable because other agents' actions are not deterministic and exogenous events affect their strategies. Under these circumstances, it is unfeasible for the residential agent to parametrize the MAS. Alternatively, its best option is to trust the price signals that it receives. Under this choice, the agent's consumption plan is done with certainty and the only decision variable is the energy demand of the controllable loads. Such consumption strategy can be favored as the best action according to all the available information [27]. It should be pointed out that the prevision tasks of modeling and data acquirement should be carried out once per market period. Nevertheless, the planning problem must be solved at each iteration of the negotiation process.

The optimization problem for the residential agent is formulated in Eq. (8). The objective is to maximize the individual welfare as the difference between the utility, U_t , that the user perceives from consuming energy, and the cost, C_t , that it has to pay in return. The utility from uncontrollable loads does not shift the solutions, and thus U_t is a function of only $P_{cl,t}$. The cost function is a piecewise affine function depending on whether the agent is buying or selling energy. Usually, the buying price, π_t , is higher than the selling price,

λ_t , to remunerate the grid usage [64]. Finally, the aggregator can only send π_t , and λ_t can be settled as a constant percentage of that. This problem is constrained by comfort restrictions and dynamics of controllable loads.

$$\widehat{\max}_{\widehat{P}_1, \dots, \widehat{P}_T} \sum_{t=1}^T U_t - C_t \quad (8)$$

$$C_t = \begin{cases} \pi_t \widehat{P}_t & \text{if } \widehat{P}_{g,t} \leq \widehat{P}_{f,t} + P_{cl,t} \\ -\lambda_t \widehat{P}_t & \text{if } \widehat{P}_{g,t} > \widehat{P}_{f,t} + P_{cl,t} \end{cases} \quad (9)$$

The utility function depends on the controllable load and it must be concave. Furthermore, the utility function can be a function of either $P_{cl,t}$ or derived variables. For instance, U_t can be represented as a function of household internal temperature or the state of charge of batteries when controlling heating systems or electric vehicles, respectively. In the problem formulation, the significance of the utility function in comparison with the cost, C_t , reflects the user's price-elasticity. Therefore, the utility function often has a scale parameter that is tuned according to the user's preferences.

3.4. Local control

The local control of loads is not relevant to the anticipation tasks, but it can be usefully included in the agent's software architecture. In this behavior, the agent communicates with the drivers of controllable loads to follow the TE agreements. For this purpose, agents can integrate other models to adjust control actions with short-term forecast like time-series models of low computational cost [65]. Besides, this behavior can be expanded by other protocols to communicate with appliances.

3.5. Reconciliations

The estimated $\widehat{P}_{f,t}$ and $\widehat{P}_{g,t}$ can have errors due to the weather forecast and inner model inaccuracies. This results in deviations even if controllable loads are adjusted to follow exactly the TE agreement. Normally, energy contracts specify penalties for these kinds of deviations and involving regulations [66]. The reconciliation cost can be obtained right after the market period ends.

In power systems, some grid codes show that stability limits are not symmetric and thus, underestimating energy consumption can be cheaper than overestimating it for the grid operator. This effect can be translated to final consumers with different penalties for positive and negative deviations [67]. In this case, risk-averse agents can use previous reconciliation results to shift their consumption strategy and avoid higher penalties. However, this analysis considers risk-neutral agents whose best strategy is to communicate their estimates, \widehat{P}_t .

3.6. Communications

Finally, the residential agent needs a communication block to interact with other agents. It receives price signals and answers with the consumption strategy. The agent certainly needs to know the communication protocols, executed in lower levels of the smart grid. The schematic of the communications of the described MAS is presented in Fig. 6. The aggregator agent receives information from other higher-level agents or a market database (market DB) and communicates with the residential agents through a local server. The house DB represents the residential agents' primary knowledge.

4. Case studies

The implemented communication server uses the XMPP protocol to test the proposed TE configuration. The market period is 24 h. Energy and price signals are discretized in intervals of 5 min. The agents' behavior is programmed by using SPADE in python to make them asynchronous [68], and the optimization problems are addressed by using the solvers of SciPy [69].

For the residential agents, the utilized weather data corresponds to the conditions from 1st to February 5, 2018 in Trois-Rivières, QC. Regarding the residential agents' designs, the power generation is modeled by a feed-forward neural network with 100 neurons in five layers and a hyperbolic tangent as the activation function. The inputs of this model are the time of day, solar irradiance, wind speed, wind direction, cloud coverage, and external temperature. Besides, in order to forecast the consumption of uncontrollable loads, a Support Vector Machine (SVM) is used with a radial basis function as the kernel. In this case, the explanatory variables are a cosine signal with a 24 h period, the number of the days of the week (from 1 to 7), the external temperature, and the previous time interval consumption. In addition, the controllable load corresponds to a single-zone space heater. The dynamics of this load are modeled based on a linear function of its consumption, $P_{cl,t}$, and the external temperature, $\theta_{ext,t}$, as presented in Eq. (10). This model assumes that the current value of internal temperature, $\theta_{int,t}$, is linked to its previous one, $\theta_{int,t-1}$ [70]. The parameters α and β are obtained by the ordinary least-squares method and adapted through Algorithm 2 as the other models.

$$\widehat{\theta}_{int,t} = \alpha \theta_{ext,t} + (1 - \alpha) \theta_{int,t-1} + \beta P_{cl,t} \quad (10)$$

For this controllable load, the utility function is presented in Eq. (11). θ_{ref} is the internal temperature that maximizes the customer's comfort and obtained from the thermostat set-points. This utility function is concave because there are no monotone preferences for temperature. In other words, the utility is non-decreasing while the marginal benefit is non-increasing. It should be noted that zero consumption does not imply zero utility in this case [71]. The parameter δ represents the user's elasticity and is considered constant. It is used for weighting the utility with respect to the cost. Since the only heating source is electricity, the utility function does not consider cross-elasticity with other resources. When the agent is participating in more energy markets, it is necessary to expand the utility and cost terms to find an optimal integrated strategy for consumption [47].

$$U_t = -\delta \left(\widehat{\theta}_{int,t} - \theta_{ref} \right)^2 \quad (11)$$

The electrical heating system as controllable load adds two new constraints to the agents' planning problem. First, the consumption, $P_{cl,t}$, cannot exceed the technical limit of the space heater. Second, the final internal temperature must be equal to the initial one in order to start every market period from similar conditions and keep the optimal substructure of the problem. The constraints are presented in Eqs. (12) and (13). Nonetheless, the second constraint should be modified when using rolling horizons or discounted functions with infinite planning periods for other kinds of markets.

$$P_{cl,max} \geq P_{cl,t} \quad \forall t \quad (12)$$

$$\theta_0 = \theta_T \quad (13)$$

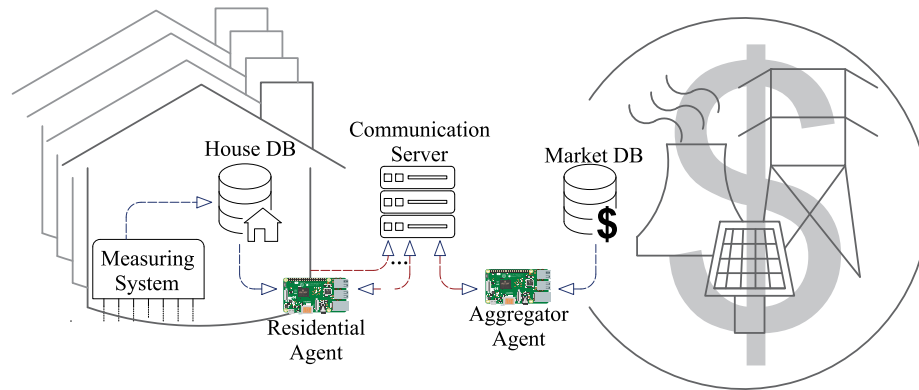


Fig. 6. Data network in a distribution circuit.

4.1. Five residential agents

The first case study contains five houses with the following devices:

- H1.** Controllable heating system, uncontrollable electrical loads, and solar PV array
- H2.** Controllable heating system, uncontrollable electrical loads, and solar PV array
- H3.** Uncontrollable electrical loads and solar PV array
- H4.** Controllable heating system and uncontrollable electrical loads
- H5.** Uncontrollable electrical loads

The proposed residential agent architecture with the mentioned load models is enough to overcome residential customers' heterogeneity because the models are trained to produce zero output when there is no data. The consumption data of uncontrollable electrical appliances corresponds to real measures, collected from houses in Trois-Rivières, QC, during the same period as weather data. The solar PV arrays and the heating systems have capacities of 10 kWp and 15 kW, respectively.

In order to apply a sensibility analysis to the parameter δ , all the agents are configured with the same constant value in this TE framework. This parameter only affects the houses with controllable loads and thus, H3 and H5 can be considered inflexible demand. On the other hand, given the convexity of the utility function for heating systems, there is a limited range where changing δ affects the cost of H1, H2, and H4. This range that depends on the parameters of the model (Eq. (10)) is subject to gradual changes from one market period to another because of the adaptive training.

Fig. 7 presents the results of internal temperature for one house with different values of δ where $\theta_{ref} = 21^\circ\text{C}$. A customer with high price-elasticity is represented by a low value of δ , which leads to higher deviations from the reference temperature. Such customer undergoes more temperature fluctuations to leverage low price periods by preheating.

The final agreed power demand for $\delta = 0.1$ is presented in Fig. 8. On the last day, the consumption increases due to low external temperature. According to the corresponding planning procedure, the total aggregated demand for the five days should be 2965.77 kW h and the PV surplus 15.38 kW h. Since the planning procedure results in a forward contract instead of a future one, the penalties for deviations should not be harsh for residential customers.

Fig. 9 presents the results related to the price signal based on $\delta = 0.1$. The unitary cost, UC , is \$0.04 and the initial cost is \$0.06. It can be understood that when the solar PV arrays are producing energy, the prices reduce in order to incentivize consumption. The iterations stop when the estimated PAR converges with a relative difference between consecutive iterations lower than 10^{-4} .

Table 2 summarizes the final peak-to-average ratios for different price-elasticities within five days. The gap between the actual value and the estimated PAR demonstrates the aggregator's need to improve its model of the residential agents' response. It should be noticed that a lower value of δ increases the peaks not only in the temperature but also in the consumption. However, customers with higher price-elasticities pay a lower final cost and have a bigger margin to adjust the load drivers in the real operation.

4.2. Seven residential agents

In the next step, two other houses are added to the initial case. These homes consist of uncontrollable appliances and controllable heating systems with the same capacity to examine their contributions to the system flexibility. The other conditions remain equal for the new arrangement. The aggregated energy use increases, but the demand profile has lower PAR. This is due to the new controllable loads contribution to flattening the profile. However, an individual price signal for each customer can be a better approach to shift the consumption when there are different kinds of controllable loads. The demand profile for $\delta = 0.1$ is presented in Fig. 10.

Similarly, the price signal has low values during solar PV production hours. The final cost increases for this case due to the new houses energy consumption. The revenue from the aggregation rate is the same in all cases. The price results for $\delta = 0.1$ are presented in Fig. 11. Furthermore, the entire results for cost and PAR are presented in Table 3.

4.3. Results analysis

The results, presented in Tables 2 and 3, show that elastic users managing controllable loads can reduce the operation cost of an energy system. In this case, users' elasticity is represented by the scaling parameter, δ , of the utility function. This representation is useful to formulate an optimization problem for balancing utility and energy cost in order to find a consumption strategy. The optimization is carried out by an automated agent that gets a forward contract. This, in turn, can simplify the participation of residential customers in energy markets and grant the rationality in the decision process to develop market-clearing mechanisms.

It is relevant to consider that users' elasticity can vary in time.




Fig. 7. Temperature conditions of the houses.




Fig. 8. Aggregated energy demand with five residential agents for $\delta = 0.1$




Fig. 10. Aggregated energy demand with seven residential agents for $\delta = 0.1$





Fig. 9. Negotiations results with five residential agents for $\delta = 0.1$

Table 2
Final Peak-to-Average ratio at different elasticities with five residential agents.

δ	Day 1	Day 2	Day 3	Day 4	Day 5	Cost [CAD]
0.0001	3.0953	3.7448	4.2460	2.3986	2.7348	119.0689
0.001	2.4247	1.9857	2.9140	1.5243	1.5081	120.6070
0.01	1.8471	1.5520	2.8390	1.2855	1.3470	120.8605
0.1	1.5828	1.3935	2.5551	1.2242	1.3407	125.1178

However, selecting an accurate value of elasticity to perform transactions is not a trivial task for automated agents. A possible solution is to allow users to express their preferences on comfort and cost continuously in order to adapt the problem formulation.

Besides, the results of controlling electric heating systems show that a more elastic users bear bigger fluctuations in temperature. Thus, it could be reasonable to add ramp restrictions into the optimization problem because these variations can reduce the lifespan of some heating systems [72].

Another problem existing in the literature, mentioned in Table 1, is the direct interaction between residential users and wholesale energy markets that causes difficulty in coordinating large energy systems. In the simulated transactions, it has been evidenced that residential agents can get contracts by interacting only with demand aggregators since they know the unitary cost of energy and their revenue cap. The advantage of forward contracts is the possibility of having demand estimates, in advance, to plan the system




Fig. 11. Negotiation results with seven residential agents for $\delta = 0.1$

Table 3
Final Peak-to-Average ratio at different elasticities with seven residential agents.

δ	Day 1	Day 2	Day 3	Day 4	Day 5	Cost [CAD]
0.0001	3.0544	3.2389	4.1896	2.3787	2.6406	186.0821
0.001	2.3888	1.9023	2.8923	1.3180	1.4777	187.6408
0.01	1.7408	1.4152	2.6069	1.2800	1.3426	190.3280
0.1	1.5358	1.3744	2.4661	1.2093	1.3400	191.2978

operation towards coordinating several energy markets. Moreover, the historical information about these contracts can be useful to do long-term planning and ensure the adequacy of the resources.

In the aggregator side, there is an estimation error that results in a miscalculation of the PAR as it can be seen in the part b of Figs. 9 and 11. A part of this problem relates to the assumption that P_t is a function of only the instant price π_t . Such situation can be solved by using reinforcement learning techniques that parametrize the residential agents' responses better. One interesting result, useful to improve the aggregator agent's models, is that the convergence rate does not rely on the number of flexible resources. The fact that the price signal is unique for all residential customers can lead to a Prisoner's Dilemma (PD) because it shifts all the flexible resources to consume on the same low price periods.

4.4. Limitations and application opportunities

The proposed agent architecture can be expanded to transact commodities other than active energy. The residential agent needs more models of devices in its local environment to forecast their consumption and know their controllable potentials. However, the general formulation of the optimization problem remains the same (balancing users' utility and energy cost). For the aggregator agent, it is necessary to include other optimization blocks because flattening the demand profile is not of interest to all energy markets. In such a case, it is advantageous to use asynchronous behavior to support multi-objective optimization. This results in agent architectures that contribute to the development of smart energy systems and allow for the integrated operation of all energy grids, involved in the residential sector.

The interaction protocol, presented in this paper, is sequential to ensure the participation of all residential agents. This configuration is suitable for forward-markets but limits the application to other markets such as spot markets where clearing time is crucial. Additionally, the proposed protocol is not intended to permit the communication between the residential agents because it is expected that the aggregator makes the coordination. In future work, it is interesting to analyze the potentials of this interaction protocol to use individualized price signals and avoid PD.

In the above cases, it has been assumed that the system is able to absorb all imbalances because the adequacy of energy resources is out of the scope of this paper. In fact, for addressing this matter, the aggregator agent needs to communicate with higher-level agents in the wholesale market to get an estimate of the unitary cost of energy beforehand. However, the operation of a large energy system ultimately depends on the ensemble of small coordinated systems.

Finally, it is important to mention that the COVID-19 pandemic hastens application opportunities for technologies that engage the residential sector in TE systems. In fact, lockdown measures have increased the energy demand of houses [73]. Even after economic recovery, the residential sector electricity demand is expected to remain higher than before the pandemic [74].

5. Conclusions

In recent years, transactive energy systems have been developed to allow different kinds of grid agents to trade active energy among other services. These systems help retailers and utility companies refine and automate their information process and decision algorithms. Nevertheless, demand-side agents requirements, especially in the residential sector, have not been properly contemplated and their decision-making process has been overlooked. Therefore, it is important to develop automated systems that make decisions and participate in transactive mechanisms on behalf of residential customers. Particularly, the anticipation tasks of prevision and planning must be automated to engage customers into forward-markets.

In this paper, the proposed planning algorithm for residential agents has been implemented through an agent architecture with six behavior. This architecture can be conveniently integrated into a multi-agent system to leverage transactive energy mechanisms and advance towards fully decentralized smart energy systems. Besides, the adaptability character of the proposed architecture allows for overcoming the heterogeneity of residential customers. The developed planning algorithm can be used with different models of controllable and uncontrollable appliances and expanded to participate in other energy markets.

To integrate the residential agent architecture into a transactive energy system, we have presented an interaction protocol to reach equilibrium in a Stackelberg game with a demand aggregator as the leader. This protocol is sequential to ensure all agents participate in the transactions and contract energy for the market period. The suggested strategy for managing the energy system can contribute to scaling market solutions and help analyze complex systems as an ensemble of small coordinated systems. The proposal has been tested by using simulated transactions and actual data of household appliances and electric heating systems, as controllable loads,

during winter period. The results have demonstrated that the flexibility of residential resources strongly depends on users' valuations of comfort.

Declaration of competing interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

Acknowledgments

The authors would like to thank the Laboratoire des technologies de l'énergie d'Hydro-Québec, the Natural Science and Engineering Research Council of Canada, and the Foundation of Université du Québec à Trois-Rivières.

References

- [1] Stram BN. Key challenges to expanding renewable energy. *Energy Pol* 2016;96:728–34. <https://doi.org/10.1016/j.enpol.2016.05.034>.
- [2] Lund H, Østergaard PA, Connolly D, Mathiesen BV. Smart energy and smart energy systems. *Energy* 2017;137(May):556–65. <https://doi.org/10.1016/j.energy.2017.05.123>.
- [3] Bublitz A, Keles D, Zimmermann F, Fraunholz C, Fichtner W. A survey on electricity market design: insights from theory and real-world implementations of capacity remuneration mechanisms. *Energy Econ* 2019;80:1059–78. <https://doi.org/10.1016/j.eneco.2019.01.030>.
- [4] Abrishambaf O, Lezama F, Faria P, Vale Z. Towards transactive energy systems: an analysis on current trends. *Energy Strategy Reviews* 2019;26:100418. <https://doi.org/10.1016/j.esr.2019.100418>.
- [5] Divshali PH, Choi BJ, Liang H. Multi-agent transactive energy management system considering high levels of renewable energy source and electric vehicles, IET Generation, Transm Distrib 2017;11(15):3713–21. <https://doi.org/10.1049/iet-gtd.2016.1916>.
- [6] Marzband M, Fouladfar MH, Akorede MF, Lightbody G, Pouresmaeil E. Framework for smart transactive energy in home-microgrids considering coalition formation and demand side management. *Sustainable Cities and Society* 2018;40(January):136–54. <https://doi.org/10.1016/j.scs.2018.04.010>.
- [7] Nizami MSH, Hossain MJ, Fernandez E. Multiagent-based transactive energy management systems for residential buildings with distributed energy resources. *IEEE Transactions on Industrial Informatics* 2020;16(3):1836–47. <https://doi.org/10.1109/TII.2019.2932109>.
- [8] Gallo G. Electricity market games: how agent-based modeling can help under high penetrations of variable generation. *Electr J* 2016;29(2):39–46. <https://doi.org/10.1016/j.tej.2016.02.001>.
- [9] Liang Y, Wei W, Wang C. A generalized Nash equilibrium approach for autonomous energy management of residential energy hubs. *IEEE Transactions on Industrial Informatics* 2019;15(11):5892–905. <https://doi.org/10.1109/TII.2019.2907714>.
- [10] Good N, Martínez Ceseña EA, Heltoer C, Mancarella P. A transactive energy modelling and assessment framework for demand response business cases in smart distributed multi-energy systems. *Energy* 2018. <https://doi.org/10.1016/j.energy.2018.02.089>.
- [11] Khorasany M, Mishra Y, Ledwich G. Auction based energy trading in transactive energy market with active participation of prosumers and consumers, 2017 Australasian Universities Power Engineering Conference. AUPEC 2017 2017–November 2018:1–6. <https://doi.org/10.1109/AUPEC.2017.8282470>.
- [12] Yaghmaee Moghaddam MH, Leon-Garcia A. A fog-based internet of energy architecture for transactive energy management systems. *IEEE Internet of Things Journal* 2018;5(2):1055–69. <https://doi.org/10.1109/JIOT.2018.2805899>.
- [13] Huang Q, McDermott TE, Tang Y, Makhmalbaf A, Hammerstrom DJ, Fisher AR, Marinovici LD, Hardy T. Simulation-based valuation of transactive energy systems. *IEEE Trans Power Syst* 2019;34(5):4138–47. <https://doi.org/10.1109/TPWRS.2018.2838111>.
- [14] Hanumantha Rao B, Arun SL, Selvan MP. An electric power trading framework for smart residential community in smart cities. *IET Smart Cities* 2019;1(2):40–51. <https://doi.org/10.1049/iet-smc.2019.0055>.
- [15] Burger S, Chaves-Ávila JP, Batlle C, Pérez-Arriaga IJ. A review of the value of aggregators in electricity systems. *Renew Sustain Energy Rev* 2017;77(February 2016):395–405. <https://doi.org/10.1016/j.rser.2017.04.014>.
- [16] Janko SA, Johnson NG. Scalable multi-agent microgrid negotiations for a transactive energy market. *Appl Energy* 2018;229(July):715–27. <https://doi.org/10.1016/j.apenergy.2018.08.026>.
- [17] Rasheed MB, Javaid N, Arshad Malik MS, Asif M, Hanif MK, Chaudary MH. Intelligent multi-agent based multilayered control system for opportunistic load scheduling in smart buildings. *IEEE Access* 2019;7:23990–4006. <https://doi.org/10.1109/ACCESS.2019.2900049>.
- [18] Safdarian A, Fotuhi-Firuzabad M, Lehtonen M. A distributed algorithm for managing residential demand response in smart grids. *IEEE Transactions on Industrial Informatics* 2014;10(4):2385–93. <https://doi.org/10.1109/TII.2014.2316639>.
- [19] Nunna HS, Srinivasan D. Multiagent-based transactive energy framework for distribution systems with smart microgrids. *IEEE Transactions on Industrial Informatics* 2017;13(5):2241–50. <https://doi.org/10.1109/TII.2017.2679808>.
- [20] Zhou Y, Wu J, Long C. Evaluation of peer-to-peer energy sharing mechanisms based on a multiagent simulation framework. *Appl Energy* 2018;222(February):993–1022. <https://doi.org/10.1016/j.apenergy.2018.02.089>.
- [21] Alam MR, St-Hilaire M, Kunz T. Peer-to-peer energy trading among smart homes. *Appl Energy* 2019;238(December 2018):1434–43. <https://doi.org/10.1016/j.apenergy.2019.01.091>.
- [22] Liu Z, Wu Q, Ma K, Shahidepour M, Xue Y, Huang S. Two-stage optimal scheduling of electric vehicle charging based on transactive control. *IEEE Transactions on Smart Grid* 2019;10(3):2948–58. <https://doi.org/10.1109/TSG.2018.2815593>.
- [23] El-Baz W, Tzschentschler P, Wagner U. Integration of energy markets in microgrids: a double-sided auction with device-oriented bidding strategies. *Appl Energy* 2019;241:625–39. <https://doi.org/10.1016/j.apenergy.2019.02.049>.
- [24] Chen T. Understanding deregulated retail electricity markets in the future: a perspective from machine learning and optimization. Ph.D. thesis. University of Michigan-Deaborn; 2018.
- [25] Yu M, Hong SH. A real-time demand-response algorithm for smart grids: a Stackelberg game approach. *IEEE Transactions on Smart Grid* 2016;7(2):879–88. <https://doi.org/10.1109/TSG.2015.2413813>.
- [26] Fiez T, Chasnov B, Ratliff LJ. Convergence of learning dynamics in Stackelberg games. *arXiv.org*. 1–26arXiv:1906.01217, <http://arxiv.org/abs/1906.01217>; 2019.
- [27] Gibbons R. *Game theory for applied economists*. New Jersey: Princeton University Press; 1992.
- [28] Li S, Lian J, Conejo A, Zhang W. Transactive energy system: market-based coordination of distributed energy resources. *arXiv.org* (aug 2019). *arXiv:1908.03641*, <http://arxiv.org/abs/1908.03641>.
- [29] Adhikari R, Pipattanasomporn M, Kuzlu M, Bradley SR. Simulation study of transactive control strategies for residential HVAC systems. *IEEE PES Innovative Smart Grid Technologies Conference Europe 2016:1–5*. <https://doi.org/10.1109/ISGTEurope.2016.7856240>.
- [30] Buffo G, Marocco P, Ferrero D, Lanzini A, Santarelli M. Power-to-X and power-to-power routes. In: *Solar hydrogen production, elsevier*; 2019. p. 529–57. <https://doi.org/10.1016/B978-0-12-814853-2.00015-1>.
- [31] McKenna K, Keane A. Residential load modeling of price-based demand response for network impact studies. *IEEE Transactions on Smart Grid* 2016;7(5):2285–94. <https://doi.org/10.1109/TSG.2015.2437451>.
- [32] Gama J, Zlobaitė I, Bifet A, Pechenizkiy M, Bouchachia A. A survey on concept drift adaptation. *ACM Comput Surv* 2013;1(1). <https://doi.org/10.1145/2523813>.
- [33] Tesfatsion L. Electric power markets in transition: agent-based modeling tools for transactive energy support. In: *Handbook of computational economics*, vol. 4. Elsevier B.V.; 2018. p. 715–66. <https://doi.org/10.1016/b.s.hescom.2018.02.004>.
- [34] GridWise Architecture Council. *GridWise transactive energy framework*. GridWise Architecture Council on Transactive Energy 2019;1(1):1–23.
- [35] Melton R. *Transactive energy - automated use of demand side resources to help grid operations*. Tech. Rep. May. Pacific Northwest National Laboratory; 2016.
- [36] Cong P, Li L, Zhou J, Cao K, Wei T, Chen M, Hu S. Developing user perceived value based pricing models for cloud markets. *IEEE Trans Parallel Distr Syst* 2018;29(12):2742–56. <https://doi.org/10.1109/TPDS.2018.2843343>.
- [37] Odell J, Giorgini P, Müller J. *Agent-oriented software engineering V.* heidelberg: springer berlin; 2004.
- [38] Duan G, Dong Z, Wang X. Composite auction method for suppressing unreasonable electricity price spikes in a competitive electricity market. *IEE Proc Generat Transm Distrib* 2005;152(4):460. <https://doi.org/10.1049/ip-gtd:20045055>.
- [39] Li S. *Transactive control for large-scale cyber-physical systems*. Ph.D. thesis. The Ohio State University; 2017.
- [40] Lezama F, Soares J, Hernandez-Leal P, Kaisers M, Pinto T, Vale Z. Local energy markets: paving the path toward fully transactive energy systems. *IEEE Trans Power Syst* 2019;34(5):4081–8. <https://doi.org/10.1109/TPWRS.2018.2833959>.
- [41] Usilar M, Rohjans S, Neureiter C, André FP, Velasquez J, Steinbrink C, Efthymiou V, Migliavacca G, Horsmanheimo S, Brunner H, Strasser TL. Applying the smart grid architecture model for designing and validating system-of-systems in the power and energy domain: a European perspective. *Energy* 2019;12(2). <https://doi.org/10.3390/en12020258>.
- [42] Hu J, Yang G, Kok K, Xue Y. Transactive control : a framework for operating power systems characterized by high penetration of distributed energy resources. *Journal of Modern Power Systems and Clean Energy* 2017;5(3):451–64. <https://doi.org/10.1007/s40565-016-0228-1>.
- [43] Bienert R, Herberg U, Zuber J, Mashima D. *OpenADR 2.0 - profile specification B* profile, tech. Rep., OpenADR alliance. <https://www.openadr.org/specification>; 2015.

- [44] Zhang Y, Krishnan VV, Pi J, Kaur K, Srivastava A, Hahn A, Suresh S. Cyber physical security analytics for transactive energy systems. *IEEE Transactions on Smart Grid* 2020;11(2):931–41. <https://doi.org/10.1109/TSG.2019.2928168>.
- [45] International Energy Agency (IEA). World energy balances: overview, tech. Rep. Paris: IEA; 2020. <https://www.iea.org/reports/world-energy-balances-overview>.
- [46] Lund H, Werner S, Wiltshire R, Svendsen S, Thorsen JE, Hvelplund F, Mathiesen BV. 4th generation district heating (4GDH). *Energy* 2014;68:1–11. <https://doi.org/10.1016/j.energy.2014.02.089>. <https://linkinghub.elsevier.com/retrieve/pii/S0360544214002369>.
- [47] Sorknæs P, Lund H, Skov IR, Djørup S, Skytte K, Morthorst PE, Fausto F. Smart Energy Markets - future electricity, gas and heating markets. *Renew Sustain Energy Rev* 2019;119(March 2019). <https://doi.org/10.1016/j.rser.2019.109655>.
- [48] Fraija A, Agbossou K, Henao N, Kelouwani S. Peak-to-Average ratio analysis of A load aggregator for incentive-based demand response. In: 2020 IEEE 29th international symposium on industrial electronics (ISIE), IEEE; 2020. p. 953–8. <https://doi.org/10.1109/ISIE45063.2020.9152474>.
- [49] Sutton R, Barto A. Reinforcement learning an introduction. Cambridge, Massachusetts: The MIT Press; 2018.
- [50] Kounelis I, Steri G, Giuliani R, Geneiatakis D, Neisse R, Nai-Fovino I. Fostering consumers' energy market through smart contracts. *Energy and Sustainability in Small Developing Economies, ES2DE 2017 - Proceedings 2017*;5. <https://doi.org/10.1109/ES2DE.2017.8015343>.
- [51] Mahmoodi M, Shamsi P, Fahimi B. Economic dispatch of a hybrid microgrid with distributed energy storage. *IEEE Transactions on Smart Grid* 2015;6(6):2607–14. <https://doi.org/10.1109/TSG.2014.2384031>.
- [52] Ling RF. Comparison of several algorithms for computing sample means and variances. *J Am Stat Assoc* 1974;69(348):859–66. <https://doi.org/10.1080/01621459.1974.10480219>.
- [53] Glimcher P, Fehr E. *Neuroeconomics: decision making and the brain*. second ed. Edition, vol. 63. London: Elsevier; 2014. <https://doi.org/10.1016/j.neuron.2009.07.005>.
- [54] Nagi K. *Transactional agents: towards a robust multi-agent system*. Karlsruhe, Germany: Springer Berlin Heidelberg; 2001.
- [55] Shehory O, Sturm A. *Agent-oriented software engineering. Reflections on architectures, methodologies, languages, and frameworks*. New York: Springer Berlin Heidelberg; 2014.
- [56] Doksaeter Sivle A, Kolstø SD. Use of online weather information in everyday decision-making by laypeople and implications for communication of weather information. *Meteorol Appl* 2016;23(4):650–62. <https://doi.org/10.1002/met.1588>.
- [57] Malkiel B. *A random walk down wall street*, norton, New York, New York, USA. 1973.
- [58] Bifet A, Gavaldà R, Holmes G, Pfahringer B. *Machine learning for data streams: with practical examples in MOA*. Cambridge, Massachusetts: The MIT Press; 2018. <https://moa.cms.waikato.ac.nz/book-html/>.
- [59] Kolajo T, Daramola O, Adebisi A. Big data stream analysis: a systematic literature review. *Journal of Big Data* 2019;6(1):47. <https://doi.org/10.1186/s40537-019-0210-7>.
- [60] Gaonkar P, Bapat J, Das D. Location-aware multi-objective optimization for energy cost management in semi-public buildings using thermal discomfort information. *Sustainable Cities and Society* 2018;40(May 2017):174–81. <https://doi.org/10.1016/j.scs.2017.12.021>.
- [61] Zliobaite I. *Adaptive training set formation*. Ph.D. thesis. Vilnius University; 2010.
- [62] Toquica D, Agbossou K, Malhamé R, Henao N, Kelouwani S, Cardenas A. Adaptive machine learning for automated modeling of residential prosumer agents. *Energies* 2020;13(9):2250. <https://doi.org/10.3390/en13092250>.
- [63] Aggarwal CC, Hinneburg A, Keim DA. On the surprising behavior of distance metrics in high dimensional space. In: *American journal of Dermatopathology*, vol. 30. Springer Link; 2001. p. 420–34. https://doi.org/10.1007/s-540-44503-X_27.
- [64] De Castro L, Dutra J. Paying for the smart grid. *Energy Econ* 2013;40:S74–84. <https://doi.org/10.1016/j.eneco.2013.09.016>.
- [65] Nazariyouya H, Wang B, Wang Y, Chu P, Pota HR, Gadh R. Univariate time series prediction of solar power using a hybrid wavelet-ARMA-NARX prediction method. In: *Proceedings of the IEEE power engineering society transmission and distribution conference 2016-july*; 2016. p. 1–5. <https://doi.org/10.1109/TDC.2016.7519959>.
- [66] Gu C, Yuan C, Li F, Song Y. Risk management in use-of-system tariffs for network users. *IEEE Trans Power Syst* 2013;28(4):4683–91. <https://doi.org/10.1109/TPWRS.2013.2277962>. <http://ieeexplore.ieee.org/document/6584815/>.
- [67] Merino J, Mendoza-Araya P, Veganzones C. State of the art and future trends in grid codes applicable to isolated electrical systems. *Energies* 2014;7(12):7936–54. <https://doi.org/10.3390/en7127936>.
- [68] Palanca J, Terrasa A, Julian V, Carrascosa C. SPADE 3: supporting the new generation of multi-agent systems. *IEEE Access* 2020;8:182537–49. <https://doi.org/10.1109/ACCESS.2020.3027357>.
- [69] Virtanen P, Gommers R, Oliphant TE, Haberland M, Reddy T, Cournapeau D, Burovski E, son P, Weckesser W, Bright J, van der Walt SJ, Brett M, Wilson J, Millman KJ, Mayorov N, Nelson ARJ, Jones E, Kern R, Larson E, Carey C, Polat I, Feng Y, Moore EW, VanderPlas J, Laxalde D, Perktold J, Cimrman R, Henriksen I, Quintero EA, Harris CR, Archibald AM, Ribeiro AH, Pedregosa F, van Mulbregt P, Contributors S. *SciPy 1.0—fundamental algorithms for scientific computing in Python*, arXiv.org. 2019. p. 10121. 1–22arXiv:1907.
- [70] Li N, Chen L, Low SH. Optimal demand response based on utility maximization in power networks. In: 2011 IEEE power and energy society general meeting, IEEE; 2011. p. 1–8. <https://doi.org/10.1109/PES.2011.6039082>.
- [71] Samadi P, Mohsenian-Rad H, Schober R, Wong VW. Advanced demand side management for the future smart grid using mechanism design. *IEEE Transactions on Smart Grid* 2012;3(3):1170–80. <https://doi.org/10.1109/TSG.2012.2203341>.
- [72] Cheng Li, Li Zhenjiang, Li Mo, Meggers F, Schlueter A, Lim Hock Beng. Energy efficient hvac system with distributed sensing and control. In: 2014 IEEE 34th international conference on distributed computing systems, IEEE; 2014. p. 429–38. <https://doi.org/10.1109/ICDCS.2014.51>.
- [73] Cheshmehzangi A. COVID-19 and household energy implications: what are the main impacts on energy use? *Heliyon* 2020;6(10):e05202. <https://doi.org/10.1016/j.heliyon.2020.e05202>. <https://linkinghub.elsevier.com/retrieve/pii/S2405844020320454>.
- [74] International Energy Agency (Iea). Covid-19 impact on electricity, Tech. rep., IEA, Paris. <https://www.iea.org/reports/covid-19-impact-on-electricity>; 2021.

3.3 Intégration des préférences des utilisateurs

3.3.1 Contexte

Dans ce projet, on considère un système de chauffage comme la charge contrôlable de l'agent résidentiel. L'agent peut profiter des périodes de prix bas pour augmenter la consommation de chauffage et la réduire lorsque le prix n'est pas favorable. Puisque, sur le marché à terme, l'agent reçoit des prix pour un horizon défini et il est possible de planifier la consommation si on dispose d'un modèle de la dynamique thermique de la maison. Le modèle thermique utilisé dans cette étude a été établi à partir de données de consommation réelles dans la région du Québec, Canada.

Le chauffage a été choisi comme charge contrôlable dans ce projet, car il représente une part importante de la consommation résidentielle dans plusieurs pays [16]. De plus, la capacité thermique des maisons et des bâtiments permet de modifier la consommation de ces charges sans impacter fortement le confort des utilisateurs. Ces charges sont aussi relativement faciles à contrôler et à modéliser [99].

Toutefois, avant de modifier la consommation de chauffage, l'agent doit connaître les préférences thermiques de l'utilisateur afin de garantir un niveau de confort adéquat à tout moment. Si les préférences de l'utilisateur ne sont pas prises en compte, l'agent privilégie la minimisation des coûts à la maximisation du confort, ce qui conduit à une perte de bien-être pour l'utilisateur. C'est pourquoi il est nécessaire de développer une méthode qui permette à l'agent d'interroger les préférences de l'utilisateur et de les inclure dans le problème transactionnel.

3.3.2 Méthodologie

Pour inclure les préférences de l'utilisateur, on utilise un système de recommandation pour suggérer une évaluation du confort thermique dans le cas où l'utilisateur ne la communique pas à l'agent. Ce système est entraîné à partir des choix précédents effectués par l'utilisateur dans des conditions similaires. Cette approche n'empêche pas l'utilisateur d'imposer ses préférences lorsqu'il n'est pas d'accord avec la valeur suggérée. L'interaction entre l'utilisateur et le système de recommandation est présentée dans la Figure 3-3.

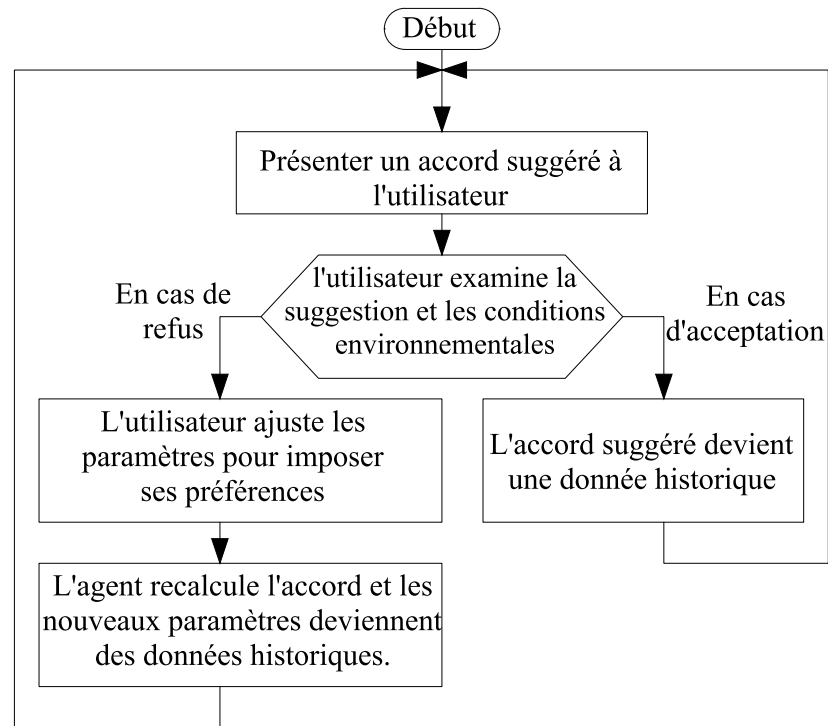


FIGURE 3-3 Interaction de l'utilisateur avec le système de recommandation

Le système de recommandation est basé sur un processus gaussien, car cette distribution s'est avérée utile pour modéliser des données de préférences [40]. Dans ce cas, le processus gaussien prend en compte des variables telles que la température extérieure et le prix moyen de l'électricité pour estimer les préférences en matière de confort thermique. L'utilisation de la moyenne comme valeur représentative est due à l'aspect pratique du calcul, mais il serait possible d'utiliser une autre mesure statistique qui donne une idée du comportement quotidien du prix et de la température. Un avantage des processus gaussiens est qu'ils conservent toutes les informations nécessaires à la connaissance de la distribution uniquement dans les matrices de moyenne et de covariance. De plus, pour ces processus, il existe des méthodes bien définies dans la littérature pour calculer l'estimateur du "maximum a posteriori" (MAP) [41]. En général, ces méthodes impliquent l'inversion d'une matrice de covariance. Dans ce cas, la décomposition de Cholesky est utilisée pour l'inversion car elle est plus efficace en termes de calcul que les méthodes traditionnelles pour les matrices définies positives [100].

En connaissant les décisions que l'utilisateur a prises précédemment pour différentes conditions, la première étape du système de recommandation consiste à entraîner le processus gaussien avec ces données. L'étape suivante consiste à déterminer quand l'estimateur MAP est une recommandation adéquate et quand il vaut la peine d'explorer d'autres options. Si l'utilisateur n'a pas exploré suffisamment de combinaisons température/coût, la recommandation peut diverger de la MAP à raison d'un écart type pour présenter une combinaison plus économique, compte tenu du fait que les préférences en matière de coûts sont strictement monotones. D'autre part, lorsque les moments du processus gaussien atteignent un état stationnaire (en considérant un certain seuil), le MAP devient une recommandation appropriée.

3.3.3 Résultats

La validation du système de recommandation a été effectuée en considérant les variables qui influencent la décision de l'utilisateur, telles que la volonté de payer, la température préférée, l'impatience et les conditions environnementales. Pour étudier les décisions des différents types d'utilisateurs, on a effectué une analyse de sensibilité sur ces variables. La décision prise par l'utilisateur est d'accepter ou non le plan de consommation proposé par l'agent, et de modifier l'évaluation du confort thermique s'il ne l'accepte pas.

Le système de recommandation proposé, basé sur un processus gaussien, a été comparé à d'autres techniques de recommandation bien connues telles que la méthode de persistance et les machines à vecteurs de support (SVM) [101]. Les résultats montrent que les recommandations de la méthode proposée ont un taux d'acceptation plus élevé, même pour les utilisateurs impatientes. Comme cas de contrôle, on a choisi un utilisateur ayant une haute propension à payer pour vérifier que les méthodes ne souffrent pas de surapprentissage.

A Recommender System for Predictive Control of Heating Systems in Economic Demand Response Programs

DAVID TOQUICA ¹, KODJO AGBOSSOU ¹ (Senior Member, IEEE), ROLAND MALHAMÉ ² (Fellow, IEEE),
NILSON HENAO ¹, SOUSSO KELOUWANI ³ (Senior Member, IEEE), AND MICHAËL FOURNIER ⁴

¹Department of Electrical and Computer Engineering, University of Quebec, Trois-Rivières, QC G8Z 4M3, Canada

²Department of Electrical Engineering, Polytechnique Montreal, Montreal, QC H3T 1J4, Canada

³Department of Mechanical Engineering, University of Quebec, Trois-Rivières, QC G8N 4M3, Canada

⁴Laboratoire des Technologies de l'énergie, Institut de Recherche Hydro-Québec, Shawinigan, QC G9N 7N5, Canada

CORRESPONDING AUTHOR: David Toquica (e-mail: david.camilo.toquica.cardenas@uqtr.ca)

ABSTRACT Flexibility from demand-side resources is increasingly required in modern power systems to maintain the dynamic balance between demand and supply. This flexibility comes from elastic users managing controllable loads. In this context, controlling Electric Space Heaters (ESHs) is of particular interest because it can leverage building inner thermal storage capacity to shift consumption while maintaining comfort conditions. Some economic Demand Response (DR) programs have considered exploiting ESHs flexibility potentials in recent years. However, these programs still struggle to engage customers due to the complexity of processing price signals for inexpert users. Therefore, it is necessary to develop automated tools for helping users to operate their loads. Accordingly, this paper presents a recommender system based on Gaussian processes to discover users' valuations of thermal comfort and perform the predictive control of their ESHs. The proposed method enables customers to participate in DR programs and impose their preferences through straightforward queries instead of directly changing control parameters. Validation results demonstrate that users maximize their utility by supplying noiseless and consistent data to the recommender system. Additionally, the suggested approach achieves a higher acceptance rate than other methods from the literature, such as persistency and support vector machines.

INDEX TERMS Heating systems, predictive control, preference learning, recommender system, utility maximization.

NOMENCLATURE

Acronyms

ESH	Electric space heater.
DR	Demand response.
GP	Gaussian process.
HMI	Human-machine interface.
MAP	Maximum a posteriori.
UX	User experience.
WTP	Willingness to pay.

Variables

c_t	Electricity cost at time t .
F	Scale factor of the thermal comfort valuation.

F_H	Set of n historical values of F .
$\mathbb{I}_{n \times n}$	Identity matrix of $n \times n$ dimension.
K	Covariance function.
P_t	Energy consumption of the ESH at time t .
P_{max}	Capacity of the ESH.
$P_{app,t}$	Consumption of household appliances at time t .
$P_{irr,t}$	Total solar irradiation at time t .
s	Consumption strategy.
T	Market period of t time slots.
u_t	User's utility at time t .
x_M	Set of average values of π and θ_{ext} for a market period.
X_H	Set of n historical average values of π and θ_{ext} .

δ_t	Form factor of the thermal comfort valuation at time t .
π_t	Electricity price at time t .
σ_H	Standard deviation of the components of X_H .
σ_M	Standard deviation of the estimation of F .
σ_n	Standard deviation of the noise in F_H .
θ_t	House indoor temperature at time t .
θ_{ref}	User's preferred temperature.
$\theta_{ext,t}$	Outdoor temperature at time t .
φ_t	Thermal comfort valuation at time t .

I. INTRODUCTION

The world is experiencing an energy and technology transition driven by environmental, social, and economic concerns. One of the goals of this transition is to decarbonize electric power generation by integrating renewable resources. However, it becomes challenging to keep the dynamic balance of the grid counting with these resources due to their intermittent and stochastic nature. Therefore, it is crucial to increase the flexibility of power systems to absorb imbalances and maintain reliable, resilient, and secure energy supply [1]. Flexibility can come from different sources like Demand Response (DR) programs, fast generation ramping, grid reconfigurations, and energy storage systems [2].

The interest in flexibility from DR programs is encouraged by the adoption of new smart technologies, especially in the residential sector [3]. This sector is also a huge energy consumer in many countries, and modifying its demand patterns can significantly improve the system operation. Accordingly, different DR programs have emerged to manage residential sector loads such as electric vehicles, Electric Water Heaters, Air-Conditioners, and Electric Space Heaters (ESHs) [4], [5]. Some of these programs have also incorporated energy storage systems to shift the demand without compromising the comfort [6]. In this regard, ESHs are advantageous since they can use building inner thermal energy storage to provide flexibility.

According to the International Energy Agency, ESHs can become a major source of flexibility in many regions [7]. Such opportunity has stimulated regulators to develop codes and standards for electrifying space heaters and accelerating the adoption of smart technologies. However, it is still necessary to engage customers and show them the economic advantages of providing flexibility with their ESHs. Some barriers to having more participants in DR programs are the lack of customers' knowledge, the technology cost, and the response fatigue [8]. In order to address these problems, it is suitable to automate the customers' decision process rather than take direct control of their loads. However, the automation is not simple since each customer has a different valuation of comfort and experiences various conditions.

A. RELATED WORKS

It is desirable to focus the DR programs on customers' preferences to avoid imposing conditions and to make the

control actions more welcomed. In this context, the convenience of recommender systems for engaging residential customers into DR programs has been explored in the literature [18]. Indeed, recommendations can facilitate users' interactions with automated systems and help discover better consumption strategies. Previous findings on the application of recommender systems for residential energy management are listed in Fig. 1. Those applications highlight the challenge of collecting data from inconsistent user inputs even when they act rationally with stable and monotone preferences. This situation is due to noisy drivers like impatience, comfort bias, privacy concerns, and misperceptions. Accordingly, recommender systems have to build training datasets aiming to improve both the accuracy and serendipity of the suggestions [19].

For the specific case of ESHs, recommender systems have been used to aggregate energy consumption and infer thermal comfort perception [20]. A common technique for these recommenders is collaborative filtering that collects data from several users before suggesting control actions. These filters can identify average preferences and cluster customers, so they are suitable for office buildings or groups of residences [21]. However, these techniques are not aware of the specific context of each customer. Beyond that, they do not examine the effect of individual preferences on elastic consumption, which is crucial for customizing DR programs.

Aside from recommender systems, other strategies to include users' preferences into ESH control require querying customers directly about specific parameters. For active learning strategies, the control algorithm queries the customer when it faces unknown conditions and uses Bayesian updates to discover absolute preferences [22]. Then, customers must know their willingness to pay (WTP), parametrize their demand curves, and define temperature comfort limits explicitly for answering the queries and participating in DR programs. These scenarios are not practical to promote DR programs among inexpert customers. Moreover, direct queries are not handy for automating ESHs control since they do not tend to reduce annoyance [23].

There exist also approaches that infer occupancy instead of preferences to consider human-in-the-loop in ESHs control [24]. These intrusive methods require several sensors to detect occupancy and model customers' behavior. Avoiding user queries makes it hard for the modeling process since finding all variables that affect user behavior is not easy, and general assumptions result in low accuracy predictions. [25]. Furthermore, control of heating systems based on occupancy measurements becomes reactive and unsuitable for planning DR programs [26].

B. PAPER CONTRIBUTIONS

This paper presents a recommender system that suggests adequate thermal comfort valuations for practical participation in economic DR programs. The recommender can be seen as a regressor in a supervised machine learning framework that takes previous users' inputs to predict their preferences

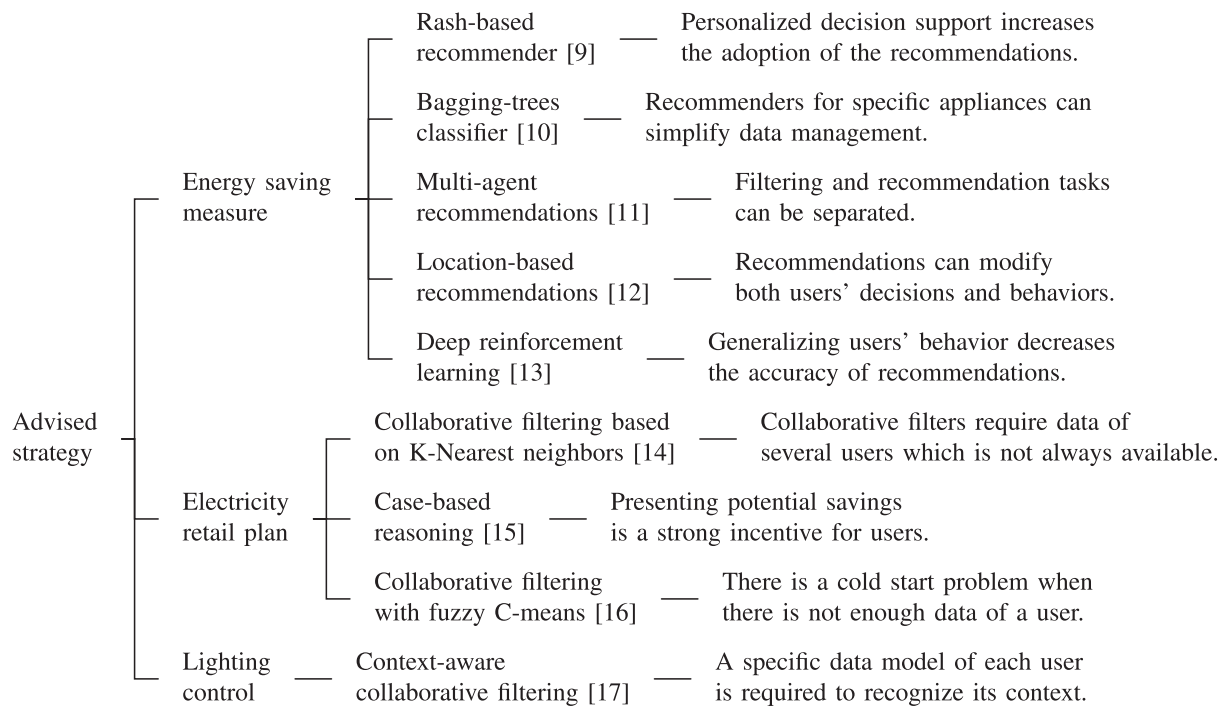


FIGURE 1. Findings of previous applications of recommender systems in home energy management systems.

TABLE 1 Characteristics of the Human-in-The-Loop Control Schemes for Residential ESHs

Approach	Allow customers to impose decisions	Suitable for inexpert customers	Non-intrusive	Context-aware	Helps reducing queries (annoyance)
Comfort assumption [28]		✓	✓		✓
Direct queries [29]	✓		✓	✓	
Occupancy modelling [26]		✓		✓	✓
Collaborative filtering [20]		✓	✓		✓
Active learning [22]	✓	✓	✓	✓	
Proposed approach	✓	✓	✓	✓	✓

in future conditions [27]. In the proposed method, users can accept or adjust the suggestions before automated control mechanisms take action. The human intervention is reduced in the long run as the recommender system learns users' preferences. Furthermore, the recommender presents user-friendly information, making it easy for the users to impose their preferences when they disagree with the suggestions. In this way, the recommender learns the specific context of a customer without querying for complex data or using intrusive methods. The features of the proposed approach are summarized in Table 1.

The proposed recommender system is integrated into a predictive control technique for the ESHs to participate in economic DR programs. This technique is based on a thermal dynamics model to verify the feasibility of consumption strategies. Previous studies have proved the feasibility of employing discrete-time linear models to represent thermal load dynamics, even in multi-zone buildings [30]. Considering the matters discussed concerning the proposed recommender system, the contributions of this paper can be summarized as follows:

- The design of a recommender system that helps customers complete the information of a predictive control scheme for ESHs. The system does not impose constraints but adapts the control mechanism to the users' context without intrusive methods. The recommendations are made over the weights of a payoff function, which reflects thermal comfort valuations and users' price-elasticity. The developed method builds on Gaussian process assumptions to update user preferences when they provide new information.
- A straightforward querying method based on the generalized optimal-choice axiom to retrieve preference information from inexpert users. The proposed method deploys user-friendly information for customers to compare similar options when making decisions. Then, they can directly modify the parameters of an ESH control mechanism and participate in DR programs. At the same time, they improve the recommender system training with relevant feedback. In contrast with the active-learning methods, users are not committed to providing information for each new DR condition.

C. PAPER ORGANIZATION

The rest of the paper is organized as follows: Section II presents the model-based predictive control formulation and the effects of user preferences on DR programs. Section III describes the recommender system, developed for the specific case of ESHs, and the characteristics of the queries to the users. Section IV discusses the case study and the validation method, followed by the concluding remarks in Section V.

II. MODEL-BASED PREDICTIVE CONTROL OF HEATING SYSTEMS

Economic DR programs send price signals to customers for relevant time windows [31]. Next, customers trust the information they receive and formulate their consumption strategy with certainty. This procedure allows for considering DR in planning and dispatching problems. Here, the DR configuration assumes no communication between residential customers, so their plans are not coordinated. For each customer, the consumption strategy s^* attempts to maximize the individual utility as the difference between customer benefit (thermal comfort) and electricity cost, as presented in (1). The decision variables correspond to the consumption at each time slot.

$$s^* = \operatorname{argmax}_{P_1, P_2, \dots, P_T} \sum_{t=1}^T (u_t - c_t) \quad (1)$$

$$\text{s.t. : } 0 \leq P_t \leq P_{max} \quad \forall t \quad (2)$$

$$\theta_0 = \theta_T \quad (3)$$

where for t time slots, u_t is the benefit perceived from P_t energy consumption, and c_t is the energy cost. T is the market period and P_{max} is the capacity of the ESH system. The final temperature, θ_T must be equal to the initial condition, θ_0 to ensure the problem has an optimal substructure in the long run. The cost function, c_t with the known price signal, π_t is presented in (4) as a linear function since it is assumed there is no economy of scale for residential customers. The decision variable, P_t is continuous considering that the control signal can be modulated appropriately for thermostatically controlled heaters or heat pumps.

$$c_t = \pi_t P_t \quad (4)$$

It should be noted that the utility function, u_t is concave because there are no monotone preferences in temperature [32]. This function is not directly related to consumption but the actual temperature of the indoor air mass, θ_t . In fact, there is an optimal temperature, θ_{ref} that maximizes users' comfort so that the utility is proportional to the deviation from that reference, as presented in (5). The factor, φ_t encompasses the user's arc price-elasticity to weight the user's utility against the cost.

$$u_t = -\varphi_t (\theta_{ref} - \theta_t)^2 \quad (5)$$

In order to relate u_t to the consumption, it is necessary to include the thermal dynamic model of the system. For a




FIGURE 2. Agreed cost as a function of the thermal comfort valuation.

single-zone structure, the dynamic response is similar to an RC circuit as described in the standard ISO 52016 [33]. In discrete-time, the thermal model is reduced to the state-space equation, (6), where $\theta_{ext,t}$ is the external temperature, $P_{irr,t}$ is the total solar irradiation, and $P_{app,t}$ is the energy consumption of other appliances in the house. The coefficients $\alpha_1, \alpha_2, \beta_1, \beta_2, \beta_3$ can be found with a least-squares method and updated adaptively when new measurements are available. For multi-zone buildings it is necessary to include the heat transfer coefficients between zones [34].

$$\theta_t = \alpha_1 \theta_{ext,t} + \alpha_2 \theta_{t-1} + \beta_1 P_{irr,t} + \beta_2 P_{app,t} + \beta_3 P_t \quad (6)$$

The constraint in (3) can be relaxed to preserve the tractability of the problem, considering that the optimization problem has the form of a linear quadratic regulator with this thermal model. Next, to perform predictive control, it is necessary to acquire the forecasts for $\theta_{ext,t}$ and P_{irr} from external information services. Likewise, it is required to either make a forecast for $P_{app,t}$, or gather such information from other smart controllers in the house if available. All the forecasted variables used to develop the consumption strategy represent a source of error. However, assuming a well-designed DR mechanism, it is reasonable to formulate a risk-neutral consumption strategy relying on the expected values of the forecasted variables. [35].

Finally, the factor φ_t of the utility function must be set according to the customer preferences. In this case, the choice of this factor is automated by the recommender system taking into account the historical user choices. However, in the automation, it is crucial to consider that the control problem formulation imposes limits on this factor where its increase or decrease does not change the final cost, as shown in Fig. 2. The cost is maximum when the indoor temperature is equal to the reference θ_{ref} , and it cannot be zero due to the constraint in (3). The curve in Fig. 2 can be stretched or contracted depending on the parameters of the thermal model.

III. RECOMMENDER SYSTEM

Given the configuration of the economic DR mechanisms, residential customers cannot collect data from their peers. This




FIGURE 3. Basic components of the user interface.

also preserve their data privacy. Thus, they cannot implement collaborative filtering techniques to obtain values for φ_t [36]. Consequently, the option is to implement a content-based recommender considering only the previous choices of the same customer. The thermal comfort valuation φ_t is divided into a scale factor F and a form factor δ_t , as presented in (7), to capture context-aware preferences and intraday changes. The exponential transformation allows covering a wide range of values in compact numbers.

$$\varphi_t = e^{-F\delta_t} \quad (7)$$

Previous studies on ranking problems have shown that users' preferences fit Mallow's model because a customer tends to choose the same values under the same querying conditions [37]. Thus, that model is frequently used for distributions of ranked preferences with different distance metrics of the permutations. Following the same principle of Mallow's model (law of large numbers), the continuous parameter, F is modeled by a normal distribution, and the recommender system becomes a Gaussian Process (GP). The feasibility of modeling thermal preferences through a GP has been explored formerly in [38]. For δ_t , which changes during the day, it is convenient to set a profile in an interval between (0,1] to capture household occupancy information. This profile is also obtained from previous customer choices within similar days.

This content-based approach can face difficulties in the early stages when there is not enough data for training. Some solutions to this cold-start problem have been proposed based on Bayesian optimization and inverse reinforcement learning [39], [40]. In both cases, it is necessary to use a prior distribution of a function or its parameters and update it when new observations are available.

A. DATA DISAGGREGATION

The user interface should display simple information since the customer only needs to adjust thermostat set-points for the next market period while inspecting the electricity cost. The basic components of the user interface are presented in Fig 3. From the user's inputs, it is possible to obtain the φ_t profile for the utility function using the Karush-Kuhn-Tucker conditions. Next, it is necessary to disaggregate the values of F and the profiles of δ_t . To do this for a particular day, F is considered as

the maximum value of customer choices in the product ($F\delta_t$) since $\delta_t \in (0, 1]$.

For the next market period, the recommended value F is obtained from a GP regression. Then, δ_t for $t \in [1, \dots, T]$ is taken by weighting previous values of similar days. Various measures of similarity have been explored in [41] considering several features. Since δ_t captures occupancy information, it is suitable to consider similarity according to the day of the week and to give more weight to the adjacent days. For instance, the occupancy of the next Friday can be closer to the one of the last Friday, or the occupancy of a Saturday can be similar to previous weekends.

B. GAUSSIAN PROCESS

From the machine learning perspective, the recommender system is a regressor that maps user preferences under given conditions. The general formulation of the GP regressor is presented in [42]. The parameter F is influenced by features like the electricity price and the external temperature. Therefore, its estimation, \hat{F} can be defined by (8) below. Since this parameter is considered constant during the market period, i.e. one day, it is suitable to use the daily average values $\bar{\theta}_{ext}$ and $\bar{\pi}$ as feature variables in the regression.

$$\hat{F} = f(\bar{\pi}, \bar{\theta}_{ext}) = f(x) \quad (8)$$

In order to simplify the notation of the GP, the set of n days historical features is outlined by $X_H = [x_1, \dots, x_n]^T \in \mathbb{R}^{n \times 2}$ and the next market-period features are $x_M \in \mathbb{R}^{1 \times 2}$. Likewise, $F_H = [F_1, \dots, F_n] \in \mathbb{R}^n$ stands for corresponding historical observations of F obtained from previous user's choices. The GP is presented in (9),

$$\begin{bmatrix} F_H \\ F \end{bmatrix} \sim \mathcal{N} \left(0, \begin{bmatrix} K(X_H, X_H) + \sigma_n^2 \mathbb{I}_{n \times n} & K(X_H, x_M) \\ K(x_M, X_H) & K(x_M, x_M) \end{bmatrix} \right) \quad (9)$$

where K is the covariance function that maps the feature vectors, x , into Gram matrices, and σ_n represents the noise of the observations. Since preferences are expected to be stationary, there is no need for a tracking system and the prior mean is set to zero. This canonical notation is favourable for the GP because the conditional distributions are well-known in the literature [42]. In this case, the interest is in the distribution of F given F_H, X_H , and x_M , so the first and second-order moments are presented in (10) and (11). In the GP, the expected value, $\mathbb{E}[F|x_M, X_H, F_H]$ is also the maximum a posteriori (MAP) estimator of F , which is both an adequate solution for regression problems and a good recommendation in some situations as presented later in this document.

$$\mathbb{E}[F|x_M, X_H, F_H] = K(x_M, X_H) [K(X_H, X_H) + \sigma_n^2 \mathbb{I}_{n \times n}]^{-1} F_H \quad (10)$$

$$\begin{aligned} \sigma_M^2 &= K(x_M, x_M) - K(x_M, X_H) [K(X_H, X_H) + \sigma_n^2 \mathbb{I}_{n \times n}]^{-1} \\ &\quad \times K(X_H, x_M) \end{aligned} \quad (11)$$

In practice, the inverse of $[K(X_H, X_H) + \sigma_n^2 \mathbb{I}_{n \times n}]$ is computed with the Cholesky decomposition since the covariance

matrices are Hermitian positive-definite. For this case, it is convenient to consider the radial basis function as the covariance function, which has two parameters σ_H and L , presented in (12). This function is helpful because user preferences are expected to be stationary, discarding seasonal effects, vacancies, and other long-run behavior changes [43]. Thus, the covariance function is stationary considering only the similarity in the features space.

$$k(x, x') = \sigma_H^2 e^{-\frac{1}{2}(x-x')^T L^{-1}(x-x')} \quad (12)$$

where $L \in \mathbb{R}^{2 \times 2}$ is a diagonal matrix in which large entries imply a low correlation between the feature and the covariance. σ_H^2 corresponds to the expected value of the squared norm of X_H elements. Then, the required Gram matrices are composed as follows:

$$K(X_H, X_H) = \begin{bmatrix} k(x_1, x_1) & \dots & k(x_1, x_n) \\ \vdots & \ddots & \vdots \\ k(x_n, x_1) & \dots & k(x_n, x_n) \end{bmatrix} \quad (13)$$

$$K(x_M, X_H) = [k(x_M, x_1), \dots, k(x_M, x_n)] \quad (14)$$

$$K(x_M, x_M) = [k(x_M, x_M)] \quad (15)$$

the set of parameters, L can be tuned by maximizing the likelihood of historical data using quasi-Newton methods. The likelihood for the formulated GP is presented in (16),

$$\begin{aligned} \log(\mathbb{P}(F_H|X_H)) &= -\frac{1}{2} F_H^T [K(X_H, X_H) + \sigma_n^2 \mathbb{I}_{n \times n}]^{-1} F_H \\ &\quad -\frac{1}{2} \log(K(X_H, X_H) + \sigma_n^2 \mathbb{I}_{n \times n}) \\ &\quad -\frac{n}{2} \log(2\pi) \end{aligned} \quad (16)$$

where n is the number of samples in F_H . Subsequently, it is possible to estimate the MAP estimator of F for the next market period. At this point, it is necessary to analyze when the MAP expresses an accurate recommendation. First, utility functions are considered ordinal and users are assumed to be rational, which means they have *strict preferences* for cost savings [44]. Besides, customers can have a range of acceptable temperatures for which the perceived utility is the same. This means, in brief, a consumption strategy s_1 is strictly preferred over s_2 ($s_1 \succ s_2$) if it has a lower cost and manages the temperature setpoints inside an acceptable margin. However, this does not imply that the user knows what the optimal strategy is. In fact, users can merely accept consumption strategies cheaper than their WTP without searching for the optimal. Therefore, recommending the MAP, obtained from historical data, will lead to an acceptable value of \hat{F} but not to the best.

It is convenient to suggest the MAP when the GP becomes stationary, assuming stationary preferences of rational users. Conversely, it is favorable to suggest a higher value than the MAP (lower-cost strategy) while the GP has not reached a steady state. For example, the MAP plus one standard deviation. In this way, the recommender system improves the serendipity by showing unknown alternatives to the user. The

Algorithm 1: Recommender Algorithm.

input : Previous accepted parameters ($F\delta_t$) with the corresponding features ($\bar{\theta}_{ext}, \bar{\pi}$), future prices and weather conditions for the next market period

output: Parameters for the next market period ($\hat{F}\hat{\delta}_t$)

begin

Divide the historical user's accepted parameters into F and $\delta_t \in (0, 1]$;
Compute the covariance matrix with the available data using Eq. 12;

Compute $\mathbb{E}[F|x_M, X_H, F_H]$ using Eq. 10;

Check weak-sense stationarity regarding the previous statistical moments considering an adequate threshold;

if *The process is in steady state* **then**

 | $\hat{F} = \mathbb{E}[F|x_M, X_H, F_H]$;

else

 | $\hat{F} = \mathbb{E}[F|x_M, X_H, F_H] + \sigma_M$;

 Set $\hat{\delta}_t$ according to past similar days

end

statistical moments of the GP are compared before and after an update through a pre-defined threshold to check stationarity. The recommender system is summarized in Algorithm 1.

The process of moving from the MAP can be seen as an exploration that is needed to find the optimal strategy from stochastic feedback [39]. When the process converges, the recommender system can stop the exploration and start the exploitation of the acquired knowledge about user's preferences, i.e. suggesting only the MAP. Accordingly, it is suitable to move with the standard deviation, which is big when the agent has few data points and gets smaller quickly when the user gives consistent responses.

A drawback of the formulated GP is its application to online learning because the covariance computation and the matrix inversion are impractical for large datasets. The GP regressor has $\mathcal{O}(n^2)$ memory cost and $\mathcal{O}(n^3)$ computational complexity, where n is the number of samples [45]. This issue can be dealt with a recursive estimation, similar to the Kalman filter, by considering the previous posterior as the prior and using a linear model, which relates states and observations [46]. In this way, the recommender system can avoid storing extensive historical data and keep only information from the last market period.

C. CUSTOMER QUERIES

Considering that querying can create annoyance to the user, it is not suitable to ask for approval of a suggested power consumption plan at each time. Actually, when the customer does not make corrections, it is assumed that it has accepted the suggestion, and the related data is stored to train the recommender system. The customer interacts through a Human-Machine Interface (HMI) that displays the suggested DR agreement for the next market period (temperature setpoints and cost) and allows changing the set-points. Once the

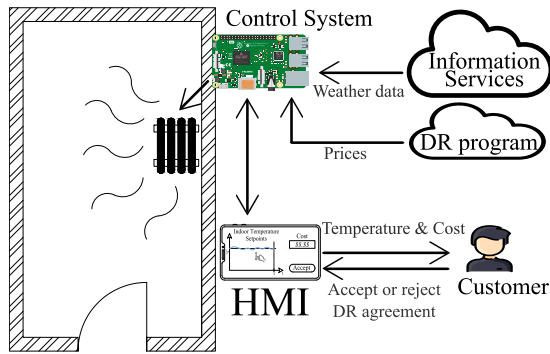


FIGURE 4. Information flows in the proposed recommender system.

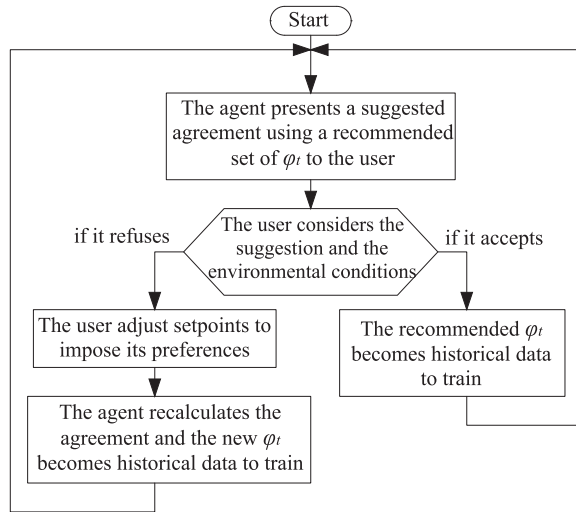


FIGURE 5. Flow chart of the user interactions.

user changes a parameter, it is necessary to recalculate the cost. This interaction is sketched in Fig. 4.

As a result, at the start of each market period, the system recommends a combination of temperature and cost to the customer to either accept (do nothing) or refuse (adjust set-points). At the end, the agreed parameters become data to train the recommender system in both cases. This procedure is presented in Fig. 5. It is worth mentioning that the customer can also modify the reference temperature, θ_{ref} . However, such modification is not considered in the current market period but in the next one. Consequently, a single parameter is queried and the customer can compare similar options when making decisions.

The HMI does not present penalties for deviation from the DR agreement in the proposed approach because the system is performing a predictive control. The ultimate goal of the HMI is to present user-friendly information and allow users to set their preferences. Thus, it is convenient to show only the temperature set-points and the total cost, and let the user modify just one of those. For more expert users, the HMI can include penalties information, if it influences their decisions.




FIGURE 6. Decision network for the customer.

IV. EXPERIMENTAL SETUP AND VALIDATION

Since a customer becomes committed to the DR mechanism, the accuracy of suggestions is crucial in the proposed mechanism. Therefore, the metrics for the recommender system must consider both the decision support and the deviation of the suggestions. In this case, we use the user's acceptance rate for the decision support and the difference from the final agreement in kWh as the accuracy metric. We perform an offline validation simulating the customer decision process to validate the recommender system. Besides, we compare the proposed approach with other two recommender techniques frequently used in the literature, under the same conditions:

- A persistency method that recommends user's accepted values for the last market period [47]. Considering stationarity in the preferences, a customer can choose the same options for consecutive days when external features (π and θ_{ext}) have slight changes.
- A Support Vector Regressor (SVR) that has the same kernel (covariance function) as the GP [48]. For this case, the acceptable margin from the hyperplane is set to 0.1, the regularization parameter for deviations is considered 1, and the training stop criteria is a tolerance of 0.001.

The variables that influence customer behavior are depicted in the decision network in Fig. 6. The reference temperature, θ_{ref} , the temperature setpoints, θ_t , the WTP, and the impatience function are decision nodes for the user, while the suggestion and the occupancy profile are chance nodes. The impatience function is merely a step function. Thus, the user stops interacting with the HMI after a defined number of queries. Formally, the queries reduce customers' comfort, and they stop interacting when their utility starts decreasing at each interaction [38]. Highly involved users adjust setpoints until they find an appropriate agreement, giving less noisy data to the recommender system. It is worth mentioning that the offline validation presented here does not allow for measuring the user experience (UX) with the HMI.

The decision network is compiled for the simulated customer in Algorithm 2. The decision process starts with a predefined WTP and the range of acceptable temperatures. The reference temperature is fixed beforehand. The HMI specifies the step-size in which ϕ_t can increase or decrease.

As a result, more patient customers with lower WTPs make more changes in the HMI while very impatient ones with

Algorithm 2: User Decision Process.

```

input : Minimum acceptable temperatures, WTP,
          $\theta_{ref}$ , Maximum queries
output:  $F\delta_t$  profile
begin
    Check the suggested agreement: temperature
    setpoints and cost ;
    while the queries are tolerable and the agreement
    is not acceptable do
        if the cost is higher than the WTP then
            | increase all  $F\delta_t \quad \forall t \in [1, \dots, T]$ 
        if the setpoints are lower than the acceptable
        temperatures then
            | decrease  $F\delta_t$  for all unacceptable
            temperatures  $\theta_t$ 
        end
    end
end
    
```

higher WTPs accept any suggested agreement at first. Due to the interest in the acceptance rate, a sensibility analysis is carried out with different values of WTP.

A. DATA DESCRIPTION

The weather data for θ_{ext} and P_{irr} corresponds to 90 winter days (20th December to 20th March, 2018) in the city of Trois-Rivieres, Quebec, Canada. The P_{app} data is related to a real house in the same location. This data has been used to find the parameters of the thermal model by ordinary least-squares regression. The resulting values are presented in (17) below. θ_{ext} and θ , P_{app} and P , and P_{irr} are expressed in Celsius degrees, kWh, and kW/m^2 , respectively.

$$\theta_t \approx 0.08316\theta_{ext,t} + 0.99168\theta_{t-1} + 0.00016P_{irr,t} + 0.07142P_{app,t} + 0.11064P_t \quad (17)$$

The value of φ_t can vary from -10 to 10 at steps of 0.2 . Finally, the market period, T is 24 hours and the signals are discretized at 5-minute intervals. The price signal corresponds to the spot market in Ontario, Canada during the same days in 2018 [49]. This signal is presented in Fig. 7 for the simulation period. The average price is 0.0532 CAD/kWh. The range of acceptable temperatures, used to simulate customer's behavior, is the same every day, as presented in Fig. 8. The threshold to check stationarity in the GP is 0.1 in the mean and 0.01 in the variance. The recommendation for the first day is zero for all recommenders, and thus, the prior for the GP is $\mathcal{N}(0, 1)$.

B. RESULTS AND DISCUSSION

Given the price signal, performing a sensitivity analysis on WTP from 1 to 5 CAD per day is reasonable. The maximum number of queries is set at 20 to scan a wide range of φ_t . The acceptance rate results during the 90 days for all combinations are summarized in Table 2. The proposed GP recommender leads to a higher acceptance rate in most cases, especially when the user's WTP is low thanks to the exploration process that constantly looks for a lower cost. A user with a WTP of 5 CAD/day accepts all the suggestions within the range

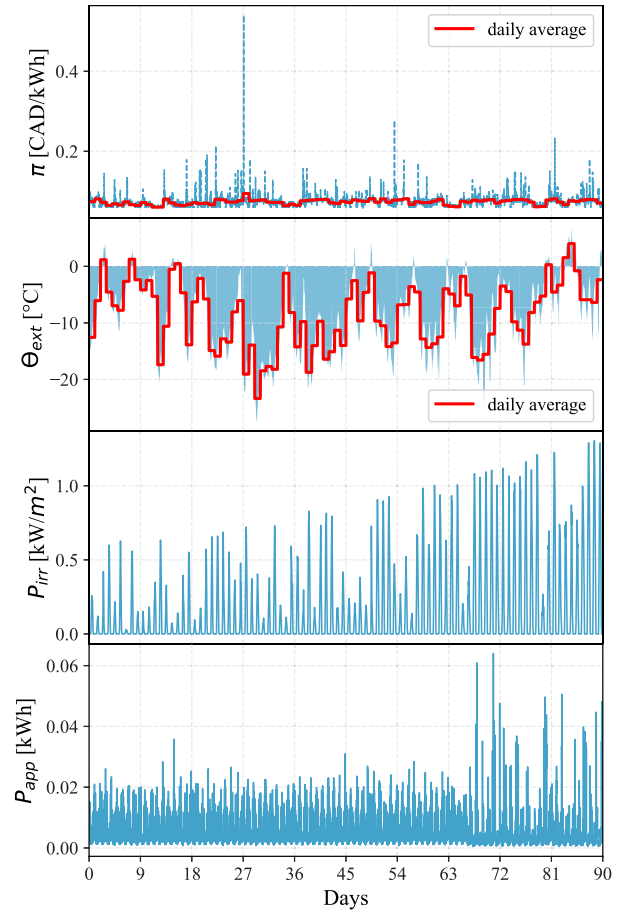


FIGURE 7. Signals used for the off-line validation.




FIGURE 8. Range of acceptable indoor temperatures.

of comfortable temperatures since the cost never exceeds that value. This case is useful to validate that the recommendations are fitting and do not diverge from training data.

A method with a higher acceptance rate does not imply that it has the most accurate suggestions, as customers accept any consumption strategy that meets their temperature and cost conditions. Thus, it is also relevant to consider the recommenders' deviations from the final DR agreement of the customer. The energy deviations are presented in Fig 9

TABLE 2 Acceptance Rate of the Recommender Systems

WTP [CAD/day]	Maximum queries	GP	SVR	Persistency
1	1	6/90	0/90	0/90
	5	46/90	0/90	0/90
	10	51/90	0/90	0/90
	20	54/90	12/90	1/90
2	1	7/90	0/90	1/90
	5	46/90	0/90	2/90
	20	54/90	15/90	5/90
3	1	47/90	43/90	40/90
	5	60/90	44/90	46/90
	10	64/90	46/90	47/90
	20	67/90	46/90	47/90
4	1	83/90	85/90	65/90
	5	84/90	85/90	85/90
	20	88/90	86/90	86/90
5	1	90/90	90/90	90/90
	5	90/90	90/90	90/90
	10	90/90	90/90	90/90
	20	90/90	90/90	90/90

in absolute values. It is not appropriate to separate positive and negative deviations since we are not considering penalties on the DR configuration. The SVR method has a lower variation for impatient customers because it does not make exploration. When impatience ceases to be a relevant noisy driver, the serendipity given by the GP method is beneficial to find better consumption strategies. In all cases, the GP-based recommender has a lower median deviation.

Patient customers give more consistent feedback the recommenders offer according to the WTPs. When it is not feasible to have a consumption strategy cheaper than WTP, users reject any suggestion and start changing temperatures. In such situations, patient customers will lose time trying to find other alternatives. An experienced user with some idea of the feasibility of the consumption strategies may find it relevant to have boundaries information on the HMI. For instance, indicating the high prices period can reduce customer exploration at that time.

Regarding the deviation in temperature, we present the number of hours where the suggestion was outside the comfortable range in Fig. 10. For impatient customers, the GP-based method suggest more uncomfortable temperatures because it is trying to reduce the cost. When the limit of queries increases, the temperature deviation of all recommenders decreases, and the GP becomes similar to the SVR method. In that scenario, the persistency method shows more temperatures outside the comfort limits, even for high WTP.

The GP recommender seems to be a good option for most cases. However, it requires a larger hardware infrastructure than other methods like a persistency recommender that can be implemented in a simple data buffer. Recommending the last values of both F and δ_t can suit impatient customers since their noisy inputs are inadequate for training other algorithms. Conversely, this procedure results in significant deviations for




FIGURE 9. Daily consumption deviation between the suggested strategy and the DR agreement.

patient users. Hence, it is advisable to acquire detailed information from customers and install a recommender system depending on their specific context.

C. LIMITATIONS AND OPPORTUNITIES

The proposed approach allows incorporating a prior distribution to improve the performance of the recommendations. If there exists a characterization of residential demand price-elasticity in a particular location, it is possible to pre-configure the φ_t profile for that place. Besides, such information can be used to weight F against δ_t instead of using the (0,1] range. Collecting data from a group of users can help fit better the preferences for individuals, as it happens in platforms like Youtube [50].

One of the challenges for the recommenders is to deal with Big Data. When the agent obtains more information from the user, it is necessary to implement the recursive algorithms. Another alternative way to deal with this issue is to implement adaptive learning techniques and filter the training samples. However, this also requires patient customers who give less noisy data to train because their inconsistent preferences can be treated as outliers.

The offline validation setup used here is suitable to analyze the recommender system in controlled scenarios. In future




FIGURE 10. Total duration of suggested temperatures outside the comfort range in the 90-day simulation.

analysis, an online validation should be performed with clusters of actual customers and A/B testing methods to check the influence of external information and the HMI limitations. In that case, the thermal model must be adapted to each customer situation.

V. CONCLUSION

Space heater systems have the potential for becoming the principal source of flexibility from the residential sector in cold-weather countries like Canada. Demand response programs can exploit this flexibility to build a more sustainable grid. However, residential customers lack adequate expertise in controlling these devices according to market signals. Therefore, it is necessary to provide automated tools that engage users. These tools require knowledge about users' preferences to reach convenient agreements. Accordingly, this paper presents a recommender system that allows automated systems to suggest an appropriate valuation of thermal comfort and make an agreement in the context of an economic demand response program. The proposed method is based on a Gaussian Process that explores cheaper options to increase serendipity in the suggestions. This process is trained with the customer's previous choices. The information required from the customer is reduced to a single scale parameter in each transaction to provide simple queries and easily comparable

options. In fact, in the presented approach, users need to supply more information only when they refuse the recommendation, not during all the training as in active learning methods. The offline validation of the recommender system shows that patient customers, who express more consistent preferences, give less noisy data and have a higher acceptance rate. From this perspective, this work contributes to analyzing recommender systems requirements according to customers' specific contexts. Future work focuses on integrating the proposed recommender system into complete home energy management systems to fully automate residential demand response.

ACKNOWLEDGMENT

The authors would like to thank the Laboratoire des technologies de l'énergie d'Hydro-Québec, the Natural Science and Engineering Research Council of Canada, and the Foundation of Université du Québec à Trois-Rivières.

REFERENCES

- [1] International Renewable Energy Agency (IRENA), "Power system flexibility for the energy transition. Part I: Overview for policy makers," IRENA, Abu-Dhabi, UAE, Tech. Rep. 978-92-9260-089-1, 2018. [Online]. Available: <https://www.irena.org/>
- [2] J. Cochran *et al.*, "Flexibility in 21st century power systems," National Renewable Energy Laboratory (NREL), Golden, CO, USA, Tech. Rep. NREL/TP-6A20-6172, 2014.
- [3] L. Martirano *et al.*, "Demand side management in microgrids for load control in nearly zero energy buildings," *IEEE Trans. Ind. Appl.*, vol. 53, no. 3, pp. 1769–1779, May/Jun. 2017.
- [4] Z. Liu, Q. Wu, K. Ma, M. Shahidehpour, Y. Xue, and S. Huang, "Two-stage optimal scheduling of electric vehicle charging based on transactive control," *IEEE Trans. Smart Grid*, vol. 10, no. 3, pp. 2948–2958, May 2019.
- [5] J. Hu, G. Yang, K. Kok, Y. Xue, and H. W. Binder, "Transactive control: A framework for operating power systems characterized by high penetration of distributed energy resources," *J. Modern Power Syst. Clean Energy*, vol. 5, no. 3, pp. 451–464, May 2017. [Online]. Available: <http://link.springer.com/10.1007/s40565-016-0228-1>
- [6] B. Gao, W. Zhang, Y. Tang, M. Hu, M. Zhu, and H. Zhan, "Game-theoretic energy management for residential users with dischargeable plug-in electric vehicles," *Energies*, vol. 7, no. 11, pp. 7499–7518, 2014.
- [7] International Energy Agency (IEA), "Tracking buildings 2020," IEA, Paris, Tech. Rep., 2020. [Online]. Available: <https://www.iea.org/reports/tracking-buildings-2020>
- [8] J.-H. Kim and A. Shcherbakova, "Common failures of demand response," *Energy*, vol. 36, no. 2, pp. 873–880, Feb. 2011. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S0360544210007176>
- [9] A. Starke, M. Willemsen, and C. Snijders, "Effective user interface designs to increase energy-efficient behavior in a rasch-based energy recommender system," in *Proc. 11th ACM Conf. Recommender Syst.*, New York, NY, USA, 2017, pp. 65–73. [Online]. Available: <https://dl.acm.org/doi/10.1145/3109859.3109902>
- [10] A. Alsalemi *et al.*, "Achieving domestic energy efficiency using micro-moments and intelligent recommendations," *IEEE Access*, vol. 8, pp. 15047–15055, 2020. [Online]. Available: <https://ieeexplore.ieee.org/document/8959214/>
- [11] D. Jiménez-Bravo, J. Pérez-Marcos, D. De la Iglesia, G. Villarrubia González, and J. De Paz, "Multi-agent recommendation system for electrical energy optimization and cost saving in smart homes," *Energies*, vol. 12, no. 7, Apr. 2019, Art. no. 1317. [Online]. Available: <https://www.mdpi.com/1996-1073/12/7/1317>
- [12] P. Wei, S. Xia, and X. Jiang, "Energy saving recommendations and user location modeling in commercial buildings," in *Proc. 26th Conf. User Model., Adaptation Personalization*, New York, NY, USA, 2018, pp. 3–11. [Online]. Available: <https://dl.acm.org/doi/10.1145/3209219.3209244>

- [13] P. Wei, S. Xia, R. Chen, J. Qian, C. Li, and X. Jiang, "A deep-reinforcement-learning-based recommender system for occupant-driven energy optimization in commercial buildings," *IEEE Internet Things J.*, vol. 7, no. 7, pp. 6402–6413, Jul. 2020. [Online]. Available: <https://ieeexplore.ieee.org/document/9001078/>
- [14] Y. Zhang, K. Meng, W. Kong, and Z. Y. Dong, "Collaborative filtering-based electricity plan recommender system," *IEEE Trans. Ind. Informat.*, vol. 15, no. 3, pp. 1393–1404, Mar. 2019. [Online]. Available: <https://ieeexplore.ieee.org/document/8412100/>
- [15] T. Pinto, R. Faia, M. Navarro-Caceres, G. Santos, J. M. Corchado, and Z. Vale, "Multi-agent-Based CBR recommender system for intelligent energy management in buildings," *IEEE Syst. J.*, vol. 13, no. 1, pp. 1084–1095, Mar. 2019. [Online]. Available: <https://ieeexplore.ieee.org/document/8533391/>
- [16] F. Luo, G. Ranzi, X. Wang, and Z. Y. Dong, "Social information filtering-based electricity retail plan recommender system for smart grid end users," *IEEE Trans. Smart Grid*, vol. 10, no. 1, pp. 95–104, Jan. 2019. [Online]. Available: <https://ieeexplore.ieee.org/document/7997914/>
- [17] P. Kar, A. Shareef, A. Kumar, K. T. Harn, B. Kalluri, and S. K. Panda, "ReViCEE: A recommendation based approach for personalized control, visual comfort & energy efficiency in buildings," *Building Environ.*, vol. 152, pp. 135–144, Apr. 2019. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S0360132319300459>
- [18] Y. Himeur *et al.*, "A survey of recommender systems for energy efficiency in buildings: Principles, challenges and prospects," *Inf. Fusion*, vol. 72, pp. 1–21, Aug. 2021. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S1566253521000178>
- [19] T. Silveira, M. Zhang, X. Lin, Y. Liu, and S. Ma, "How good your recommender system is? A survey on evaluations in recommendation," *Int. J. Mach. Learn. Cybern.*, vol. 10, no. 5, pp. 813–831, 2019. [Online]. Available: <http://dx.doi.org/10.1007/s13042-017-0762-9>
- [20] D. Daum, F. Haldi, and N. Morel, "A personalized measure of thermal comfort for building controls," *Building Environ.*, vol. 46, no. 1, pp. 3–11, Jan. 2011. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S0360132310001915>
- [21] A. Ghahramani, F. Jazizadeh, and B. Becerik-Gerber, "A knowledge based approach for selecting energy-aware and comfort-driven HVAC temperature set points," *Energy Buildings*, vol. 85, pp. 536–548, Dec. 2014. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S0378778814007932>
- [22] M. Shann and S. Seuken, "An active learning approach to home heating in the smart grid," in *Proc. Int. Joint Conf. Artif. Intell.*, 2013, pp. 2892–2899.
- [23] X. Jin, K. Baker, D. Christensen, and S. Isley, "Foresee: A user-centric home energy management system for energy efficiency and demand response," *Appl. Energy*, vol. 205, pp. 1583–1595, Nov. 2017.
- [24] L. Rueda *et al.*, "Online unsupervised occupancy anticipation system applied to residential heat load management," *IEEE Access*, vol. 9, pp. 109806–109821, 2021.
- [25] A. A. Adamopoulou, A. M. Tryferidis, and D. K. Tzovaras, "A context-aware method for building occupancy prediction," *Energy Buildings*, vol. 110, pp. 229–244, Jan. 2016. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S0378778815303212>
- [26] R. Tang, S. Wang, and K. Shan, "Optimal and near-optimal indoor temperature and humidity controls for direct load control and proactive building demand response towards smart grids," *Automat. Construction*, vol. 96, pp. 250–261, Dec. 2018. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S0926580518303133>
- [27] R. C. Bagher, H. Hassanpour, and H. Mashayekhi, "User trends modeling for a content-based recommender system," *Expert Syst. Appl.*, vol. 87, pp. 209–219, Nov. 2017. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S0957417417304384>
- [28] R. Adhikari, M. Pipattanasomporn, M. Kuzlu, and S. R. Bradley, "Simulation study of transactive control strategies for residential HVAC systems," in *Proc. IEEE PES Innov. Smart Grid Technol. Conf. Europe*, 2016, pp. 1–5.
- [29] N. Mohammad and A. Rahman, "Transactive control of industrial heating-ventilation-air-conditioning units in cold-storage warehouses for demand response," *Sustain. Energy, Grids Netw.*, vol. 18, 2019, Art. no. 100201. [Online]. Available: <https://doi.org/10.1016/j.segan.2019.100201>
- [30] D. T. Vedullapalli, R. Hadidi, and B. Schroeder, "Combined HVAC and battery scheduling for demand response in a building," *IEEE Trans. Ind. Appl.*, vol. 55, no. 6, pp. 7008–7014, Nov./Dec. 2019.
- [31] F. Liberati, A. D. Giorgio, A. Giuseppe, A. Pietrabissa, E. Habib, and L. Martirano, "Joint model predictive control of electric and heating resources in a smart building," *IEEE Trans. Ind. Appl.*, vol. 55, no. 6, pp. 7015–7027, Nov./Dec. 2019.
- [32] P. Samadi, H. Mohsenian-Rad, R. Schober, and V. W. Wong, "Advanced demand side management for the future smart grid using mechanism design," *IEEE Trans. Smart Grid*, vol. 3, no. 3, pp. 1170–1180, Sep. 2012.
- [33] T. Zakula, M. Bagaric, N. Ferdelji, B. Milovanovic, S. Mudrinic, and K. Ritos, "Comparison of dynamic simulations and the ISO 52016 standard for the assessment of building energy performance," *Appl. Energy*, vol. 254, 2019, Art. no. 113553. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0306261919312279>
- [34] R. Chi, Y. Hui, R. Wang, B. Huang, and Z. Hou, "Discrete-time-Distributed adaptive ILC with nonrepetitive uncertainties and applications to building HVAC systems," *IEEE Trans. Syst., Man, Cybern. Syst.*, to be published, doi: [10.1109/TSMC.2021.3113090](https://doi.org/10.1109/TSMC.2021.3113090). [Online]. Available: <https://ieeexplore.ieee.org/document/9552438/>
- [35] S. Kuhn and R. Schultz, "Risk neutral and risk averse power optimization in electricity networks with dispersed generation," *Math. Methods Operations Res.*, vol. 69, no. 2, pp. 353–367, May 2009. [Online]. Available: <http://link.springer.com/10.1007/s00186-008-0264-3>
- [36] J. Vuelvas, F. Ruiz, and G. Grusso, "Limiting gaming opportunities on incentive-based demand response programs," *Appl. Energy*, vol. 225, pp. 668–681, Sep. 2018.
- [37] V. Vitelli, O. Sorensen, M. Crispino, A. Frigessi, and E. Arjas, "Probabilistic preference learning with the Mallows rank model," *J. Mach. Learn. Res.*, vol. 18, no. 158, pp. 1–49, 2018. [Online]. Available: <http://jmlr.org/papers/v18/15-481.html>
- [38] A. Perrault and C. Bouillier, "Experiential preference elicitation for autonomous heating and cooling systems," in *Proc. Int. Joint Conf. Auton. Agents Multiagent Syst.*, 2019, pp. 431–439.
- [39] B. Shahriari, K. Swersky, Z. Wang, R. P. Adams, and N. De Freitas, "Taking the human out of the loop: A review of Bayesian optimization," *Proc. IEEE*, vol. 104, no. 1, pp. 148–175, Jan. 2016.
- [40] N. Bazenkov and M. Goubko, "Advanced planning of home appliances with consumer's preference learning," in *Proc. Russian Conf. Artif. Intell.*, 2018, pp. 249–259. [Online]. Available: http://link.springer.com/10.1007/978-3-030-00617-4_23
- [41] C. Aggarwal, A. Hinneburg, and D. Keim, "On the surprising behavior of distance metrics in high dimensional space," *Amer. J. Dermatopathology*, vol. 30, no. 4, pp. 420–434, 2001. [Online]. Available: http://link.springer.com/10.1007/3-540-44503-X_27
- [42] C. Rasmussen and C. Williams, *Gaussian Processes for Machine Learning*. vol. 7. London, U.K.: MIT Press, 2006.
- [43] D. Rafailidis and A. Nanopoulos, "Modeling users preference dynamics and side information in recommender systems," *IEEE Trans. Syst., Man, Cybern. Syst.*, vol. 46, no. 6, pp. 782–792, Jun. 2016. [Online]. Available: <https://ieeexplore.ieee.org/document/7194815/>
- [44] P. Glimcher and E. Fehr, *Neuroeconomics: Decision Making and the Brain*, vol. 63, 2nd ed., London, U.K.: Elsevier, 2014.
- [45] F. Perez-Cruz, S. Van Vaerenbergh, J. J. Murillo-Fuentes, M. Lazaro-Gredilla, and I. Santamaria, "Gaussian processes for nonlinear signal processing: An overview of recent advances," *IEEE Signal Process. Mag.*, vol. 30, no. 4, pp. 40–50, Jul. 2013.
- [46] M. Schürch, D. Azzimonti, A. Benavoli, and M. Zaffalon, "Recursive estimation for sparse Gaussian process regression," *Statist.*, May 2019. [Online]. Available: <http://arxiv.org/abs/1905.11711>
- [47] J. Beel, S. Langer, M. Genzmehr, and A. Nürnberger, "Persistence in recommender systems: Giving the same recommendations to the same users multiple times," in *Proc. Int. Conf. Theory Pract. Digit. Lib.*, 2013, pp. 386–390. [Online]. Available: http://link.springer.com/10.1007/978-3-642-40501-3_43
- [48] S.-H. Min and I. Han, "Recommender systems using support vector machines," in *Proc. 5th Int. Conf. Web Eng.*, 2005, pp. 387–393. [Online]. Available: http://link.springer.com/10.1007/11531371_50
- [49] The Independent Electricity System Operator (IESO), "Data directory: Realtime market price report," 2019, Accessed: Feb. 12 2019. [Online]. Available: <http://www.ieso.ca/en/Power-Data/Data-Directory>
- [50] S. Baluja, "A simple and efficient method to handle sparse preference data using domination graphs: An application to YouTube," *Procedia Comput. Sci.*, vol. 80, pp. 2302–2311, 2016. [Online]. Available: <http://dx.doi.org/10.1016/j.procs.2016.05.424>

Chapitre 4 - Mise en œuvre expérimentale

4.1 Plateforme multi-agents

La validation de la solution proposée pour les agents résidentiels automatisés requiert le développement d'un système de télécommunications pour l'échange de signaux de marché. Ce système est la base du mécanisme de ET dans lequel les agents commercent et se coordonnent. Dans ce cas, un serveur de messagerie instantanée Prosody IM est utilisé pour router les messages XMPP car il est particulièrement pratique pour l'enregistrement des agents [102]. La topologie du système de télécommunication est présentée dans la Figure 4-1. Le réseau interne du logiciel hôte est séparé afin de pouvoir être utilisé pour ajouter des services locaux (contrôleurs d'appareils ou interfaces utilisateur). Le service DNS interne est nécessaire pour router les messages à l'intérieur et à l'extérieur du réseau local parce que le protocole XMPP ne reconnaît pas les adresses IP directement.

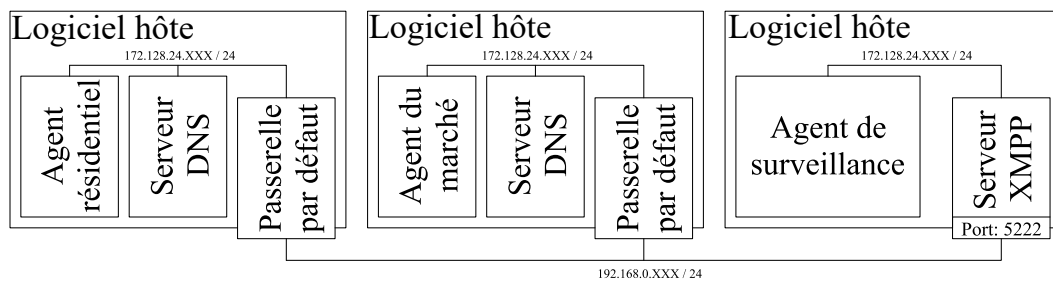


FIGURE 4-1 Topologie du système de télécommunication

Dans la configuration expérimentale de base, il suffit de disposer d'un agent résidentiel et d'un agent du marché chargé d'envoyer le signal de prix. Ce même agent est chargé de consulter les prévisions de la météo des services externes et de les partager dans la base de données du

système de l'ET. En outre, pour contrôler les processus expérimentaux, un agent de supervision a été ajouté pour vérifier les messages et pour envoyer les paramètres de simulation à l'agent résidentiel et à l'agent du marché (agrégateur de demande dans ce cas). Les signaux sont discrétisés par intervalles de cinq minutes, de sorte que pour un marché de 24 heures, les datagrammes sont des vecteurs de 288 positions.

4.2 Déploiement de logiciels

Les agents ont été développés sous forme d'images Docker sur Python 3.9 pour être installés dans un conteneur. Dans l'expérimentation, l'architecture logicielle des agents a été modifiée pour fonctionner comme une machine à état afin de contrôler le temps de simulation. Cette modification est illustrée dans la Figure 4-2. Cela implique que, bien que les comportements soient asynchrones, ils attendent une indication pour s'activer. Les transitions entre les états se font par des événements internes qui indiquent la fin d'un processus et non par des signaux du système de l'ET. Comme il n'y a qu'un seul agent résidentiel dans la simulation, il n'est pas nécessaire de coordonner les temps de réponse dans le système de l'ET.

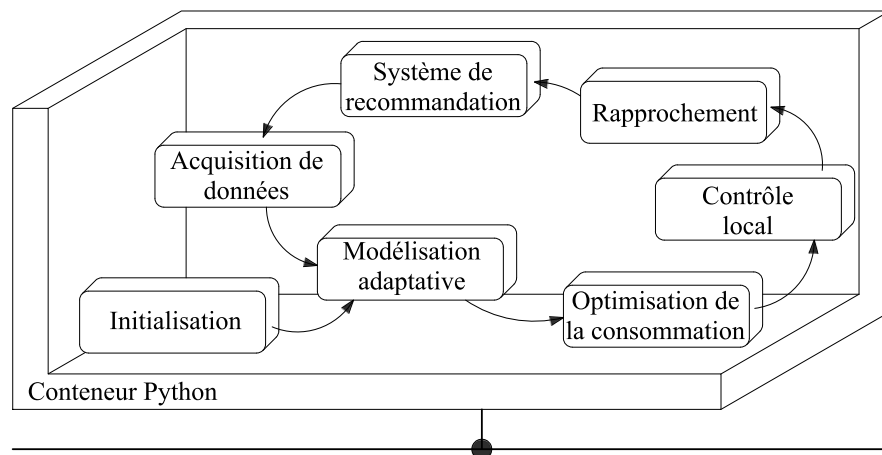


FIGURE 4-2 Transition entre les comportements de l'agent résidentiel

Les paramètres des instances de chaque comportement d'agent sont partagés par les méthodes "SET" pour fixer une valeur et "GET" pour en extraire la valeur. Ces méthodes sont déclarées dans la classe qui construit l'agent. De cette façon, il n'est pas nécessaire de répéter les

données entre les comportements des agents et les valeurs des processus précédents peuvent être réutilisées.

4.3 Caractéristiques du matériel

Le conteneur qui exécute l'agent résidentiel a été déployé sur un dispositif Raspberry Pi de quatrième génération (ARM v8) avec 8 Go de RAM. Il s'agit d'un appareil économique qui peut gérer les versions complètes des systèmes d'exploitation basés sur Linux. Par ailleurs, le dispositif a été configuré pour fonctionner avec l'alimentation par Ethernet (PoE) car il n'a pas de périphériques attachés, ce qui simplifie le câblage lors de son installation. Le processeur est un Broadcom BCM2711 1,5 GHz. Les temps mesurés des différents processus de l'agent résidentiel dans ce dispositif sont présentés dans la Figure 4-3. La variation des temps de calcul est due à des facteurs non contrôlables dans ce cas, comme le paramétrage du système d'exploitation ou la température du processeur. Il est important de préciser que le processus d'optimisation de la consommation utilise la librairie CVXPY avec des solveurs compilés en C#, tandis que les autres processus utilisent les outils Numpy directement en Python [103], [104].

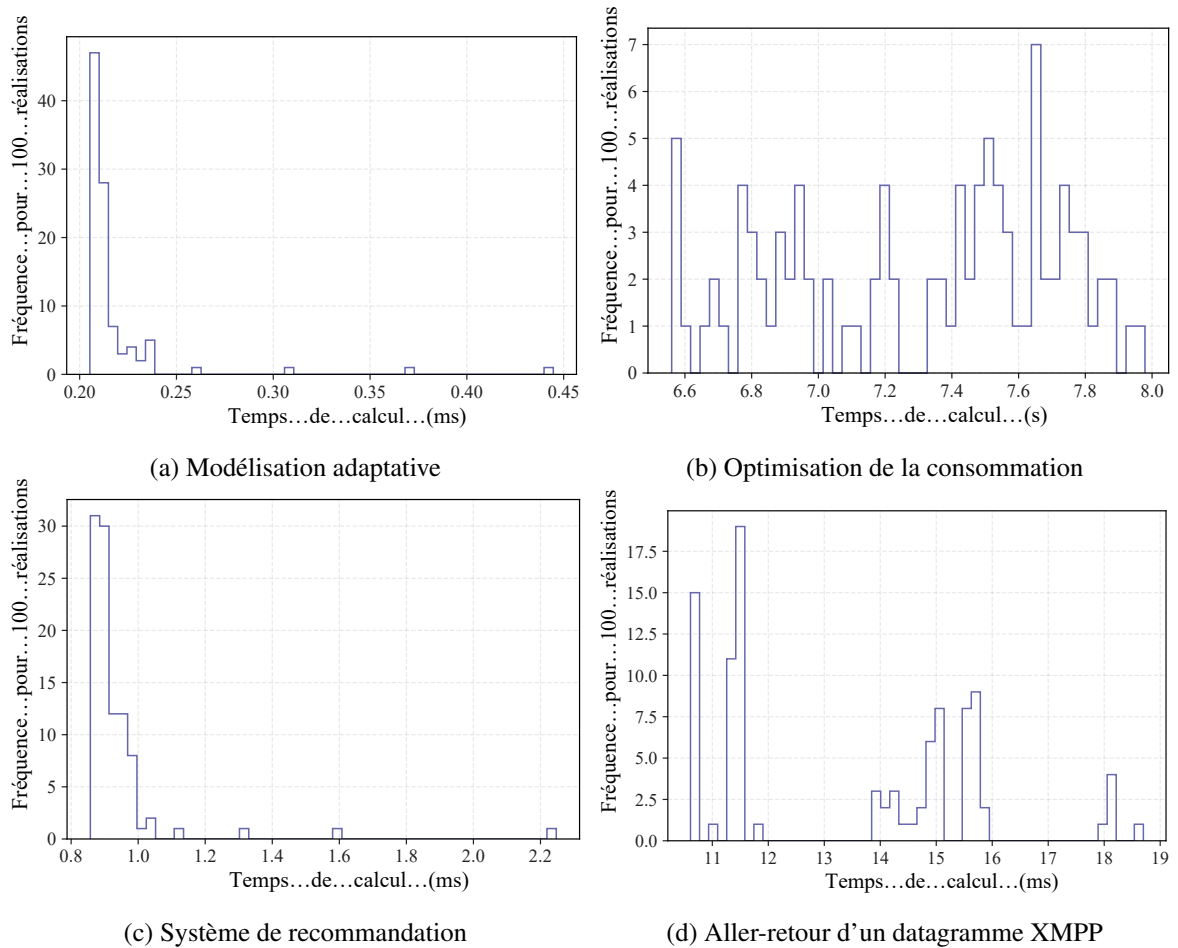


FIGURE 4-3 Mesures du temps de calcul des processus de l'agent résidentiel

Le serveur de télécommunications XMPP se trouve également dans un conteneur Docker, mais sur une architecture Intel i5-7600 x64 (3.5 GHz) avec 8 Go de RAM.

Les résultats expérimentaux de la mise en œuvre de l'agent montrent que le processus d'optimisation est le plus lent, prenant parfois jusqu'à 8 secondes. Par conséquent, lorsque l'interaction avec les autres agents du marché nécessite plusieurs itérations, il convient d'envisager une négociation précoce afin d'obtenir le contrat de l'ET à temps. La configuration du système de l'ET doit également tenir compte du traitement parallèle des agents pour éviter les encombrements. En outre, lorsque le signal de prix doit être coordonné avec d'autres agents du réseau, avec des autres contraintes, il faut prévoir le temps nécessaire à tous pour atteindre un point d'équilibre. La définition de ces interactions multi-agents dépasse le cadre de cette thèse, mais c'est un point important à prendre en compte dans les développements futurs de l'ET.

4.4 Modèles des charges résidentielles

4.4.1 Modèle de charges non contrôlables

On a utilisé une régression basée sur une machine à vecteur de support (SVR) pour les charges non contrôlables. De manière similaire à la machine à vecteurs de support pour les problèmes de classification (SVM), cet algorithme trouve un hyperplan qui minimise la norme (l_2) des vecteurs de support [105]. La différence entre SVM et SVR, est qu'un SVR utilise l'hyperplan pour estimer les valeurs de la variable indépendante et non pour séparer les données. Dans ce cas, un noyau a été utilisé pour trouver les vecteurs de support puisque les données de consommation ne suivent pas une tendance linéaire par rapport à ses variables explicatives. Le noyau utilisé est la fonction de base radiale, car il possède une efficacité de calcul plus élevée que les autres fonctions de la littérature [41].

La consommation des charges incontrôlables est expliquée par quatre variables : un signal cosinus avec une période de 24 heures, un nombre indiquant le jour de la semaine (de 1 à 7), la température extérieure et la consommation du jour précédent. Si l'on considère que les signaux sont discrétisés à 5 minutes, la consommation de la journée précédente serait prise en compte avec un retard allant jusqu'à 288 échantillons. La température extérieure et les variables de consommation ont été normalisées à des valeurs entre [0,1] et la marge d'erreur acceptable entre l'hyperplan et les échantillons est fixée à 0,1.




FIGURE 4-4 Modèle de charges non contrôlables

4.4.2 Modèle des dispositifs de génération

Pour ce projet, on a utilisé une simulation d'un système photovoltaïque de 10 kWp. Les données relatives à ce système ont été générées à l'aide du modèle SANDIA des panneaux

qui prend en compte 5 points de la courbe caractéristique tension/courant des panneaux : courant de court-circuit, tension de circuit ouvert, courant de puissance maximale, courant à la moitié de la tension de circuit ouvert et tension moyenne entre le circuit ouvert et la puissance maximale [106]. De plus, le modèle effectue une correction spectrale pour la densité de l'air. Les panneaux utilisés sont des modules Canadian Solar CS6X 300M et l'onduleur est un ABB PVI 10 I 208V [107], [108].

Le modèle utilisé par l'agent automatisé pour prédire la production de ce système photovoltaïque est un réseau neuronal Feed Forward. Le réseau est composé de 100 neurones organisés en 5 couches. Ces neurones utilisent une fonction logistique avec un seuil d'activation de 0,5 [109]. Les poids du réseau neuronal sont formés par rétropropagation à l'aide de l'algorithme ADAM (descente de gradient stochastique avec estimation du moment adaptatif). Les variables explicatives de la production du système photovoltaïque sont l'irradiation solaire, la vitesse et la direction du vent, l'heure, la couverture nuageuse et la température extérieure. Le nombre de variables explicatives conditionne le temps d'apprentissage du modèle. Les autres facteurs qui influencent le temps d'apprentissage sont le nombre d'itérations du processus de descente de gradient, le nombre d'échantillons utilisés et le nombre de neurones. Le nombre d'itérations pour atteindre un niveau d'erreur acceptable et éviter l'overfitting est de l'ordre de 100. Le but de l'utilisation de ce modèle est de démontrer la faisabilité de l'algorithme d'adaptation proposé sur un modèle de régression commun dans la littérature, cependant il existe d'autres modèles qui intègrent des systèmes discriminatifs et génératifs (auto-encodeurs et transformeurs), et qui pourraient améliorer la prédiction.




FIGURE 4-5 Modèle des dispositifs de génération

4.4.3 *Modèle de charges contrôlables*

La charge contrôlable par l'agent résidentiel correspond à un système de chauffage dans un environnement fermé qui est considéré comme une zone thermique unique. Les compteurs d'énergie sont directement connectés au panneau de distribution et les actionneurs sont deux plinthes électriques de 1000 W. Le signal de puissance est modulé par des largeurs d'impulsion (PWM) pour ajuster la valeur en fonction du contrat TE de l'agent. Dans cet environnement contrôlé, la position des portes ou des fenêtres n'est pas modifiée et le flux d'air dans les conduits est connu pour maintenir la température selon les prévisions. En dehors des conditions de laboratoire, il serait nécessaire d'ajouter un contrôleur en boucle fermée qui minimise les écarts de consommation en tenant compte des perturbations du système en temps réel.

Le modèle du système de chauffage est basé sur un circuit RC thermique avec une seule capacité par zone, selon la norme ISO 13790 [110]. Ce modèle est réduit à un espace d'état pour relier la consommation à la température interne de la maison. Ce modèle ne considère pas la non-linéarité de la dynamique thermique, mais il s'est avéré pratique pour le contrôle prédictif [111]. L'apprentissage des paramètres du modèle se fait par la méthode des moindres carrés. Au cours du projet, différentes variations de ce modèle ont été utilisées. Une première option consistait à considérer uniquement la température externe comme une perturbation. Une deuxième variation de ce modèle a été réalisée en incluant d'autres variables telles que l'irradiation solaire et la consommation des charges non contrôlables. Dans d'autres applications avec des résidences plus grandes, ce modèle linéaire peut être étendu à une configuration multizone en incluant des informations sur la géométrie de la construction : les transferts de chaleur entre zones adjacentes et une capacité thermique proportionnelle au volume chaque zone.

Il faut noter que cette charge de chauffage impose deux nouvelles contraintes au problème de planification de l'agent automatisé : la consommation ne peut être supérieure à la limite technique du système de chauffage et la température à la fin de la période de marché doit être égale à la température initiale pour que le problème ait une sous-structure optimale. Cette dernière contrainte peut être relâchée en utilisant des multiplicateurs de Lagrange pour

maintenir la tractabilité du problème.




FIGURE 4-6 Modèle de charges contrôlables

Chapitre 5 - Discussion et opportunités futures

5.1 Perspectives d'évolution des agents résidentiels automatisés

L'agent résidentiel développé dans ce projet a été utilisé pour effectuer les tâches de prévision et de planification de la consommation. Les informations traitées par cet agent lui permettent de trouver la stratégie optimale pour actionner un système de chauffage en fonction d'un signal de prix et des préférences de l'utilisateur. Cette stratégie est communiquée aux autres agents du réseau par le biais de l'infrastructure smart-grid afin de rechercher un accord sur un marché à terme.

Dans l'environnement local de l'agent, il peut y avoir des charges autres que le chauffage qui peuvent être contrôlées pour apporter de la flexibilité au réseau. Par exemple, on pourrait modifier les temps de charge des véhicules électriques, les points de consigne des climatiseurs, ou même le facteur de puissance de certains onduleurs. Il sera alors intéressant dans de futures applications d'intégrer des modèles d'autres charges dans l'architecture de l'agent résidentiel. De cette manière, l'agent sera en mesure de planifier la consommation complète de toutes les charges et disposera de plusieurs variables de décision pour exécuter ses contrats.

Pour le contrôle du système de chauffage, l'agent prend en compte les préférences de l'utilisateur en utilisant un système de recommandation. De façon similaire, lorsque l'agent contrôle d'autres appareils, il doit intégrer d'autres méthodes d'apprentissage des préférences en fonction de la nature de ces appareils. Par ailleurs, le système de recommandation présenté ici doit être testé avec des utilisateurs réels afin de valider le soutien à la décision. Pour ce faire, il est possible d'utiliser des techniques de validation en ligne telles que les tests A/B [32].

Le modèle utilisé pour réaliser le contrôle prédictif du système de chauffage est linéaire et basé sur un circuit thermique RC [110]. Ce modèle d'espace d'état capture approximativement la dynamique du système réel. Cependant, il existe des effets qui ne sont pas modélisés et qui peuvent être inclus dans d'autres modèles pour améliorer la stratégie de contrôle. Par exemple, on pourrait utiliser des modèles plus sophistiqués qui tiennent compte du transfert convectif et radiatif à travers les fenêtres et les portes.

Un autre aspect à analyser dans les développements futurs est le traitement des rapprochements par l'agent. Si les pénalités pour les déviations sur le marché sont établies dans les contrats à terme ou au moyen de contrats intelligents, elles pourraient être calculées directement par l'agent. Par contre, si les pénalités dépendent du comportement de la demande agrégée, l'agent devra consulter d'autres acteurs du réseau pour connaître le coût des pénalités. Dans les deux cas, il sera bénéfique pour l'agent de garder une trace des rapprochements afin de prendre en compte l'aversion au risque des utilisateurs dans les transactions futures. Pour les utilisateurs peu disposés à prendre des risques, les données historiques peuvent aider à formuler des stratégies de consommation prudentes qui minimisent le coût des pénalités. Par ailleurs, la connaissance des erreurs dans les prévisions des modèles peut aider à préparer des actions de contrôle dans le réseau électrique pour éviter les pannes.

Finalement, dans de très grandes MAS, il sera nécessaire d'étudier les exigences en matière de hardware pour l'interaction d'une multitude d'agents. En effet, en minimisant le hardware, comme cela a été fait ici avec les Raspberry Pi, permet des mises en œuvre moins coûteuses pour les utilisateurs de l'ET. Cependant, il est nécessaire de prendre en compte le compromis entre le matériel et le temps de calcul, car il y a une période limitée pour atteindre l'équilibre du marché. Dans les scénarios qui comptent de nombreux agents, plusieurs itérations du processus de négociation peuvent être nécessaires pour parvenir à un accord sur le marché à terme.

5.2 Perspectives de l'énergie transactionnelle

Afin de promouvoir le développement de l'ET, il est nécessaire d'automatiser également les tâches des autres types d'acteurs du réseau. Par exemple, sur les marchés locaux en réseaux

de distribution, il sera nécessaire de modéliser les croyances, les désirs et les intentions des agrégateurs de demande, des détaillants, des opérateurs de réseau et des régulateurs. Parallèlement au développement de ces agents, il conviendra de définir la plateforme sur laquelle ils peuvent interagir et le type de messages qu'ils échangent entre eux. L'agent résidentiel est un acteur clé, car il contrôle une partie de la demande, mais il n'est pas le seul dont dépend le maintien de l'équilibre du réseau.

À l'avenir, les marchés locaux pourront être équilibrés de manière décentralisée par des interactions entre les agents dans différents types de MAS. Même les marchés des services auxiliaires peuvent être équilibrés pour les agents afin d'assurer un meilleur degré de fiabilité et de durabilité du système électrique. Toutefois, les agents doivent évoluer pour participer à différents types de marchés et combiner des solutions. Les agrégateurs de demande seront utiles dans ces scénarios, car ils permettent un certain degré d'abstraction en considérant la demande comme un ensemble. La présence des agrégateurs sera bénéfique, même dans les micro-réseaux, pour réduire la dépendance à l'égard des grands générateurs.

Autre aspect à étudier dans les futures applications de l'ET est l'apparition de défaillances du marché. Par exemple, sur le marché local utilisé tout au cours de ce projet, il a été constaté que l'utilisation d'un signal de prix unique pour les agents résidentiels les plaçait dans une situation de dilemme du prisonnier. Ce problème impose une contrainte aux agents pour atteindre leurs objectifs de coordination. Une solution possible à ce problème consiste à utiliser des signaux de prix individuels qui reflètent les contributions de chaque agent à la coordination du réseau, de sorte que les utilisateurs plus élastiques puissent mieux s'adapter aux besoins du système.

Finalement, afin d'évoluer vers un système entièrement contrôlé par l'ET, il est nécessaire d'analyser les exigences en matière de sécurité des données. Bien que les solutions de l'ET soient mises en œuvre au niveau de la couche d'application d'un smart-grid, il est nécessaire de confirmer que le smart-grid dispose d'une sécurité suffisante pour effectuer des transactions. Ceci est dû au fait que l'utilisation de signaux de prix est une incitation directe à introduire des perturbations et à modifier les données. Une solution possible consiste à utiliser la technologie blockchain qui a démontré une amélioration de la sécurité dans d'autres types de transactions

[112]. De plus, les principes de décentralisation de la blockchain sont compatibles avec ceux de l'ET.

Chapitre 6 - Conclusions

Au cours des dernières années, différents mécanismes de l'ET ont été développés pour permettre à tous les acteurs du réseau électrique de commercialiser de l'énergie et d'autres services. Ces mécanismes visent à améliorer l'efficacité économique du secteur de l'électricité en minimisant les coûts de la consommation d'énergie et en maximisant le bien-être social. Pour que ces mécanismes fonctionnent correctement, les participants aux transactions doivent être proactifs dans la collecte d'informations et la formulation de stratégies commerciales. Cette situation pose un défi aux acteurs qui n'ont pas l'habitude de participer aux marchés de l'énergie, comme les utilisateurs résidentiels.

Dans ce projet de thèse, on a développé un agent automatisé qui représente les utilisateurs résidentiels dans les transactions. Cet agent collecte les informations nécessaires pour formuler une stratégie de consommation en fonction des signaux de prix et des préférences des utilisateurs. L'automatisation facilite la participation des utilisateurs et leur permet de donner des réponses rationnelles aux exigences du marché. De cette façon, on peut résoudre le problème de l'engagement des utilisateurs finaux, qui est l'un des obstacles à la mise en œuvre de l'ET.

L'agent développé effectue les tâches de prévision et de planification pour obtenir un accord commercial sur un marché à terme. Ces tâches définissent les comportements de l'agent, car celui-ci doit s'adapter pour remplir l'accord au mieux de ses capacités. L'agent résidentiel doit donc s'assurer que le plan de consommation est réalisable en fonction des charges contrôlables dont il dispose et l'information qu'il reçoit du système de l'ET. Il faut souligner que l'agent résidentiel a le rôle de suiveur dans les mécanismes de l'ET et il ne peut pas paramétrer ou contraindre d'autres agents.

Pour la prévision de consommation, l'agent utilise des modèles d'apprentissage automatique supervisés qu'il adapte en fonction des conditions de son environnement local. L'adaptation est réalisée au moyen d'une technique basée sur la validation croisée qui indique à l'agent avec quelles données il doit réentraîner les modèles. De cette façon, il peut les adapter à des changements tant progressifs que soudains. Ce processus prévoit que l'agent dispose d'informations actuelles et fiables pour prendre des décisions en matière de consommation.

La charge contrôlable par l'agent qui a été considéré dans ce projet est un système de chauffage. Ces systèmes peuvent profiter du stockage thermique propre des maisons pour modifier leur consommation sans affecter le confort des utilisateurs. Cependant, pour que l'agent puisse les contrôler, il est nécessaire de connaître les préférences des utilisateurs. Les informations consultées à l'utilisateur ont été réduites à des variables facilement comparables : le coût et la température. Par ailleurs, on a développé un système de recommandation qui apprend les préférences de l'utilisateur pour éviter de le consulter à chaque fois. De cette manière, l'agent dispose d'informations complètes pour formuler sa stratégie et l'utilisateur ne doit intervenir que lorsqu'il n'est pas d'accord avec la recommandation. Au fur et à mesure que le système de recommandation apprend de l'utilisateur, les tâches de l'agent deviennent plus autonomes.

L'agent développé a été testé dans différentes configurations d'un marché à terme local. Les tests ont montré que l'agent est capable de collecter et de gérer les informations nécessaires pour répondre aux exigences du marché. L'intégration de cet agent automatisé dans les systèmes électriques permettra d'évoluer vers une gestion décentralisée du réseau. En outre, l'automatisation des tâches facilite la participation des utilisateurs résidentiels aux mécanismes de l'ET, ce qui contribue à leur popularisation et à leur développement. Toutefois, il est encore nécessaire d'envisager l'automatisation d'autres agents du réseau tels que les agrégateurs de demande et les générateurs. À l'avenir, les réseaux électriques pourront être entièrement coordonnés à travers des interactions de plusieurs agents automatisés.

Concernant les prochaines étapes du développement des agents résidentiels automatisés, il sera nécessaire d'inclure les contrôleurs d'autres appareils dans le problème d'optimisation. Certaines charges, comme les véhicules électriques et les thermopompes, peuvent également être

utilisées pour apporter de la flexibilité aux réseaux électriques. À cet égard, il sera également nécessaire d'intégrer de nouvelles méthodes d'apprentissage des préférences pour gérer ces charges sans réduire le confort des utilisateurs. L'extension de l'agent résidentiel automatisé avec de nouveaux contrôleurs contribuera à formuler des stratégies de consommation qui tirent le meilleur parti des opportunités du marché de l'ET.

Bibliographie

- [1] J. E. LIVINGSTON et M. RUMMUKAINEN, « Taking science by surprise : The knowledge politics of the IPCC Special Report on 1.5 degrees, » *Environmental Science & Policy*, t. 112, p. 10-16, oct. 2020, ISSN : 14629011. DOI : 10.1016/j.envsci.2020.05.020.
- [2] M. ALLEN, O. DUBE, W SOLECKI et al., « Framing and Context. In : Global Warming of 1.5°C. An IPCC Special Report on the impacts of global warming of 1.5°C above pre-industrial levels and related global greenhouse gas emission pathways, in the context of strengthening the global response to the threat of climate change, sustainable development, and efforts to eradicate poverty, » 2018.
- [3] UNITED NATIONS (UN). « COP26 Outcomes - UN Climate Change Conference at the SEC – Glasgow 2021. » (2021).
- [4] INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC), « Climate Change 2021 : The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the IPCC, » Cambridge University Press, rapp. tech., 2021.
- [5] D. SATTERTHWAITTE, « The implications of population growth and urbanization for climate change : » *Environment and Urbanization*, t. 21, p. 545-567, 2 2009, ISSN : 09562478. DOI : 10.1177/0956247809344361.
- [6] INTERNATIONAL ENERGY AGENCY (IEA), « World Energy Outlook 2021, » IEA, Paris, rapp. tech., 2021.
- [7] UNITED NATIONS (UN), « Sustainable development major agreements and conventions, » rapp. tech., 2020.

- [8] INTERNATIONAL ENERGY AGENCY (IEA), « Net Zero by 2050, » IEA, Paris, rapp. tech., 2021.
- [9] WORLD ENERGY COUNCIL, « World Energy Trilemma Index 2020, » WEC, London, rapp. tech., 2020.
- [10] J. WIDÉN, N. CARPMAN, V. CASTELLUCCI et al., « Variability assessment and forecasting of renewables : A review for solar, wind, wave and tidal resources, » *Renewable and Sustainable Energy Reviews*, t. 44, p. 356-375, avr. 2015, ISSN : 1364-0321. DOI : 10.1016/J.RSER.2014.12.019.
- [11] C. GÜRSAN et V. de GOOYERT, « The systemic impact of a transition fuel : Does natural gas help or hinder the energy transition ? » *Renewable and Sustainable Energy Reviews*, t. 138, p. 110552, mars 2021, ISSN : 1364-0321. DOI : 10.1016/J.RSER.2020.110552.
- [12] INTERNATIONAL ENERGY AGENCY (IEA), « Clean Energy Transitions Programme, » IEA, Paris, rapp. tech., 2019.
- [13] INTERNATIONAL RENEWABLE ENERGY AGENCY (IRENA), « Adapting Market Design to High Shares of Variable Renewable Energy, » IRENA, Abu-Dhabi, rapp. tech., 2017.
- [14] W. COLE, A. W. FRAZIER et C. AUGUSTINE, « Cost Projections for Utility-Scale Battery Storage : 2021 Update, » NREL, 2021.
- [15] INTERNATIONAL RENEWABLE ENERGY AGENCY (IRENA), « Power System Flexibility for the Energy Transition. Part I : overview for policy makers, » IRENA, Abu-Dhabi, rapp. tech., 2018.
- [16] INTERNATIONAL ENERGY AGENCY (IEA), « The Critical Role of Buildings, » IEA, Paris, rapp. tech., 2019.
- [17] RÉGIE DE L'ÉNERGIE DU CANADA, « Canada's Energy Future 2020, » CER, rapp. tech., 2020.

- [18] L. ZHANG, N. GOOD et P. MANCARELLA, « Building-to-grid flexibility : Modeling and assessment metrics for residential demand response from heat pump aggregations, » *Applied Energy*, t. 233-234, n° October 2018, p. 709-723, 2019, ISSN : 03062619. DOI : 10.1016/j.apenergy.2018.10.058.
- [19] GRIDWISE ARCHITECTURE COUNCIL (GWAC), « Transactive Energy Framework, » *GWAC Architecture Council on Transactive Energy*, t. 1.1, p. 1-23, 2019.
- [20] M. USLAR, S. ROHJANS, C. NEUREITER et al., « Applying the smart grid architecture model for designing and validating system-of-systems in the power and energy domain : A European perspective, » *Energies*, t. 12, n° 2, 2019, ISSN : 19961073. DOI : 10.3390/en12020258.
- [21] J LIAN, W ZHANG, Y SUN, L. MARINOVICI, K KLASI et S. WIDERGREN, « Transactive Systems. Part I : Theoretical Underpinnings of payoff functions, control decisions, information privacy, and solution concepts, » PNNL, US Department of Energy, Washington, rapp. tech., 2017.
- [22] O. ABRISHAMBAF, F. LEZAMA, P. FARIA et Z. VALE, « Towards transactive energy systems : An analysis on current trends, » *Energy Strategy Reviews*, t. 26, p. 100-118, 2019, ISSN : 2211467X. DOI : 10.1016/j.esr.2019.100418.
- [23] J. SANCHEZ, D. BUNN, E. CENTENO et J. BARQUIN, « Dynamics in Forward and Spot Electricity Markets, » *IEEE Transactions on Power Systems*, t. 24, n° 2, p. 582-591, mai 2009, ISSN : 0885-8950. DOI : 10.1109/TPWRS.2009.2016464.
- [24] B. HANUMANTHA RAO, S. L. ARUN et M. P. SELVAN, « An electric power trading framework for smart residential community in smart cities, » *IET Smart Cities*, t. 1, n° 2, p. 40-51, 2019. DOI : 10.1049/iet-smc.2019.0055.
- [25] M. RAYATI, S. A. GOGHARI, Z. N. GHEIDARI et A. M. RANJBAR, « Robust and dynamic transactive energy system using Tsytkin–Polyak theorem, » *IET Smart Grid*, t. 1, p. 57-65, 2 juill. 2018, ISSN : 2515-2947. DOI : 10.1049/IET-STG.2018.0041.
- [26] NATURAL RESOURCES OF CANADA, « Secondary Energy Use and GHG Emissions by End-Use, » NRC, rapp. tech., 2018.

- [27] C. canadienne des codes du bâtiment et de prévention des INCENDIES, R. naturelles CANADA et R. du bâtiment du QUÉBEC, « Code de construction du Québec, Chapitre I.1 – Efficacité énergétique du bâtiment, et Code national de l'énergie pour les bâtiments, » Conseil national de recherches du Canada, rapp. tech., 2020.
- [28] A BENSOUSSAN, M. H. M. CHAU et S. C. P. YAM, « Mean Field Stackelberg Games : Aggregation of Delayed Instructions, » *SIAM Journal on Control and Optimization*, t. 53, n° 4, p. 2237-2266, 2015, ISSN : 0363-0129. DOI : 10.1137/140993399.
- [29] Y. YU, T. JIN et C. ZHONG, « Designing an incentive contract menu for sustaining the electricity market, » *Energies*, t. 8, n° 12, p. 14 197-14 218, 2015, ISSN : 19961073. DOI : 10.3390/en81212419.
- [30] J. GAMA, I. ZLIOBAITÉ, A. BIFET, M. PECHENIZKIY et A. BOUCHACHIA, « A Survey on Concept Drift Adaptation, » *ACM Computing Surveys*, t. 1, n° 1, 2013.
- [31] J. ODELL, P. GIORGINI et J. MÜLLER, *Agent-Oriented Software Engineering V*. Springer Berlin Heidelberg, 2004, ISBN : 3540242864.
- [32] F. RICCI, L. ROKACH, B. SHAPIRA et P. B. KANTOR, *Recommender Systems Handbook*. Boston, MA : Springer US, 2011, ISBN : 978-0-387-85819-7. DOI : 10.1007/978-0-387-85820-3.
- [33] M. YU et S. H. HONG, « A Real-Time Demand-Response Algorithm for Smart Grids : A Stackelberg Game Approach, » *IEEE Transactions on Smart Grid*, t. 7, n° 2, p. 879-888, 2016, ISSN : 19493053. DOI : 10.1109/TSG.2015.2413813.
- [34] K. JHALA, B. NATARAJAN, A. PAHWA et H. WU, « Stability of Transactive Energy Market-Based Power Distribution System under Data Integrity Attack, » *IEEE Transactions on Industrial Informatics*, t. 15, n° 10, p. 5541-5550, 2019, ISSN : 19410050. DOI : 10.1109/TII.2019.2901768.
- [35] S. BURGER, J. P. CHAVES-ÁVILA, C. BATLLE et I. J. PÉREZ-ARRIAGA, « A review of the value of aggregators in electricity systems, » *Renewable and Sustainable Energy Reviews*, t. 77, n° April, p. 395-405, 2017, ISSN : 13640321. DOI : 10.1016/j.rser.2017.04.014.

- [36] J LIAN, W ZHANG, Y SUN, L. MARINOVICI, K KALSI et S. WIDERGREN, « Transac-
tive System. Part I : Theoretical Underpinnings of Payoff Functions, Control Decisions,
Information Privacy, and Solution Concepts, » rapp. tech., 2017.
- [37] O. LOYOLA-GONZALEZ, « Black-Box vs. White-Box : Understanding Their Advan-
tages and Weaknesses From a Practical Point of View, » *IEEE Access*, t. 7, p. 154 096-
154 113, 2019, ISSN : 2169-3536. DOI : 10.1109/ACCESS.2019.2949286.
- [38] S. ZARE, N. HASHEMINEZHAD, K. SAREBANZADEH, F. ZOLALA, R. HEMMATJO et
D. HASSANVAND, « Assessing thermal comfort in tourist attractions through objective
and subjective procedures based on ISO 7730 standard : A field study, » *Urban Climate*,
t. 26, p. 1-9, 2018, ISSN : 22120955. DOI : 10.1016/j.uclim.2018.08.001.
- [39] P. GLIMCHER et E. FEHR, *Neuroeconomics : Decision Making and the Brain*, Second
Edi. London : Elsevier, 2014, t. 63, p. 150-153, ISBN : 9780124160088. DOI : 10.
1016/j.neuron.2009.07.005.
- [40] A. PERRAULT et C. BOUTILIER, « Experiential preference elicitation for autonomous
heating and cooling systems, » *Proceedings of the International Joint Conference on
Autonomous Agents and Multiagent Systems, AAMAS*, t. 1, n^o Aamas, p. 431-439,
2019, ISSN : 15582914.
- [41] C. RASMUSSEN et C. WILLIAMS, *Gaussian Processes for Machine Learning*. London :
The MIT Press, 2006, t. 7, ISBN : 026218253X.
- [42] Y. SHOHAM, « Agent-oriented programming, » *Artificial Intelligence*, t. 60, n^o 1,
p. 51-92, 1993, ISSN : 00043702. DOI : 10.1016/0004-3702(93)90034-9.
- [43] B. LUONG, J. THANGARAJAH et F. ZAMBETTA, « A BDI Game Master Agent for
Computer Role-Playing Games, » *Computers in Entertainment*, t. 15, n^o 1, p. 1-16,
2017, ISSN : 1544-3574. DOI : 10.1145/2629700.
- [44] J. BROERSEN, M. DASTANI, J. HULSTIJN, Z. HUANG et L. van der TORRE, « The
BOID architecture, » in *Proceedings of the fifth international conference on Autono-
mous agents - AGENTS '01*, New York, New York, USA : ACM Press, 2001, p. 9-16,
ISBN : 158113326X. DOI : 10.1145/375735.375766.

- [45] R. C. CARDOSO et A. FERRANDO, « A Review of Agent-Based Programming for Multi-Agent Systems, » *Computers*, t. 10, n° 2, p. 16, 2021, ISSN : 2073-431X. DOI : 10.3390/computers10020016.
- [46] M. W. KHAN et J. WANG, « The research on multi-agent system for microgrid control and optimization, » *Renewable and Sustainable Energy Reviews*, t. 80, p. 1399-1411, 2017, ISSN : 13640321. DOI : 10.1016/j.rser.2017.05.279.
- [47] A. KANTAMNENI, L. E. BROWN, G. PARKER et W. WEAVER, « Survey of multi-agent systems for microgrid control, » *Engineering Applications of Artificial Intelligence*, t. 45, p. 192-203, 2015, ISSN : 09521976. DOI : 10.1016/j.engappai.2015.07.005.
- [48] O. SHEHORY et A. STURM, *Agent-Oriented Software Engineering. Reflections on Architectures, Methodologies, Languages, and Frameworks*. New York : Springer Berlin Heidelberg, 2014, ISBN : 9783642544316.
- [49] M. S. H. NIZAMI, M. J. HOSSAIN et E. FERNANDEZ, « Multiagent-Based Transactive Energy Management Systems for Residential Buildings with Distributed Energy Resources, » *IEEE Transactions on Industrial Informatics*, t. 16, n° 3, p. 1836-1847, 2020, ISSN : 19410050. DOI : 10.1109/TII.2019.2932109.
- [50] Y. ZHOU, J. WU et C. LONG, « Evaluation of peer-to-peer energy sharing mechanisms based on a multiagent simulation framework, » *Applied Energy*, t. 222, n° February, p. 993-1022, 2018, ISSN : 03062619. DOI : 10.1016/j.apenergy.2018.02.089.
- [51] S. CHEN, Q. CHEN et Y. XU, « Strategic Bidding and Compensation Mechanism for a Load Aggregator With Direct Thermostat Control Capabilities, » *IEEE Transactions on Smart Grid*, t. 9, n° 3, p. 2327-2336, 2018, ISSN : 19493053. DOI : 10.1109/TSG.2016.2611611.
- [52] K. WACKS, « The successes and failures of standardization in home systems, » in *Proceedings from the 2nd IEEE Conference on Standardization and Innovation in Information Technology (Cat. No.01EX530)*, IEEE, 2003, p. 77-88, ISBN : 0-7803-9817-3. DOI : 10.1109/SIIT.2001.968557.

- [53] M. B. RASHEED, N. JAVAID, M. S. ARSHAD MALIK, M. ASIF, M. K. HANIF et M. H. CHAUDARY, « Intelligent Multi-Agent Based Multilayered Control System for Opportunistic Load Scheduling in Smart Buildings, » *IEEE Access*, t. 7, p. 23 990-24 006, 2019, ISSN : 21693536. DOI : 10.1109/ACCESS.2019.2900049.
- [54] L. TEFATSION, « Electric Power Markets in Transition : Agent-Based Modeling Tools for Transactive Energy Support, » in *Handbook of Computational Economics*, t. 4, Elsevier B.V., 2018, p. 715-766. DOI : 10.1016/bs.hescom.2018.02.004.
- [55] D. BUNN et F. OLIVEIRA, « Agent-based simulation : an application to the new electricity trading arrangements of England and Wales, » *IEEE Transactions on Evolutionary Computation*, t. 5, n° 5, p. 493-503, 2001, ISSN : 1089778X. DOI : 10.1109/4235.956713.
- [56] J. NICOLAISEN, V. PETROV et L. TEFATSION, « Market power and efficiency in a computational electricity market with discriminatory double-auction pricing, » *IEEE Transactions on Evolutionary Computation*, t. 5, n° 5, p. 504-523, 2001, ISSN : 1089778X. DOI : 10.1109/4235.956714.
- [57] J. ROOP et E. FATHELRAHMAN, « Modeling Electric Contract Choice : An Agent Based Approach, » *European Council for an Energy Efficient Economy*, 2003.
- [58] T. PINTO, I. PRAÇA, G. SANTOS et Z. VALE, « Demonstration of the Multi-Agent Simulator of Competitive Electricity Markets, » in *Lecture Notes in Computer Science*, Springer, Berlin, Heidelberg, 2013, p. 316-319. DOI : 10.1007/978-3-642-38073-0_36.
- [59] H. T. NGUYEN, S. BATTULA, R. R. TAKKALA, Z. WANG et L. TEFATSION, « An integrated transmission and distribution test system for evaluation of transactive energy designs, » *Applied Energy*, t. 240, p. 666-679, 2019, ISSN : 03062619. DOI : 10.1016/j.apenergy.2019.01.178.
- [60] T. HARDY, « Transactive Energy Simulation Platform, » Pacific Northwest National Laboratory (PNNL), rapp. tech., 2017.

- [61] S. KATIPAMULA, J. HAACK, G. HERNANDEZ, B. AKYOL et J. HAGERMAN, « VOLT-TRON : An Open-Source Software Platform of the Future, » *IEEE Electrification Magazine*, t. 4, n° 4, p. 15-22, 2016, ISSN : 2325-5897. DOI : 10.1109/MELE.2016.2614178.
- [62] OPENADR ALLIANCE, « Demand Response Program Implementation Guide, » *OpenADR Alliance*, p. 1-91, 2016.
- [63] B. VAN DER WAAIJ, W. WIJBRANDI et M. KONSMAAN, « White paper Energy Flexibility Platform and Interface (EF-Pi), » TNO INRG Alliander Technolution, rapp. tech., 2015.
- [64] F. LEZAMA, J. SOARES, P. HERNANDEZ-LEAL, M. KAISERS, T. PINTO et Z. VALE, « Local Energy Markets : Paving the Path Toward Fully Transactive Energy Systems, » *IEEE Transactions on Power Systems*, t. 34, n° 5, p. 4081-4088, 2019, ISSN : 15580679. DOI : 10.1109/TPWRS.2018.2833959.
- [65] G. GALLO, « Electricity market games : How agent-based modeling can help under high penetrations of variable generation, » *Electricity Journal*, t. 29, n° 2, p. 39-46, 2016, ISSN : 10406190. DOI : 10.1016/j.tej.2016.02.001.
- [66] H. S. NUNNA et D. SRINIVASAN, « Multiagent-Based Transactive Energy Framework for Distribution Systems with Smart Microgrids, » *IEEE Transactions on Industrial Informatics*, t. 13, n° 5, p. 2241-2250, 2017, ISSN : 15513203. DOI : 10.1109/TII.2017.2679808.
- [67] A. SAFDARIAN, M. FOTUHI-FIRUZABAD et M. LEHTONEN, « A distributed algorithm for managing residential demand response in smart grids, » *IEEE Transactions on Industrial Informatics*, t. 10, n° 4, p. 2385-2393, 2014, ISSN : 15513203. DOI : 10.1109/TII.2014.2316639.
- [68] T. M. MASAUD, J. WARNER et E. F. EL-SAADANY, « A Blockchain-Enabled Decentralized Energy Trading Mechanism for Islanded Networked Microgrids, » *IEEE Access*, t. 8, p. 211 291-211 302, 2020, ISSN : 21693536. DOI : 10.1109/ACCESS.2020.3038824.

- [69] K. MURPHY, *Machine Learning : A Probabilistic Perspective*. Massachusetts : The MIT Press, 2012, p. 27-71, ISBN : 9780262018029. DOI : 10.1007/978-94-011-3532-0_2.
- [70] T. AHMAD, H. CHEN, R. HUANG et al., « Supervised based machine learning models for short, medium and long-term energy prediction in distinct building environment, » *Energy*, t. 158, p. 17-32, 2018, ISSN : 03605442. DOI : 10.1016/j.energy.2018.05.169.
- [71] S. HAYKIN, *Adaptive Filter Theory*, 5th edition. Pearson, 2013.
- [72] P. X. LOEFFEL, « Adaptive machine learning algorithms for data streams subject to concept drifts, » thèse de doct., Université Pierre et Marie Curie, 2018.
- [73] J. G. MORENO-TORRES, T. RAEDER, R. ALAIZ-RODRÍGUEZ, N. V. CHAWLA et F. HERRERA, « A unifying view on dataset shift in classification, » *Pattern Recognition*, t. 45, n° 1, p. 521-530, 2012, ISSN : 00313203. DOI : 10.1016/j.patcog.2011.06.019.
- [74] G. I. WEBB et R. HYDE, « Characterizing Concept Drift, » *Data Mining and Knowledge Discovery*, 2015. arXiv : arXiv:1511.03816v6.
- [75] I. ZLIOBAITE, « Adaptive Training Set Formation, » thèse de doct., Vilnius University, 2010, p. 248.
- [76] G. WIDMER et M. KUBAT, « Learning in the presence of concept drift and hidden contexts, » *Machine Learning*, t. 23, n° 1, p. 69-101, 1996, ISSN : 0885-6125. DOI : 10.1007/BF00116900.
- [77] Z.-H. ZHOU, *Ensemble Methods : Foundations and Algorithms*. Boca Raton : CRC Press, 2012, ISBN : 9781439830055.
- [78] R. PALNITKAR et J. CANNADY, « A Review of Adaptive Neural Networks, » in *IEEE SoutheastCon, 2004. Proceedings.*, IEEE, 2004, p. 38-47, ISBN : 0-7803-8368-0. DOI : 10.1109/SECON.2004.1287896.

- [79] J. GAMA, P. MEDAS, G. CASTILLO et P. RODRIGUES, « Learning with Drift Detection, » in *Advances in Artificial Intelligence - SBIA 2004*, t. 3171, Springer, 2004, p. 286-295, ISBN : 978-3-540-23237-7. DOI : 10.1007/978-3-540-28645-5_29.
- [80] I. KOYCHEV et R. LOTHIAN, « Tracking Drifting Concepts by Time Window Optimization, » in *Research and Development in Intelligent Systems XXII*, London : Springer London, 2006, p. 46-59, ISBN : 9781846282256. DOI : 10.1007/978-1-84628-226-3_5.
- [81] R. KLINKENBERG et T. JOACHIMS, « Detecting Concept Drift with Support Vector Machines, » *Proceedings of the Seventeenth International Conference on Machine Learning*, p. 487-494, 2000.
- [82] A. BIFET et R. GAVALDÀ, « Learning from Time-Changing Data with Adaptive Windowing, » in *Proceedings of the 2007 SIAM International Conference on Data Mining*, Philadelphia, PA : Society for Industrial et Applied Mathematics, 2007, p. 443-448, ISBN : 978-0-89871-630-6. DOI : 10.1137/1.9781611972771.42.
- [83] INTERNATIONAL ENERGY AGENCY (IEA), « World Energy Outlook 2019, » IEA, Paris, rapp. tech., 2019.
- [84] S. BEHBOODI, D. P. CHASSIN, N. DJILALI et C. CRAWFORD, « Transactive control of fast-acting demand response based on thermostatic loads in real-time retail electricity markets, » *Applied Energy*, t. 210, p. 1310-1320, 2018, ISSN : 03062619. DOI : 10.1016/j.apenergy.2017.07.058.
- [85] N. MOHAMMAD et A. RAHMAN, « Transactive control of industrial heating–ventilation–air-conditioning units in cold-storage warehouses for demand response, » *Sustainable Energy, Grids and Networks*, t. 18, p. 100 201, 2019, ISSN : 23524677. DOI : 10.1016/j.segan.2019.100201.
- [86] H. HAO, C. D. CORBIN, K. KALSI et R. G. PRATT, « Transactive Control of Commercial Buildings for Demand Response, » *IEEE Transactions on Power Systems*, t. 32, n° 1, p. 774-783, 2017, ISSN : 08858950. DOI : 10.1109/TPWRS.2016.2559485.

- [87] B. SHAHRIARI, K. SWERSKY, Z. WANG, R. P. ADAMS et N. DE FREITAS, « Taking the human out of the loop : A review of Bayesian optimization, » *Proceedings of the IEEE*, t. 104, n° 1, p. 148-175, 2016, ISSN : 15582256. DOI : 10.1109/JPROC.2015.2494218.
- [88] B. SETTLES, « From Theories to Queries : Active Learning in Practice, » *Active Learning and Experimental Design workshop In conjunction with AISTATS 2010*, t. 16, p. 1-18, 2011.
- [89] S. ZHANG, L. YAO, A. SUN et Y. TAY, « Deep Learning Based Recommender System, » *ACM Computing Surveys*, t. 52, n° 1, p. 1-38, 2019, ISSN : 0360-0300. DOI : 10.1145/3285029.
- [90] J. FÜRNKRANZ et E. HÜLLERMEIER, *Preference Learning*. Berlin, Heidelberg : Springer Berlin Heidelberg, 2011, ISBN : 978-3-642-14124-9. DOI : 10.1007/978-3-642-14125-6.
- [91] R. BURKE, « Hybrid Recommender Systems : Survey and Experiments, » *User Modeling and User-Adapted Interaction*, 2002, ISSN : 00138703. DOI : <https://doi.org/10.1023/A:1021240730564>.
- [92] K. HARA, « Characterization of stationary preferences in a continuous time framework, » *Journal of Mathematical Economics*, t. 63, p. 34-43, 2016, ISSN : 03044068. DOI : 10.1016/j.jmateco.2015.11.005.
- [93] Q. LIU, A. H. REINER, A. FRIGESSI et I. SCHEEL, « Diverse personalized recommendations with uncertainty from implicit preference data with the Bayesian Mallows model, » *Knowledge-Based Systems*, t. 186, p. 104960, 2019, ISSN : 09507051. DOI : 10.1016/j.knosys.2019.104960.
- [94] N. BAZENKOV et M. GOUBKO, « Advanced Planning of Home Appliances with Consumer's Preference Learning, » in *Air & Space Power Journal*, Springer International Publishing, 2018, p. 249-259, ISBN : 9783030006167. DOI : 10.1007/978-3-030-00617-4_23.

- [95] T. SILVEIRA, M. ZHANG, X. LIN, Y. LIU et S. MA, « How good your recommender system is? A survey on evaluations in recommendation, » *International Journal of Machine Learning and Cybernetics*, t. 10, n^o 5, p. 813-831, 2019, ISSN : 1868808X. DOI : 10.1007/s13042-017-0762-9.
- [96] M. SHANN et S. SEUKEN, « Adaptive home heating under weather and price uncertainty using GPs and MDPs, » *13th International Conference on Autonomous Agents and Multiagent Systems, AAMAS 2014*, t. 1, p. 821-828, 2014.
- [97] D. KIM, J. LEE et J. CHOI, « Learning User Preferences and Understanding Calendar Contexts for Event Scheduling, » 2018. arXiv : arXiv:1809.01316v2.
- [98] C. C. AGGARWAL, « Towards systematic design of distance functions for data mining applications, » in *Proceedings of the ninth ACM SIGKDD international conference on Knowledge discovery and data mining - KDD '03*, New York, New York, USA : ACM Press, 2003, p. 9, ISBN : 1581137370. DOI : 10.1145/956750.956756.
- [99] F. AMARA, K. AGBOSSOU, A. CARDENAS, Y. DUBÉ et S. KELOUWANI, « Comparison and Simulation of Building Thermal Models for Effective Energy Management, » *Scientific research publishing*, t. 4, p. 973-981, 5 2015, ISSN : 2050750X. DOI : 10.4236/sgre.2015.6400.
- [100] Y. WANG et J. BO, « Fast algorithm for matrix inversion in generalized predictive control, » *IEEE*, juill. 2011, p. 7367-7371, ISBN : 978-1-4244-9436-1. DOI : 10.1109/MACE.2011.5988752.
- [101] S.-H. MIN et I. HAN, « Recommender Systems Using Support Vector Machines, » D. LOWE et M. GAEDKE, éd., Springer Link, 2005, p. 387-393. DOI : 10.1007/11531371_50.
- [102] M. WILD, « Prosody IM Documentation, » rapp. tech., 2022.
- [103] A. AGRAWAL, R. VERSCHUEREN, S. DIAMOND et S. BOYD, « A rewriting system for convex optimization problems, » *Journal of Control and Decision*, t. 5, n^o 1, p. 42-60, 2018.

- [104] C. R. HARRIS, K. J. MILLMAN, S. J. van der WALT et al., « Array programming with NumPy, » *Nature*, t. 585, n° 7825, p. 357-362, sept. 2020. DOI : 10.1038/s41586-020-2649-2. adresse : <https://doi.org/10.1038/s41586-020-2649-2>.
- [105] M. AWAD et R. KHANNA, « Support Vector Regression, » in *Efficient Learning Machines*, Berkeley, CA : Apress, 2015, p. 67-80. DOI : 10.1007/978-1-4302-5990-9_4.
- [106] SANDIA NATIONAL LABORATORY et US. DEPARTMENT OF ENERGY, « SANDIA PV Array Performance Model, » rapp. tech., 2021.
- [107] CANADIAN SOLAR, « MaxPower CS6X Series, » Solar Panels Datasheet, rapp. tech., 2013.
- [108] ABB, « ABB string inverters, » Solar Inverters Datasheet, rapp. tech., 2015.
- [109] J. H. YOUSIF, H. A. KAZEM, N. N. ALATTAR et I. I. ELHASSAN, « A comparison study based on artificial neural network for assessing PV/T solar energy production, » *Case Studies in Thermal Engineering*, t. 13, p. 100407, 2019, ISSN : 2214157X. DOI : 10.1016/j.csite.2019.100407.
- [110] R. BRUNO, G. PIZZUTI et N. ARCURI, « The Prediction of Thermal Loads in Building by Means of the en ISO 13790 Dynamic Model : A Comparison with TRNSYS, » *Energy Procedia*, t. 101, n° September, p. 192-199, 2016, ISSN : 18766102. DOI : 10.1016/j.egypro.2016.11.025.
- [111] S. GOYAL et P. BAROOAH, « A method for model-reduction of non-linear thermal dynamics of multi-zone buildings, » *Energy and Buildings*, t. 47, p. 332-340, avr. 2012, ISSN : 03787788. DOI : 10.1016/j.enbuild.2011.12.005.
- [112] M. R. HAMOUDA, M. E. NASSAR et M. M. A. SALAMA, « Centralized Blockchain-Based Energy Trading Platform for Interconnected Microgrids, » *IEEE Access*, t. 9, p. 95 539-95 550, 2021, ISSN : 2169-3536. DOI : 10.1109/ACCESS.2021.3090213.